




IA. MEDICINA E INGENIERÍA ALGORITMOS QUE SALVAN VIDAS

IA. MEDICINA E INGENIERÍA

Algoritmos que salvan vidas

Luis Cabero Roura
Abel Guzmán López

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
UNIVERSIDAD AUTÓNOMA DE BARCELONA



IA. Medicina e ingeniería

Algoritmos que salvan vidas



IA. Medicina e ingeniería

Algoritmos que salvan vidas

EDITORES

Luis Cabero Roura
Abel Guzmán López

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
UNIVERSIDAD AUTÓNOMA DE BARCELONA

Primera edición 2025.

ISBN: 978-607-27-2720-5

Santos Guzmán López
Rector
Mario Alberto Garza Castillo
Secretario General
José Javier Villarreal
Secretario de Extensión y Cultura
Antonio Ramos Revillas
Director de Editorial Universitaria

© Universidad Autónoma de Nuevo León
© Luis Cabero Roura y Abel Guzmán López
© Los autores y las autoras, por sus textos

Dirección de Editorial Universitaria UANL
Padre Mier 909 Pte. esquina con Vallarta, Centro, Monterrey, Nuevo León,
México, C.P. 64000.
Teléfono: (81) 8329 4111.
e-mail: editorial.uanl@uanl.mx
Página web: editorialuniversitaria.uanl.mx

.....
Esta publicación, en su integridad y los derechos contenidos en ella, está protegida por la Ley Federal de Derecho de Autor y la Ley Federal de Protección a la Propiedad Industrial, por lo que no podrá ser reproducida con fines comerciales sin autorización del editor. Asimismo, queda prohibido cualquier uso de esta publicación, sea total o parcialmente, con fines de entrenamiento de cualquier clase de inteligencia artificial, minería de datos y textos, incluyendo, pero no limitado, a la generación y/o publicación de obras derivadas o contenidos basados total o parcialmente en esta obra y en cualquiera de sus partes, pertenecientes a la Universidad Autónoma de Nuevo León, a través de la Dependencia Universitaria que corresponde. Las violaciones a estas disposiciones constituyen una infracción en materia de comercio, derechos de autor y un delito.
.....

Impreso en Monterrey, México.
Printed in Monterrey, Mexico



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



EDITORIAL UNIVERSITARIA UANL



Universitat Autònoma
de Barcelona



La salud persona a persona



VISIÓN UANL
2040



excelencia
por medio
la educación

Índice

Prólogo	11
Capítulo I	
Introducción a la Inteligencia Artificial (IA) en Obstetricia y Ginecología	15
<i>L. Cabero Roura (Barcelona) y Abel Guzmán López (Monterrey)</i>	
1.1. Definición y conceptos básicos de la IA	16
1.2. Historia y evolución de la IA en la medicina	25
1.3. Aplicaciones generales de la IA en la salud de la mujer	41
Capítulo II	
Fundamentos de la IA: Algoritmos y Técnicas	55
<i>Romeo Sánchez Nigenda (Monterrey), Luis Martín Torres Treviño (Monterrey), Sara Elena Garza Villarreal (Monterrey), Erick de Jesús Ordaz Rivas (Monterrey) Dr. Nasser Mohamed Noriega</i>	
2.1. Aprendizaje automático (Machine Learning)	55
2.2. Redes Neuronales y Aprendizaje Profundo (Deep Learning)	76
2.3. Procesamiento del Lenguaje Natural (NLP) en Salud	81
2.4. Técnicas de Visión por Computador	93
Capítulo III	
Uso de la IA en la Investigación clínica en ginecología y obstetricia	111
<i>Omar Alberto Hernández Barboza (Monterrey), Hilda Cristina Ochoa Bayona (Monterrey)</i>	
3.1. Introducción	111
3.2. Relación con la Inteligencia Artificial	112
3.3. Fundamentos y Tecnología Clave	112
3.4. Diseño de Investigación con IA en Ginecología y Obstetricia	113
3.5. Aplicaciones Actuales por Área	114
3.6. Implementación Reales y Casos de Uso Institucionales	116
3.7. Recomendaciones Operativas para Centros que Desean comenzar Implementaciones de la IA en la Investigación Clínica	119
3.8. Ejemplos Detallados de Estudios Representativos	120
3.9. Recursos Prácticos: Herramientas y Repositorios que se Pueden Utilizar para Alimentar a la IA y Desarrollar Investigación Clínica Confiable	120
Capítulo IV	
IA en Obstetricia	
<i>Rodrigo Orozco (Málaga)</i>	
4.1. Diagnóstico prenatal asistido por IA	128
<i>Alba Farras Llobet (Barcelona) y María Ángeles Sánchez (Barcelona)</i>	
4.2. IA en el seguimiento del bienestar fetal	132
4.3. IA en la Diabetes Mellitus Gestacional: De la Predicción a la Aplicación Clínica	137
<i>Dr. Luis Abel Guzmán Ochoa Dr. Leonardo Mancillas Adame Profesor de Medicina</i>	
4.4. Predicción de complicaciones obstétricas	143
4.5. Sistemas de Apoyo para la Toma de Decisiones en el Parto	151
<i>Miquel Martra Celma (Barcelona), Juan Antonio Soria López (Monterrey)</i>	

Capítulo V

IA en Ginecología

Manuel Albi

- 5.1. Diagnóstico precoz de cáncer ginecológico 169
Manuel Albi (Barcelona), Emilio Modesto Treviño Salinas (Monterrey)
- 5.2. Estado actual del uso de la inteligencia artificial en la aplicación de las técnicas de reproducción asistida 184
- 5.3. Tratamiento Asistido por IA en Ginecología 194
Javier de la Torre Fernández de Vega (Barcelona)

Capítulo VI

Procesamiento de imágenes médicas con IA

Pablo Naval Baudín (Barcelona), Nadine Romera Lobato (Barcelona)

- 6.1. Introducción 205
- 6.2. Evolución y contexto histórico 207
- 6.3. Aplicaciones clínicas 208
- 6.4. Diferentes enfoques de segmentación 209

Capítulo VII

Recopilación y análisis de Datos en inteligencia artificial

Luis Cabero (Barcelona) y Esther Martínez (Barcelona)

- 7.1. Fuentes de Datos en Obstetricia y Ginecología 219
- 7.2. Calidad y Ética en la Recopilación de Datos 224
- 7.3. Calidad Asistencial 227
- 7.4. La IA en la Práctica Médica: Experiencia, Perspectiva y Formación 234
- 7.5. Ética en la Recopilación de Datos, su Uso y su Privacidad 237
- 7.6. Protocolo de Comunicación Médica Integrando IA en Ginecología y Obstetricia 241
- 7.7. Resultados de Eficiencia y Sensibilidad del Uso de IA en Ginecología y Obstetricia 246
- 7.8. Nuevas Estructuras de Gobernanza y Tomas de Decisiones 259
- 7.9. Indicadores Comunes en Ginecología y Obstetricia 262
- 7.10. Manual de Métodos de Acreditación Clínica 268
- 7.11. Formación Continuada en Salud 271
- 7.12. Aprendizaje Federado en Salud para Preservar la Privacidad 276
- 7.13. Papel de los Programas de Calidad Asistencial 278
- 7.14. ¿Se puede trabajar con Dos Bases de Datos Distintas a la Vez? 281
- 7.15. Infraestructura Necesaria para Disponer de IA en Técnicas de Obstetricia y Ginecología 281
- 7.16. Administración de los Riesgos en Medicina: Conceptos Básicos 285
- 7.17. ¿Cómo Puede Ayudar la IA en la Prevención de Riesgos en Medicina? 286
- 7.18. Aprendizaje Federado en Salud para Preservar la Privacidad 288

Capítulo VIII

Retos y Limitaciones de la IA en Obstetricia y Ginecología

Rodrigo Orozco Fernández (Barcelona)

- 8.1. Barreras técnicas y de integración clínica 295
- 8.2. Retos éticos y legales 301
- 8.3. Desigualdades en el acceso a la tecnología 309

Capítulo IX

Conclusiones y Perspectivas

Cristina Caramés Sánchez (Barcelona)

9.1. Resumen de los avances actuales	319
9.2. Consideraciones para una implementación ética y segura de la IA	321
9.3. Recomendaciones para la investigación y desarrollo futuros	321

Capítulo X

Apendix: Recursos Técnicos y Guías Prácticas

A.1. Introducción a las herramientas de programación para IA en salud	327
A.2. Bibliotecas de código abierto para el análisis de datos médicos	331
A.3. Recursos para la formación en IA para profesionales de la salud	356

Capítulo XI

Avances recientes destacados en Medicina

Adendo 1. Avances recientes destacados en Medicina	367
Adendo 2. El alfabeto cerebral humano	387
Adendo 3. Calidad Asistencial	391
Adendo 4. Glosario de Inteligencia Artificial (IA)	410

Capítulo XII

Referencias	417
-------------	-----

Capítulo XIII

Autores	431
---------	-----

Prefacio

A medida que se han ido introduciendo avances en el escenario de la inteligencia artificial (IA), a su vez hemos ido siendo más ignorantes de muchos procesos intermedios que nuestro cuerpo humano, nos brinda cada día.

En muy poco tiempo, de igual forma como ha ocurrido con otras vertientes de la ciencia, se ha descubierto y se ha empezado a interaccionar con distintos sistemas, dejando por hecho que las brechas desde el punto de partida hasta un posible final, pueden ser extensas en poco tiempo, y no en años como sucedía antes, sin mucha interacción con la tecnología.

Nadie pone en discusión que esta tecnología proporciona una ayuda impresionante, cuando es utilizada de manera racional y ética, y es por ello que los centros reguladores que cambien sus sistemas de control, tendrán en el personal médico y sanitario a los artífices de estos avances que, sin duda, serán fundamentales.

Es verdad que, así como estamos magnificando la parte positiva, la sociedad y los centros reguladores, deberán ser muy cautos y precisos para que esta metodología no se utilice para fines no ortodoxos, y la sociedad sea maltrecha desde los inicios de los embarazos.

Como pueden asumir, un libro de estas características no es fácil de hacer, y mucho menos para las manos de personal no acostumbrado con esta técnica, como por ejemplo la mayoría de médicos. Sin embargo, no podemos renunciar a poner el primer eslabón. Y ahí es donde empieza la obra. Ciencia básica con complejidad creciente a medida que el libro avanza, con material realizado por reconocidos autores.

El presente libro se dedica exclusivamente a la salud femenina. Desde un punto de vista profesional se analizan el cómo las técnicas van cambiando y mejorando, así cómo se introducen nuevos campos, entre otras situaciones singulares.

Reconocemos y agradecemos la importante colaboración del Dr. Luis Cabero y del Dr. Abel Guzmán que participaron con la coordinación de los demás autores participantes, dejando una obra que simboliza el fruto del trabajo de distintas instituciones educativas de gran prestigio, a quienes también se extiende el agradecimiento, en particular al Hospital Quironsalud de Barcelona, España, a su personal administrativo involucrado, por todas las facilidades brindadas.

Deseamos que este libro sea de gran aporte a la generación del nuevo e innovador conocimiento, siempre con apego ético que lleve al bienestar de toda nuestra sociedad.

Dr. Med. Santos Guzmán López
Rector de la Universidad Autónoma de Nuevo León, México.

Prólogo

El avance de la inteligencia artificial (IA) en el ámbito de la medicina está marcando un punto de inflexión en la forma en que se conciben el diagnóstico, el tratamiento y la gestión clínica. En la especialidad de **obstetricia y ginecología**, la aplicación de herramientas de IA ha demostrado un enorme potencial para mejorar la precisión diagnóstica, optimizar la toma de decisiones y personalizar la atención médica, todo ello en un contexto en el que la seguridad materno-fetal es una prioridad absoluta.

El desarrollo de modelos de aprendizaje automático ha permitido avances significativos en la **predicción del parto prematuro**, la identificación de **complicaciones obstétricas** y la detección temprana de **anomalías fetales** mediante ecografía asistida por IA. En ginecología, el uso de algoritmos de reconocimiento de patrones ha mejorado la capacidad de detección del **cáncer de cuello uterino y de mama**, mientras que los sistemas de apoyo a la decisión clínica han optimizado la selección de tratamientos en patologías como el **síndrome de ovario poliquístico o la endometriosis**.

Sin embargo, la implementación de la IA en la práctica clínica plantea desafíos que van más allá de la precisión de los modelos. **La validación de algoritmos en poblaciones diversas, la integración con los sistemas de historia clínica electrónica, la transparencia en la interpretación de los resultados y la adherencia a principios éticos y regulatorios** son aspectos fundamentales que deben ser considerados para garantizar una aplicación segura y efectiva de estas tecnologías.

Este libro tiene como objetivo proporcionar a los profesionales de la salud una **visión integral y basada en la evidencia** sobre la aplicación de la inteligencia artificial en obstetricia y ginecología. A lo largo de sus capítulos, se abordarán los principios fundamentales del aprendizaje automático y la IA aplicada a la medicina, los avances más recientes en la especialidad, así como las oportunidades y limitaciones de estas herramientas en la práctica clínica. Además, se incluirán casos clínicos y experiencias reales de implementación, con el propósito de ofrecer una perspectiva pragmática y orientada a la aplicación.

La medicina basada en inteligencia artificial no busca sustituir el juicio clínico, sino complementarlo con análisis avanzados y predicciones basadas en grandes volúmenes de datos. Comprender estas tecnologías y su impacto en la asistencia materno-infantil es esencial para los profesionales de la salud que deseen **liderar la innovación en sus respectivas áreas y garantizar la mejor calidad de atención para sus pacientes**.

Queremos expresar nuestro más profundo agradecimiento a todos los **autores y colaboradores** que han contribuido con su conocimiento y experiencia en la redacción de los capítulos de esta obra. Su dedicación y compromiso han sido fundamentales para garantizar que este libro refleje el estado actual de la inteligencia artificial en obstetricia y ginecología, proporcionando una referencia rigurosa y actualizada para los profesionales de la salud.

Asimismo, extendemos nuestro reconocimiento a las **universidades e instituciones académicas** que han participado en este proyecto, brindando su apoyo en la investigación y desarrollo de los contenidos. En particular, agradecemos la colaboración de la **Universidad Autónoma de Nuevo León y Universidad Autónoma de Barcelona**, así como la participación de los centros de Quironsalud de España cuyos equipos de trabajo han aportado su experiencia en inteligencia artificial aplicada a la medicina.

Este libro es el resultado de un esfuerzo colectivo en el que la sinergia entre la comunidad médica, la academia y la tecnología ha sido clave. Esperamos que esta obra sirva como una guía de referencia y un punto de partida para la integración efectiva de la inteligencia artificial en la obstetricia y la ginecología.

Dr. Med. Oscar Vidal Gutiérrez
Director de la Facultad de Medicina y Hospital Universitario
“Dr. José Eleuterio González” de la UANL
Monterrey, México
Octubre 2025.

1. INTRODUCCIÓN A LA INTELIGENCIA ARTIFICIAL (IA) EN OBSTETRICIA Y GINECOLOGÍA

Introducción a la inteligencia artificial (IA) en obstetricia y ginecología

Prof. L. Cabero Roura (Barcelona) y Dr. med. Abel Guzmán Lopez(Monterrey)

Es una realidad que el contenido doctrinal y científico de la ciencia avanza hacia una dirección que algunos grupos denominan "virtual", pero que cada día se demuestra más real de lo que inicialmente se pensaba. Los elementos de trabajo que configuran esa realidad son heterogéneos pero complementarios. A medida que un árbol crece, su tallo se ramifica y se especializa en diversas funciones: ya sea de soporte para su arquitectura o para proporcionar la base donde crezcan nuevas ramas con sus hojas, esenciales para una buena transformación de la composición atmosférica y para obtener una oxigenación que, transportada por la savia, será de utilidad indispensable para que sus raíces se desarrollen y permitan estabilidad y sustento a todo el árbol. De esta forma, el conjunto trabaja para obtener un elemento básico para el bosque, del cual se iniciará otro ciclo, también encadenado, con resultados diversos en función de la familia vegetal a la que pertenezcan sus elementos.

Hemos visto cómo, en pocas palabras, se ha hecho un repaso muy somero de la biología de un árbol y un bosque, y desde ahí, cada uno puede añadir la secuencia de fenómenos que desee, con resultados muy diversos en cada lugar. Por lo tanto, este proceso no es virtual, sino real, y coexiste con nuestro ciclo vital, sin que a nadie le sorprenda su complejidad. Pues bien, al adentrarnos en la realidad "virtual", ocurre un proceso semejante, pero con escenarios y reglas de observación y manipulación distintas a las que hasta hace poco disfrutábamos. Cada uno de los pasos que hemos ido recordando se denomina de forma distinta y, dada su complejidad inicial, debe utilizarse una nueva semántica que facilite nuestra labor y, al final, sea de utilidad para todos. Ello nos obliga a un proceso de formación y adiestramiento si queremos comunicarnos entre nosotros y con la nueva tecnología. Dado que esta semántica es ajena a nuestros conocimientos actuales, a las personas que no estén familiarizadas con este sendero les será difícil superarlo, pero el proceso formativo es el mismo que se ha utilizado hasta ahora. Hace unos años, hablar de un *chip*, un *boot*, un *chat*, etc., era casi un insulto, y hoy día ya han sido incluidos en el diccionario de la Real Academia Española. Lo mismo ocurrirá en pocos años con la matriz de confusión, el aprendizaje profundo, los vectores, inteligencia artificial, inteligencia de enjambre, los vectores de ruido, los transformadores generativos preentrenados (GPT), unidad lineal rectificadora, la red neuronal recurrente (RNN), codificación contextual, etc.

Por lo tanto, los profesionales del futuro (prácticamente ya en la actualidad) deberán acostumbrarse a utilizar la nueva semántica y adquirir el adiestramiento necesario para manejar con cautela, profesionalidad y ética los nuevos paradigmas que están llegando a nuestros entornos. Sin lugar a dudas, una vez que se hayan adentrado un poco, los beneficios y los descubrimientos de sus funcionalidades les favorecerán y ayudarán a encontrar soluciones basadas en el conocimiento de muchos elementos, lo que redundará en una mejoría personal y social incontestable.

La llamada inteligencia artificial (a partir de ahora, la IA) es la máquina o el sistema informático diseñado para realizar tareas que habitualmente requieren inteligencia humana, lo que incluye habilidades como el razonamiento, el aprendizaje, la percepción, la comprensión del lenguaje y la toma de decisiones tanto personales como colectivas. La IA combina disciplinas como matemáticas, informática, neurociencia y lingüística para simular o emular procesos cognitivos humanos.

La evolución tecnológica ha impactado significativamente el campo de la salud, y la Inteligencia Artificial (IA) ha emergido como una herramienta clave en el avance de la obstetricia y ginecología. Esta disciplina médica, que abarca la salud reproductiva femenina, el embarazo, el parto y el posparto, se beneficia de la IA

para mejorar la detección temprana de enfermedades, optimizar tratamientos y personalizar la atención a las pacientes.

Joana Barbany, consultora, destaca que "el origen de la IA es la lingüística, y no la tecnología" [1]. Su exitoso libro *Rehumanizando la tecnología* aborda el impacto de la tecnología y la revolución digital en las personas, la empresa y la sociedad, resaltando sus ventajas y desafíos.

La tecnología puede acercar a las personas, facilitar tareas cotidianas como comprar o estudiar e incrementar la productividad de las empresas. Sin embargo, también puede tener consecuencias negativas en la salud y la felicidad de las personas. La revolución digital y la tecnología tienen un impacto transformador: han cambiado la forma en que vivimos y han generado un cambio disruptivo en la economía, las personas y la sociedad. Es necesario ahora, más que nunca, humanizar las relaciones y promover un enfoque más equilibrado y consciente de la tecnología para conseguir una sociedad más justa y feliz.

Las humanidades tienen recorrido. En una entrevista, Barbany también lucha por romper la brecha de género que existe en el mundo tecnológico, mostrando un perfil completo que implica haber trabajado en la administración pública, como consultora de empresas privadas y emprendedora.

Una reflexión que rompe esquemas es sobre el origen de la IA, que ella sitúa en la lingüística, en el perfil de las humanidades de los estudios, antes que en el propio campo tecnológico. También explica aquellos aspectos humanos que la IA todavía no ha conseguido, como la comunicación no verbal:

"Cuando hablamos de lenguaje existe aquello del emisor, el receptor, el canal y el contenido. Esto seguirá igual, pero hay todo un tema de la comunicación no verbal que también forma parte del lenguaje que la IA pierde: la no verbal, cómo al comunicar somos literales o tenemos una segunda connotación, o vamos con segundas... Y eso la IA aún no lo sabe leer. No sabe si estamos haciendo una connotación".

A partir de aquí, Barbany desglosa los imprescindibles para aprender a humanizar la tecnología y lograr que la IA se acerque más a nosotros que a la inversa:

"Aprender, es decir, el conocimiento, es fácil. Además, hoy en día, con cursos por internet, es muy fácil realizar un cursillo sobre cómo aprender con la IA. Pero de las personas ser responsables, saber trabajar en equipo, comunicar bien, tener unos valores, esto cuesta mucho y esto o se tiene o no se tiene, no se puede entrenar. Por lo tanto, cuando encuentras a una persona que tiene estas *soft skills* la tienes que cuidar como oro. Luego ya lo enseñarás a hacer".

De todas maneras, es necesario tener unos conocimientos básicos informáticos para ir introduciéndose en esta nebulosa que, en estos momentos, conocemos solo en una parte muy pequeña.

1.1. Conceptos Básicos de la Inteligencia Artificial

1.1.1. Definición y Clasificación

La IA es un campo de la informática que busca desarrollar sistemas capaces de realizar tareas que, si fueran realizadas por humanos, requerirían inteligencia. Existen diversas clasificaciones, y a medida que se profundice en el tema, irán apareciendo otras, basadas en aspectos quizás todavía no identificados. En síntesis, las fuentes de información sugieren que no toda la tecnología o metodología es la misma, por lo que debemos clasificarla para saber dónde nos encontramos. Asimismo, se debe tener presente que no todos los campos de la IA son iguales, por lo que debemos analizar la capacidad de la herramienta que se usa. Con todo ello, es decir, intentando mezclar los distintos tipos con las distintas capacidades, y subsidiariamente definir las principales áreas que, utilizando técnicas especializadas y distintas, nos facilitarán los resultados de ciertos aspectos.

A continuación, se desglosará cada uno de esos preceptos. Empecemos por su clasificación genérica:

Clasificación de la IA:

- **IA débil (Narrow AI):** Diseñada para realizar tareas específicas (por ejemplo, asistentes virtuales como Siri o Alexa, sistemas de recomendación).
- **IA fuerte (General AI):** Teóricamente, sería capaz de realizar cualquier tarea intelectual que un ser humano pueda hacer, pero aún está en desarrollo.
- **Superinteligencia artificial:** Un nivel hipotético en el que la inteligencia de las máquinas supera con creces la humana.

En función de sus capacidades, se perfilarán los distintos tipos de IA:

Tipos de IA según sus capacidades:

- **Reactiva:** Sistemas que responden a estímulos específicos sin capacidad de aprendizaje (por ejemplo, Deep Blue, la computadora que juega ajedrez).
- **Con memoria limitada:** Sistemas que pueden usar datos pasados para mejorar su desempeño futuro (como los vehículos autónomos).
- **Con teoría de la mente:** IA hipotética que entendería y simularía emociones humanas.
- **Autónoma o consciente:** IA que posee autoconciencia (actualmente no existe).

Con la información que ya se desprende de los dos atributos anteriores, se pueden identificar las principales áreas de la IA:

Áreas Principales de la IA:

- **IA Descriptiva o Basada en Reglas (Rule-Based AI):** Es el tipo de IA más básico. Se basa en reglas y lógica predefinida que le permite tomar decisiones simples. Esta forma de IA no es capaz de aprender de los datos ni mejorar con la experiencia. Un ejemplo son los sistemas expertos utilizados en el pasado para apoyar diagnósticos médicos.
- **Aprendizaje Automático (Machine Learning, ML):** Es una subárea de la IA que permite que los sistemas aprendan y mejoren automáticamente a partir de la experiencia sin ser programados explícitamente para ello. Los algoritmos de ML utilizan datos para identificar patrones y hacer predicciones o decisiones basadas en esos patrones.
 - **Tipos de aprendizaje automático:**
 - **Supervisado:** Los modelos se entrenan con un conjunto de datos etiquetado sistema aprende a través de ensayo y error, recibis, es decir, con ejemplos que contienen tanto la entrada como la salida deseada, lo que ayuda a que el sistema "aprenda" a predecir resultados.
 - **No supervisado:** El modelo trabaja con datos sin etiquetar y busca patrones o agrupaciones en los datos sin intervención humana.
 - **Por refuerzo:** Elendo recompensas o penalizaciones según las decisiones que toma en un entorno determinado.
- **Redes Neuronales Artificiales:** Inspiradas en el cerebro humano, las redes neuronales artificiales son estructuras de algoritmos interconectados (llamados "neuronas") que trabajan en conjunto para analizar datos y hacer predicciones. Se utilizan especialmente para el reconocimiento de patrones y tareas de clasificación complejas.
 - **Las redes neuronales están compuestas por varias capas de neuronas:**

- **Capa de entrada:** Recibe los datos.
 - **Capas ocultas:** Procesan la información, donde ocurre el aprendizaje profundo.
 - **Capa de salida:** Genera el resultado o predicción final.
- **Aprendizaje Profundo (Deep Learning):** Es una técnica avanzada de aprendizaje automático que emplea redes neuronales con múltiples capas ocultas (redes neuronales profundas). Estas redes profundas son especialmente útiles para tareas complejas como el reconocimiento de imágenes, la traducción automática y el procesamiento del lenguaje natural. En el aprendizaje profundo, el sistema puede aprender automáticamente características complejas de los datos sin intervención humana, gracias a la gran cantidad de capas en su red neuronal.
 - **Algoritmos de IA:** Un algoritmo es una secuencia de pasos o reglas que el sistema sigue para realizar una tarea. En IA, los algoritmos son responsables de procesar datos y generar resultados en función de esos datos.
 - **Algunos algoritmos comunes de IA incluyen:**
 - **Regresión lineal y logística:** Utilizados para predecir valores continuos o probabilidades.
 - **Árboles de decisión:** Empleados en la clasificación y toma de decisiones.
 - **Máquinas de soporte vectorial (SVM):** Útiles para la clasificación de datos.
 - **K-means y agrupación jerárquica:** Métodos de agrupamiento en aprendizaje no supervisado.
 - **Procesamiento del Lenguaje Natural (Natural Language Processing, NLP):** El NLP permite que las máquinas entiendan, interpreten y generen lenguaje humano. Esto incluye tareas como la traducción automática, el análisis de sentimientos y la creación de respuestas automáticas a preguntas. El NLP es fundamental para el desarrollo de *chatbots* y asistentes virtuales.
 - **Visión por Computadora:** Es una rama de la IA que permite que las máquinas “vean” e interpreten información visual, como imágenes y videos. Mediante el uso de algoritmos avanzados y redes neuronales, las computadoras pueden identificar objetos, reconocer caras y realizar otras tareas de procesamiento de imágenes.
 - **Big Data:** Se refiere al conjunto de datos de gran volumen y variedad que las tecnologías de IA necesitan para entrenar sus modelos. La IA y el aprendizaje automático dependen de estos grandes volúmenes de datos para mejorar su precisión y rendimiento. Sin datos suficientes, es difícil que los modelos de IA sean efectivos.
 - **Entrenamiento y Evaluación de Modelos:** El entrenamiento de un modelo implica enseñarle a realizar una tarea específica a través de datos históricos. Una vez que el modelo ha sido entrenado, se evalúa su rendimiento utilizando un conjunto de datos de prueba para medir su precisión, sensibilidad y otros criterios.
 - **Las métricas comunes para evaluar modelos incluyen:**
 - **Precisión:** El porcentaje de predicciones correctas.
 - **Sensibilidad y especificidad:** Métricas que miden el rendimiento en problemas de clasificación.
 - **Exactitud y precisión:** Miden la cantidad de errores o desviaciones en los resultados.
 - **Sesgo y Ética en la IA:** La ética es fundamental en el desarrollo y aplicación de la IA, especialmente en términos de privacidad, sesgo y transparencia. Los modelos de IA pueden aprender sesgos si se entrenan con datos que los contengan, lo que podría llevar a decisiones injustas o discriminatorias. Es importante que los desarrolladores trabajen para reducir el sesgo en sus modelos y asegurar que la IA se utilice de manera justa y equitativa. También es fundamental considerar la privacidad de los datos de los usuarios y cumplir con las normativas de protección de datos.

1.1.2. Resumen de Conceptos Clave y Aprendizaje en Redes Neuronales

Estos conceptos básicos forman la base de la IA y ayudan a comprender cómo funcionan los sistemas inteligentes. La IA involucra el uso de algoritmos, grandes cantidades de datos, técnicas de aprendizaje automático y profundo, así como herramientas para la interpretación de lenguaje y visión computacional. Además, es importante ser conscientes de la ética y el impacto social de la IA, dado que cada vez está más presente en nuestras vidas y en la toma de decisiones a nivel global.

Este tipo de IA es capaz de generar contenido nuevo, como imágenes, texto, música e incluso código. Utiliza algoritmos como los modelos generativos adversariales (GANs) y los transformadores, como el modelo GPT (*Generative Pre-trained Transformer*). La IA generativa es responsable de crear textos realistas e imágenes.

El aprendizaje en el contexto de las redes neuronales hace referencia a cómo una red neuronal ajusta sus parámetros internos (pesos) para realizar tareas como clasificación, predicción o reconocimiento de patrones. El proceso de aprendizaje permite que la red mejore su capacidad para hacer predicciones basadas en datos de entrada.

Las redes neuronales son modelos inspirados en el cerebro humano, donde las unidades básicas (neuronas) están organizadas en capas. El aprendizaje ocurre principalmente a través de un proceso llamado entrenamiento, y hay dos enfoques principales que se usan comúnmente: el aprendizaje supervisado y el aprendizaje no supervisado.

1. Aprendizaje Supervisado:

En este enfoque, el modelo aprende a partir de un conjunto de datos etiquetado, es decir, el conjunto de entrenamiento contiene tanto las entradas (características) como las salidas deseadas (etiquetas). El objetivo es ajustar los pesos de la red para minimizar el error entre las predicciones y las etiquetas reales.

○ Proceso:

- **Propagación hacia adelante:** Los datos de entrada pasan a través de las capas de la red neuronal, y la red realiza una predicción.
- **Cálculo del error:** Se calcula la diferencia entre la predicción de la red y la salida real (usando una función de pérdida).
- **Retropropagación:** El error se propaga hacia atrás a través de la red para actualizar los pesos de las neuronas usando un algoritmo de optimización (como el algoritmo de gradiente descendente).

2. Aprendizaje No Supervisado:

Aquí, la red neuronal intenta aprender patrones y estructuras en los datos sin que se le proporcionen etiquetas. Este enfoque es útil cuando no se tiene un conjunto de datos etiquetado, o cuando se quieren descubrir patrones complejos en los datos.

○ Ejemplos:

- **Redes neuronales autoorganizadas (SOM):** Se usan para reducción de dimensionalidad y agrupamiento de datos.
- **Autoencoders:** Se utilizan para aprender representaciones compactas de datos de alta dimensionalidad, como imágenes o texto.

3. Aprendizaje Reforzado:

Un enfoque más avanzado es el aprendizaje por refuerzo, donde un agente (la red neuronal) interactúa con un entorno y aprende a maximizar una recompensa a largo plazo, ajustando sus acciones basadas en la retroalimentación del entorno. Este enfoque se usa comúnmente en juegos, robótica y optimización de procesos.

Arquitecturas de Redes Neuronales Comunes:

- **Redes Neuronales Perceptrón Multicapa (MLP):** Son redes *feedforward* tradicionales con una o más capas ocultas entre la entrada y la salida.
- **Redes Convolucionales (CNN):** Especializadas en procesamiento de imágenes y video, donde utilizan filtros convolucionales para identificar características locales (como bordes y texturas).
- **Redes Recurrentes (RNN):** Usadas para datos secuenciales, como texto o series temporales, porque tienen "memoria" de pasos anteriores.

1.1.3. ¿Cómo Aprenden las Redes Neuronales?

El aprendizaje se basa en la optimización de una función de pérdida que mide qué tan bien la red realiza la tarea deseada. Los algoritmos de optimización como el gradiente descendente ajustan los pesos de las redes neuronales para minimizar esta pérdida. A través de un proceso iterativo, la red se va ajustando y mejorando sus predicciones con cada ciclo de entrenamiento. En los próximos contenidos del libro sobre los aprendizajes y los autoaprendizajes, así como conceptos como función activatoria o regulaciones, se irán desarrollando de manera fácil y reconocible los distintos tipos de aprendizajes.

Conceptos clave:

- **Función de activación:** Ayuda a decidir si una neurona se activa o no, lo cual es fundamental para introducir no linealidades en el modelo (por ejemplo, ReLU, Sigmoide, Tanh).
- **Regularización:** Se utilizan técnicas como el *dropout* o la regularización L2 para evitar el sobreajuste (*overfitting*), asegurando que el modelo generalice bien en datos no vistos.

Las redes neuronales artificiales (RNA) son un tipo de modelo de inteligencia artificial inspirado en el funcionamiento del cerebro humano. Estas redes están compuestas por nodos o "neuronas" artificiales que trabajan en conjunto para analizar datos, identificar patrones y tomar decisiones o hacer predicciones. En el contexto de la IA, las redes neuronales son herramientas fundamentales, especialmente en el campo del aprendizaje profundo, y se aplican a tareas complejas como el reconocimiento de imágenes, el procesamiento del lenguaje natural y la detección de fraudes, entre otras.

Estructura de las Redes Neuronales:

Las redes neuronales están organizadas en capas, y cada capa contiene varias neuronas conectadas entre sí:

- **Capa de Entrada:** Es la primera capa y recibe los datos de entrada. Cada nodo en esta capa representa una característica del conjunto de datos (por ejemplo, píxeles en una imagen o palabras en un texto).

- **Capas Ocultas:** Son las capas internas que procesan los datos. Cuanto mayor sea el número de capas ocultas, más "profunda" es la red. Estas capas realizan cálculos complejos, combinando la información de las neuronas anteriores y permitiendo que el modelo aprenda características complejas de los datos.
- **Capa de Salida:** Es la última capa y produce el resultado final del modelo (por ejemplo, la clasificación de una imagen, una palabra o una predicción de valor).

Funcionamiento de las Redes Neuronales:

El funcionamiento de una red neuronal implica el paso de la información de una capa a otra, a través de conexiones ponderadas:

- **Conexiones Ponderadas:** Cada conexión entre neuronas tiene un peso que determina la influencia de una neurona sobre otra. Estos pesos se ajustan durante el entrenamiento para que la red aprenda a realizar predicciones precisas.
- **Función de Activación:** Después de que una neurona procesa los datos, aplica una función de activación (como la función Sigmoide, ReLU, o Tanh) que introduce no linealidad y permite que la red aprenda relaciones complejas entre las entradas.
- **Propagación hacia Adelante:** En este proceso, los datos se mueven desde la capa de entrada, a través de las capas ocultas, hasta llegar a la capa de salida. Cada capa transforma la información recibida de acuerdo con los pesos y las funciones de activación.
- **Retropropagación:** Durante el entrenamiento, la red ajusta sus pesos para minimizar el error en las predicciones. Este ajuste se hace mediante un proceso llamado retropropagación, donde se calculan los errores en la salida y se distribuyen hacia atrás a través de la red para actualizar los pesos de manera que el error total disminuya en el siguiente ciclo de entrenamiento.

Tipos de Redes Neuronales:

Existen varios tipos de redes neuronales, cada una diseñada para resolver problemas específicos:

- **Redes Neuronales Perceptrón:** Son las redes neuronales más simples, utilizadas para tareas de clasificación lineal básica.
- **Redes Neuronales Convolucionales (CNN):** Estas redes son populares en el reconocimiento de imágenes y videos, ya que están diseñadas para captar patrones espaciales en datos visuales. Utilizan capas de "convolución" que procesan subregiones de una imagen para extraer características como bordes, formas y texturas.
- **Redes Neuronales Recurrentes (RNN):** Estas redes están diseñadas para trabajar con datos secuenciales, como texto o series temporales, donde el orden de los datos es importante. Las RNN tienen conexiones "recurrentes" que les permiten conservar información de las etapas previas.
- **Redes Generativas Adversariales (GAN):** Son un tipo de red que consta de dos subredes: un generador y un discriminador. El generador crea datos falsos (por ejemplo, imágenes o audio), mientras que el discriminador intenta distinguir entre datos reales y falsos. Las GAN son populares en la generación de imágenes, la creación de arte digital y la simulación de datos.

Entrenamiento de las Redes Neuronales:

El proceso de entrenamiento implica ajustar los pesos de la red neuronal para que el modelo aprenda a realizar predicciones precisas. Este proceso generalmente sigue los siguientes pasos:

- **Inicialización:** Los pesos de la red se establecen en valores aleatorios o mediante un procedimiento específico.
- **Propagación hacia Adelante:** La red realiza una predicción inicial al pasar los datos de entrada a través de las capas.
- **Cálculo del Error:** Se mide el error de la predicción en relación con los datos reales (por ejemplo, utilizando una función de pérdida como el error cuadrático medio).
- **Ajuste de Pesos (Retropropagación):** Los pesos se ajustan mediante un algoritmo de optimización (por ejemplo, descenso de gradiente) para reducir el error en las predicciones.
- **Iteración:** El proceso se repite muchas veces (épocas) hasta que la red alcanza una precisión aceptable.

Aplicaciones de las Redes Neuronales:

Las redes neuronales han demostrado ser útiles en una amplia variedad de aplicaciones:

- **Reconocimiento de Imágenes y Visión por Computadora:** Clasificación de objetos, detección de rostros, diagnóstico médico mediante imágenes, etc.
- **Procesamiento del Lenguaje Natural (NLP):** Traducción automática, análisis de sentimientos, *chat-bots* y asistentes virtuales.
- **Automatización y Robótica:** Control de robots, vehículos autónomos, detección de obstáculos.
- **Finanzas:** Detección de fraudes, análisis de riesgos y predicción de precios de activos.
- **Creatividad Artificial:** Generación de música, arte y escritura mediante redes generativas.

Ventajas y Desafíos:

- **Ventajas:**
 - Capacidad para detectar patrones complejos y realizar predicciones precisas en problemas complicados.
 - Capacidad de autoajuste mediante el entrenamiento, mejorando con la exposición a más datos.
 - Versatilidad en diversas áreas de aplicación.
- **Desafíos:**
 - Alto costo computacional y necesidad de grandes volúmenes de datos.
 - Riesgo de "sobreajuste" si la red memoriza el entrenamiento en lugar de generalizar a nuevos datos.
 - Complejidad en la interpretación y comprensión de los resultados debido a la "caja negra" de muchos modelos profundos.

Las redes neuronales artificiales son modelos de IA inspirados en la estructura del cerebro humano. Gracias a su capacidad para aprender patrones y tomar decisiones, han revolucionado áreas como el procesamiento de imágenes, el análisis de lenguaje y la automatización de tareas. A pesar de sus grandes ventajas, requieren una cantidad significativa de datos y potencia computacional, y aún enfrentan desafíos en cuanto a la interpretabilidad y el control de sesgos. Todo ello ya nos permite avanzar hacia las principales áreas en las que podremos utilizar la IA.

Aplicaciones de la IA:

- **Diagnóstico médico:** Utilizada para analizar datos clínicos y ofrecer diagnósticos o recomendaciones terapéuticas.
- **Vehículos autónomos:** Los sistemas de IA permiten a los coches conducir sin la intervención humana.

- **Asistentes virtuales:** Como Siri o Alexa, que responden a preguntas y ayudan en tareas cotidianas utilizando el lenguaje natural.
- **Reconocimiento de imágenes:** Usada para detectar anomalías en imágenes médicas como radiografías o resonancias magnéticas.
- **Comercio electrónico y personalización.**
- **Ciberseguridad.**

Es cierto que con toda esa tecnología se puede fácilmente llegar a terrenos que quizás no estén acordes con la bioética y la deontología médica. Es por ello que los científicos deben poder controlar estas características para no caer en un pozo difícil de salir, y que puede poner en vilo a todos los profesionales y pacientes frente a esta nueva forma de trabajar.

Ética y desafíos:

- Preocupaciones sobre el sesgo en los algoritmos.
- Impacto en el empleo y la automatización.
- Privacidad de los datos.
- Regulaciones y responsabilidad en el uso de la IA.

Recordemos además que la IA no solo es una herramienta tecnológica, sino también un área de investigación que busca replicar y expandir los límites de la inteligencia al servicio de la población. Todo este enjambre de nuevos caminos y tecnologías se irá describiendo a medida que se avance en el libro. De momento, es necesario también conocer una serie de elementos que son la base de la IA.

Conceptos Clave (Síntesis):

- **Algoritmo:** Un conjunto de reglas o instrucciones que definen cómo una tarea debe llevarse a cabo. Son la base del funcionamiento de la IA, ya que definen cómo procesar los datos y extraer información.
- **Datos:** Son el "combustible" de la IA. Un sistema de IA necesita grandes cantidades de datos para aprender, ya que estos le permiten identificar patrones y mejorar sus predicciones. En la salud, por ejemplo, estos datos pueden ser imágenes médicas, historias clínicas, datos de sensores, etc.
- **Modelo:** Es el resultado de entrenar un algoritmo con datos. Una vez entrenado, el modelo puede hacer predicciones o tomar decisiones basadas en nueva información que no había visto antes. Por ejemplo, un modelo de diagnóstico podría identificar la presencia de una enfermedad en una imagen médica.
- **Entrenamiento y Aprendizaje:** El proceso de entrenamiento implica alimentar un algoritmo con datos para que aprenda a realizar una tarea específica. El sistema "aprende" ajustando sus parámetros hasta que es capaz de realizar la tarea con precisión. Existen diferentes tipos de aprendizaje:
 - **Supervisado:** Donde el modelo aprende con datos etiquetados (ej: imágenes de tumores marcadas como benignos o malignos).
 - **No Supervisado:** Donde el modelo explora patrones sin tener etiquetas previas.
 - **Por Refuerzo:** Donde el modelo aprende mediante una recompensa para conseguir un objetivo.
- **Inteligencia Artificial General (AGI) vs. IA Específica:**
 - **IA Específica (Narrow AI):** La mayor parte de la IA actual es específica, es decir, diseñada para realizar una tarea concreta (como reconocer caras o traducir idiomas).
 - **Inteligencia Artificial General (AGI):** Un tipo de IA aún en desarrollo que podría realizar cualquier tarea intelectual que una persona pueda hacer. Esta es la visión de una IA capaz de aprender y adaptarse a nuevas situaciones de manera similar a los humanos.

- **Aprendizaje Automático (Machine Learning):** Es una rama de la IA que permite a los sistemas aprender de los datos sin ser explícitamente programados. Los sistemas aprenden patrones y hacen predicciones o decisiones basadas en el análisis de grandes cantidades de datos.
 - **Aprendizaje Supervisado:** El sistema aprende de ejemplos etiquetados con respuestas correctas.
 - **Aprendizaje No Supervisado:** El sistema busca patrones ocultos en datos no etiquetados.
 - **Aprendizaje Por Refuerzo:** El sistema aprende a partir de acciones y recompensas, optimizando su comportamiento para obtener los mejores resultados posibles.
- **Aprendizaje Profundo (Deep Learning):** Subcampo del aprendizaje automático basado en redes neuronales artificiales. Estas redes, inspiradas en el cerebro humano, son capaces de tratar grandes volúmenes de datos y resolver problemas complejos como el reconocimiento de imágenes y la traducción automática.
- **Procesamiento del Lenguaje Natural (NLP):** Una rama de la IA que permite a los ordenadores entender, interpretar y generar lenguaje humano. Se utiliza en aplicaciones como los asistentes virtuales o la traducción automática.
- **Visión por Computador:** Permite a los ordenadores analizar e interpretar imágenes o vídeos, utilizando algoritmos para reconocer objetos, detectar anomalías o comprender escenas visuales. Es muy utilizada en diagnósticos médicos asistidos por IA.
- **Razonamiento y Toma de Decisiones:** La IA puede utilizar datos para razonar y tomar decisiones informadas, a menudo simulando el proceso de toma de decisiones humano, pero con más rapidez y precisión.

Aplicaciones en Obstetricia y Ginecología:

En el ámbito de la salud, la IA tiene un gran potencial para mejorar diagnósticos, personalizar tratamientos y optimizar los procesos médicos. En obstetricia y ginecología, puede ayudar, entre varios aspectos, a:

- Diagnóstico precoz de enfermedades ginecológicas mediante el análisis de imágenes.
- Monitorización del bienestar fetal, con sistemas que alertan sobre anomalías en tiempo real.
- Asistencia en la toma de decisiones médicas, sugiriendo posibles diagnósticos o tratamientos basados en datos de pacientes similares.

Estas aplicaciones ya están transformando la manera en que se proporciona la atención médica, haciéndola más precisa, eficiente y personalizada. En conjunto, la IA está transformando muchos campos, incluyendo la salud, con un potencial enorme para mejorar la calidad de vida y la eficiencia de las operaciones médicas.

Avances en Machine Learning:

- Los algoritmos comenzaron a aprender patrones directamente de los datos médicos.
- Surgieron técnicas como el aprendizaje supervisado y no supervisado, aplicadas a la predicción de enfermedades y el análisis de imágenes médicas.

Aplicaciones en imágenes médicas:

- La IA comenzó a analizar imágenes de rayos X, resonancias magnéticas y tomografías computarizadas para identificar anomalías como tumores o fracturas.
- Los sistemas de detección asistida por computadora (CAD) ganaron popularidad.

E-health y telemedicina:

- El aumento de dispositivos médicos conectados (como monitores portátiles) generó grandes cantidades de datos.
- La IA se utilizó para monitorear pacientes en tiempo real y alertar sobre problemas críticos.

1.2. Historia y Evolución de la Inteligencia Artificial en Medicina

Se presenta un recorrido fascinante que combina avances tecnológicos con necesidades médicas. Desde sus inicios, la IA ha buscado mejorar la toma de decisiones clínicas, optimizar procesos y ofrecer soluciones innovadoras para problemas complejos en salud.

Primera Etapa: Los Orígenes (Décadas de 1950-1970)

- **Nacimiento de la IA:** En la década de 1950, con el auge de la informática, surgieron los primeros conceptos de IA. Los investigadores comenzaron a explorar cómo las computadoras podían procesar datos médicos y ayudar en diagnósticos.
- **Primeros sistemas expertos:**
 - **MYCIN (1972):** Un sistema experto desarrollado en la Universidad de Stanford para diagnosticar infecciones bacterianas y recomendar tratamientos antibióticos. Aunque no se implementó clínicamente, fue un pionero en el uso de reglas para decisiones médicas.
 - **DENDRAL:** Diseñado para interpretar datos químicos, abrió la puerta a la aplicación de sistemas expertos en áreas biomédicas.

Segunda Etapa: Expansión y Desafíos (Décadas de 1980-1990)

- **Crecimiento de los sistemas expertos:** Los sistemas basados en reglas, como INTERNIST-I, se desarrollaron para diagnosticar enfermedades internas. Estos sistemas dependían de bases de conocimiento y reglas específicas para funcionar.
- **Limitaciones:**
 - Dificultades para manejar grandes volúmenes de datos.
 - Problemas de adaptabilidad y generalización.
 - Falta de infraestructura tecnológica en hospitales para integrar estas herramientas.
- **Emergencia de bases de datos médicas:** En esta época comenzaron a desarrollarse bases de datos clínicas y registros médicos electrónicos, esenciales para el desarrollo posterior de la IA.

Tercera Etapa: Aprendizaje Automático (Décadas de 2000-2010)

- **Avances en Machine Learning:**

- Los algoritmos comenzaron a aprender patrones directamente de los datos médicos.
- Surgieron técnicas como el aprendizaje supervisado y no supervisado, aplicadas a la predicción de enfermedades y el análisis de imágenes médicas.
- **Aplicaciones en imágenes médicas:**
 - La IA comenzó a analizar imágenes de rayos X, resonancias magnéticas y tomografías computarizadas para identificar anomalías como tumores o fracturas.
 - Los sistemas de detección asistida por computadora (CAD) ganaron popularidad.
- **E-health y telemedicina:**
 - El aumento de dispositivos médicos conectados (como monitores portátiles) generó grandes cantidades de datos.
 - La IA se utilizó para monitorear pacientes en tiempo real y alertar sobre problemas críticos.

Cuarta Etapa: Aprendizaje Profundo y Big Data (2010-Presente)

- **Revolución del Deep Learning:** Con el aumento de la potencia computacional y las redes neuronales profundas, la IA alcanzó un nivel sin precedentes de precisión en tareas médicas.
- **Aplicaciones destacadas:**
 - Diagnóstico automático de enfermedades a partir de imágenes (por ejemplo, detección de retinopatía diabética).
 - Predicción de resultados clínicos basados en datos históricos.
- **Big Data y medicina personalizada:**
 - La IA procesa datos genómicos, clínicos y de estilo de vida para diseñar tratamientos personalizados.
 - Empresas como IBM Watson Health integraron la IA en análisis genómicos y oncología.
- **Nuevas áreas de impacto:**
 - **Robótica quirúrgica:** Asistentes como el sistema Da Vinci utilizan IA para realizar cirugías mínimamente invasivas con mayor precisión.
 - **Procesamiento del Lenguaje Natural (PLN):** Herramientas para interpretar notas clínicas, extraer información de historias médicas y realizar diagnósticos.
 - **Desarrollo de fármacos:** La IA acelera la identificación de compuestos y predice su eficacia en ensayos clínicos.

Vale la pena pormenorizar con más detalle las fases que ha transcurrido la historia de la IA. La historia de la inteligencia artificial (IA) es fascinante y se remonta a miles de años, aunque el término y el enfoque científico moderno son mucho más recientes. Aquí se presenta un resumen cronológico de los hitos más importantes:

1.2.1. Orígenes Filosóficos y Evolución Temprana (Antigüedad - Siglo XIX)

- **Antigua Grecia:** Filósofos como Aristóteles reflexionaron sobre la lógica formal y la posibilidad de que las máquinas pudieran imitar el razonamiento humano.
- **Edad Media y Renacimiento:** Se construyeron autómatas mecánicos, como los de Leonardo da Vinci.
- **Siglo XVII - XIX:** Matemáticos como Leibniz y Boole desarrollaron sistemas lógicos que más tarde serían fundamentales para la computación.

Los inicios de la IA (1940-1950):

- **1943:** Warren McCulloch y Walter Pitts proponen un modelo matemático de la neurona artificial.
- **1950:** Alan Turing publica "Computing Machinery and Intelligence", donde plantea la pregunta "¿Pueden las máquinas pensar?" y propone el famoso Test de Turing.

Nacimiento oficial de la IA (1956):

- **1956:** Conferencia de Dartmouth. John McCarthy, Marvin Minsky, Claude Shannon y otros fundan el campo de la IA como disciplina. McCarthy acuña el término *inteligencia artificial*.

Primeros sistemas y expectativas (1956-1970s):

- Se desarrollan los primeros programas que resuelven problemas matemáticos y juegan ajedrez.
- **ELIZA (1966):** Simula una conversación tipo psicoterapia, anticipando los *chatbots*.
- Optimismo exagerado sobre lo que la IA lograría en pocos años.

Invierno de la IA (1970s - 1980s):

- Fracasan las expectativas iniciales: las computadoras no eran lo suficientemente potentes y los algoritmos eran limitados.
- Recortes de financiación e interés: se entra en el llamado invierno de la IA.

IA simbólica y sistemas expertos (1980s):

- Desarrollo de sistemas expertos como MYCIN (para diagnóstico médico).
- Lenguajes como LISP y PROLOG se usan ampliamente.
- Comienza el uso de IA en entornos industriales.

Renacimiento con el aprendizaje automático (1990s):

- Vuelve el interés gracias al aumento de poder computacional y bases de datos más grandes.
- Aparece el *machine learning* como enfoque dominante.
- **1997:** Deep Blue de IBM vence al campeón mundial de ajedrez Garry Kasparov.

Explosión de la IA moderna (2010s - Hoy):

- *Deep Learning* (aprendizaje profundo) revoluciona el campo con redes neuronales profundas.
- Avances en visión por computadora, procesamiento de lenguaje natural, reconocimiento de voz, etc.
- **2012:** Red neuronal de Google reconoce gatos en YouTube sin haber sido entrenada explícitamente para ello.

- **2016:** AlphaGo de DeepMind vence al campeón mundial de Go.
- Aparecen asistentes inteligentes como Siri, Alexa, y modelos como GPT (OpenAI) y BERT (Google).

IA generativa y el presente (2020s):

- Llegan modelos como ChatGPT, DALL·E, Stable Diffusion, capaces de generar texto, imágenes, música, código, etc.
- Se integran en herramientas cotidianas (Google, Microsoft Office, etc.).
- Debates éticos y sociales sobre el impacto de la IA en el empleo, la privacidad, la desinformación, y más.

Vamos a centrarnos en lo que ha pasado en la IA entre 2020 y 2025, una etapa de crecimiento explosivo y cambios importantes tanto tecnológicos como sociales:

2020-2025: La Era de la IA Generativa

- **2020-2021: Consolidación de modelos grandes:**
 - **GPT-3 (2020):** OpenAI lanza uno de los primeros modelos de lenguaje de gran escala que impresionan por su capacidad para generar texto coherente, responder preguntas, escribir código y más.
 - **IA en COVID-19:** Se usa para modelar datos, buscar tratamientos y gestionar recursos sanitarios.
 - Google lanza BERT y variantes para mejorar búsquedas y comprensión del lenguaje.
- **2022: Avances visuales y más modelos:**
 - DALL·E 2 (OpenAI) y Stable Diffusion permiten generar imágenes realistas a partir de descripciones de texto.
 - Se masifica el uso de IA multimodal (texto + imagen).
 - Comienza el debate serio sobre ética, *copyright* y control del contenido generado por IA.
- **2023: Popularización de la IA en la vida diaria:**
 - ChatGPT se vuelve masivo con millones de usuarios. Se integra en navegadores (como Bing), *apps* de productividad y educación.
 - Microsoft lanza Copilot para Office, integrando IA en Word, Excel, PowerPoint.
 - Apple y Google también aceleran sus integraciones de IA en iOS y Android.
 - Gran auge de *startups* de IA en medicina, educación, arte y videojuegos.
- **2024: Regulación, competencia y especialización:**
 - OpenAI lanza GPT-4, más potente, con capacidades multimodales (texto, imagen, audio).
 - Google responde con Gemini, un competidor directo, integrando IA en todos sus servicios.
 - La Unión Europea avanza en la *AI Act*, el primer marco regulador importante.
 - Se crean herramientas especializadas: IA médica, legal, financiera y más.
 - Se comienzan a entrenar modelos más eficientes y sostenibles por el alto coste energético de los modelos gigantes.
- **2025 (hasta ahora): Profesionalización y revolución productiva:**
 - La IA está cambiando profundamente la educación, el trabajo del conocimiento, la atención médica, el diseño, entre otros.

- Modelos personalizados (IA entrenadas con datos propios) se popularizan en empresas.
- Aumenta la preocupación por la desinformación generada por IA y los *deepfakes* realistas.
- Comienzan a emerger modelos *open-source* (como Mistral, LLaMA) como alternativas a los grandes modelos comerciales.

Tendencias clave del periodo 2020-2025:

- La IA generativa se vuelve parte de la vida cotidiana.
- Avances en modelos multimodales (que combinan texto, imagen, audio, video).
- Nuevas regulaciones globales en camino.
- Ética, privacidad y sesgo en el centro del debate.
- Transformación laboral: automatización de tareas cognitivas, creación de nuevos roles y especializaciones.

1.2.2. IA General (AGI - Inteligencia Artificial General) y Desarrollos Futuristas

El desarrollo de la inteligencia artificial (IA) avanza rápidamente y promete revolucionar múltiples aspectos de la sociedad en los próximos años. Aquí se detallan, de forma esquemática, algunos desarrollos futuristas que están en curso o que se proyectan para el futuro muy próximo:

1. IA General (AGI - Inteligencia Artificial General):

- **Visión:** Crear sistemas de IA con capacidades cognitivas humanas completas, que puedan razonar, aprender y adaptarse a una amplia variedad de tareas sin reentrenamiento.
- **Impacto:** Podrían desempeñar cualquier trabajo intelectual humano y resolver problemas complejos como el cambio climático o la exploración espacial.
- **Desafío:** Actualmente, la IA sigue siendo "estrecha" (especializada en tareas específicas). Lograr AGI requerirá avances significativos en neurociencia, computación y ética.

2. IA en Interfaces Cerebro-Máquina:

- **Descripción:** Desarrollar conexiones directas entre cerebros humanos y máquinas para amplificar las capacidades cognitivas o rehabilitar funciones perdidas.
- **Proyectos actuales:**
 - Neuralink de Elon Musk trabaja en implantes cerebrales para controlar dispositivos con la mente.
 - Interfaces no invasivas como dispositivos de electroencefalografía avanzada.
- **Futuro:** Podrían permitir habilidades como el aprendizaje instantáneo, la comunicación directa sin lenguaje y la integración de la IA en la mente humana.

3. Modelos Multimodales Avanzados:

- **Descripción:** Sistemas que combinan múltiples fuentes de información, como texto, imágenes, audio y video, para interactuar con el mundo de forma más integral.
- **Ejemplo actual:** GPT ya tiene capacidades multimodales.

- **Futuro:** Modelos que integren datos sensoriales complejos, como olores o sensaciones táctiles, para aplicaciones avanzadas en robótica, medicina y educación.

4. Robótica Impulsada por IA:

- **Visión:** Robots que aprendan como los humanos, adaptándose al entorno sin programación previa específica.
- **Áreas clave:**
 - **Nanobots médicos:** Robots microscópicos que navegan por el cuerpo humano para reparar tejidos, administrar medicamentos o eliminar tumores.
 - **Asistentes domésticos inteligentes:** Robots que entienden y anticipan las necesidades del hogar.
 - **Exploración espacial:** Robots con autonomía completa para colonizar otros planetas o explorar ambientes extremos.

5. Modelos Predictivos para la Salud:

- **Avances esperados:**
 - Sistemas de IA que analicen datos genéticos, estilo de vida y patrones de salud para predecir enfermedades años antes de que aparezcan los síntomas.
 - "Gemelos digitales" humanos: Modelos virtuales personalizados que simulen el cuerpo de una persona para predecir respuestas a tratamientos o procedimientos médicos.
- **Impacto:** Revolución en la medicina preventiva y personalizada.

6. IA en Sostenibilidad y Cambio Climático:

- **Proyectos futuros:**
 - Sistemas de IA que optimicen redes de energía renovable en tiempo real.
 - Algoritmos para diseñar nuevos materiales que absorban dióxido de carbono de la atmósfera.
 - Modelos climáticos ultra-precisos que predigan eventos extremos con semanas de antelación.

7. IA Emocional y Social:

- **Descripción:** Sistemas que no solo entiendan, sino que también simulen emociones humanas para interactuar de forma más natural.
- **Aplicaciones:**
 - Asistentes virtuales empáticos para salud mental y terapia.
 - IA en educación personalizada, adaptándose al ritmo y estado emocional del estudiante.
- **Riesgo:** Distinguir entre emociones simuladas y reales puede plantear problemas éticos.

8. IA Cuántica:

- **Definición:** La combinación de inteligencia artificial y computación cuántica para resolver problemas demasiado complejos para las computadoras clásicas.
- **Impacto potencial:**

- Resolver problemas de optimización en segundos, como logística global o simulaciones moleculares.
- Acelerar el descubrimiento de fármacos y el diseño de materiales revolucionarios.
- **Desafío:** La computación cuántica aún está en sus primeras etapas de desarrollo.

9. Creación y Arte Generativo Avanzados:

- **Futuro:** IA capaz de generar obras de arte, música, literatura y cine que rivalicen con la creatividad humana.
- **Proyectos emergentes:** Modelos de IA como DALL-E y MidJourney, evolucionados hacia creaciones completamente interactivas y contextuales.
- **Impacto:** Nuevas formas de expresión artística y democratización de herramientas creativas.

10. Economía y Sociedad Impulsadas por IA:

- **Automatización de industrias completas:** Desde la agricultura y manufactura hasta los servicios legales y financieros.
- **Ingreso básico universal:** La automatización masiva podría llevar a modelos económicos alternativos para garantizar el bienestar en una sociedad donde muchas tareas laborales sean reemplazadas.
- **Gobernanza basada en IA:** Sistemas que ayuden a los gobiernos a tomar decisiones más justas y basadas en datos.

11. Educación Personalizada Masiva:

- **Visión:** Plataformas de aprendizaje adaptativas que ajusten el contenido, la dificultad y el método de enseñanza a las necesidades individuales de cada estudiante.
- **Futuro:** Educación disponible para cualquier persona, en cualquier idioma, de forma completamente gratuita.

Retos y consideraciones éticas:

- **Regulación:** Evitar usos indebidos de la IA, como vigilancia masiva o manipulación social.
- **Control humano:** Asegurar que la IA esté alineada con los valores y objetivos humanos.
- **Inclusión:** Garantizar que los beneficios de la IA lleguen a todos, evitando desigualdades.

La IA tiene un futuro prometedor, pero es crucial equilibrar el progreso tecnológico con una visión ética y sostenible.

1.2.3. Impacto de la IA en el Medio Socioeconómico

La inteligencia artificial (IA) está transformando profundamente el medio socioeconómico, con efectos que van desde la productividad empresarial hasta la estructura del empleo y la desigualdad social. A continuación, se presenta un desglose claro y actualizado de sus principales impactos:

Transformación del Empleo:

- **Complemento vs. Sustitución:** La IA puede mejorar tareas humanas (complemento) o reemplazarlas (sustitución). En muchos sectores, ambas fuerzas coexisten.
- **Empleos más afectados:** En economías avanzadas, hasta el 60% de los empleos podrían verse afectados. Los trabajos rutinarios y administrativos son los más vulnerables.
- **Oportunidades para jóvenes:** La IA está beneficiando especialmente a la población joven, ayudándoles a integrarse en el mercado laboral.

Productividad y Crecimiento Económico:

- **Incremento del PIB:** Se estima que la IA podría aportar hasta 19.9 billones de dólares al PIB global para 2030, representando un 3.5% del total mundial.
- **Optimización empresarial:** Las empresas están reduciendo costos y aumentando ingresos gracias a la automatización y la IA generativa.

Desigualdad y Polarización Social:

- **Desigualdad salarial:** Aunque la productividad mejora, los salarios aún no reflejan plenamente el impacto de la IA.
- **Polarización de ingresos:** Los trabajadores que pueden aprovechar la IA tienden a mejorar sus ingresos, mientras que otros quedan rezagados.

Regulación y Ética:

- **Marco legal europeo:** La UE ha aprobado un reglamento pionero que regula la IA según niveles de riesgo, buscando proteger derechos ciudadanos y fomentar la innovación.
- **Desafíos éticos:** La IA plantea dilemas sobre privacidad, sesgos algorítmicos y transparencia en la toma de decisiones.

Vamos a explorar cómo la inteligencia artificial está impactando tres sectores clave en España: agricultura, turismo y educación.

Agricultura: Hacia un Campo Inteligente:

- **Agricultura de precisión:** Proyectos como AgrarIA están revolucionando el campo español mediante sensores, imágenes satelitales y modelos predictivos que permiten ajustar el riego, detectar plagas y optimizar la fertilización.
- **Sostenibilidad:** Se estima que el uso de IA podría reducir las emisiones del sector agrícola en un 30% para 2030, alineándose con el Pacto Verde Europeo.
- **Revitalización rural:** Comunidades como Castilla y León y Extremadura están usando IA para frenar la despoblación rural, mejorar la rentabilidad y atraer a jóvenes al sector.

Turismo: Personalización y Eficiencia:

- **Mejorando la experiencia del turista:** *Chatbots*, asistentes virtuales y sistemas de recomendación están personalizando viajes y estancias.
- **Optimizando operaciones:** Hoteles y agencias usan IA para prever demanda, ajustar precios dinámicamente y gestionar recursos.
- **Impulsando el turismo rural:** En zonas como Galicia o La Rioja, la IA ayuda a promocionar destinos menos conocidos mediante análisis de datos y marketing inteligente.

Educación: Aprendizaje Adaptativo:

- **Plataformas inteligentes:** Herramientas educativas basadas en IA adaptan el contenido al ritmo y estilo de aprendizaje de cada estudiante.
- **Inclusión digital:** En regiones con menor acceso a recursos, la IA puede facilitar la enseñanza remota y personalizada.
- **Formación en IA:** Universidades españolas están incorporando programas para capacitar a futuros profesionales en el uso ético y técnico de la IA.

1.2.4. Introducción a la Inteligencia Artificial en Obstetricia y Ginecología

La Transformación Digital en la Medicina Reproductiva:

La evolución tecnológica ha impactado significativamente el campo de la salud, y la Inteligencia Artificial (IA) ha emergido como una herramienta clave en el avance de la obstetricia y ginecología. Esta disciplina médica, que abarca la salud reproductiva femenina, el embarazo, el parto y el posparto, se beneficia de la IA para mejorar la detección temprana de enfermedades, optimizar tratamientos y personalizar la atención a las pacientes.

Definición y Principios Básicos de la IA:

La Inteligencia Artificial es un campo de la informática que permite a las máquinas aprender de datos, reconocer patrones y tomar decisiones sin intervención humana directa. Dentro de la IA, varias técnicas son particularmente útiles en el campo médico:

- **Aprendizaje automático (Machine Learning, ML):** Modelos que analizan grandes volúmenes de datos y aprenden de ellos para hacer predicciones.
- **Redes neuronales artificiales:** Sistemas inspirados en la estructura del cerebro que identifican patrones complejos en datos clínicos.
- **Procesamiento de lenguaje natural (NLP):** Permite la interpretación de registros médicos electrónicos y documentos clínicos.
- **Visión por computadora:** Aplicaciones en el análisis de ecografías y otras imágenes médicas.

Aplicaciones de la IA en Obstetricia y Ginecología:

Las aplicaciones de la IA en esta especialidad han ido en aumento, permitiendo mejorar la calidad de la atención y optimizar el tiempo de los profesionales médicos.

- **Diagnóstico y Predicción de Enfermedades:**
 - **Cáncer ginecológico:** Algoritmos de aprendizaje profundo pueden analizar imágenes histopatológicas para detectar células cancerígenas en etapas tempranas.
 - **Endometriosis y síndrome de ovario poliquístico (SOP):** Modelos de IA pueden analizar datos clínicos y de laboratorio para detectar patrones sugestivos de estas enfermedades.
 - **Predicción de parto prematuro:** La IA puede evaluar factores de riesgo a partir de registros electrónicos y predictores clínicos.

- **Apoyo en la Reproducción Asistida:**

- **Evaluación de la calidad embrionaria:** Algoritmos de visión por computadora analizan imágenes de embriones para mejorar la selección en tratamientos de fertilización *in vitro* (FIV).
- **Optimización de la respuesta ovárica:** Modelos predictivos ayudan a personalizar los protocolos de estimulación hormonal en pacientes con infertilidad.

- **Análisis de Imágenes Médicas:**

- **Ecografías obstétricas:** La IA puede detectar anomalías fetales y evaluar el crecimiento del bebé con mayor precisión.
- **Colposcopia asistida por IA:** Herramientas de IA analizan imágenes del cuello uterino para detectar lesiones precancerosas con alta sensibilidad.

- **Medicina Personalizada y Monitorización Remota:**

- **Predicción de complicaciones en el embarazo:** Análisis de historias clínicas y biomarcadores permite identificar mujeres en riesgo de preeclampsia, diabetes gestacional o hipertensión.
- **Wearables para seguimiento materno-fetal:** Dispositivos inteligentes con IA monitorean signos vitales de la madre y el feto en tiempo real.

Beneficios y Desafíos de la IA en la Salud Reproductiva:

Si bien la IA aporta numerosas ventajas en la obstetricia y ginecología, también enfrenta ciertos retos.

- **Beneficios:**

- Mayor precisión diagnóstica: Reducción de errores humanos y diagnósticos más rápidos y precisos.
- Optimización del tiempo médico: Reducción de carga administrativa, permitiendo más tiempo para la atención a pacientes.
- Atención personalizada: Análisis de grandes volúmenes de datos para crear tratamientos adaptados a cada paciente.

- **Desafíos:**

- Privacidad y seguridad de datos: Se deben garantizar altos estándares de protección de información médica.
- Ética en el uso de IA: Evitar sesgos en los modelos de IA y garantizar decisiones justas.
- Aceptación por los profesionales de la salud: Es necesario capacitar a los médicos para integrar estas tecnologías en su práctica clínica.

Futuro de la IA en Obstetricia y Ginecología:

El futuro de la IA en esta especialidad promete avances significativos en:

- Desarrollo de algoritmos más precisos y explicables.
- Integración de IA en hospitales y centros de salud para asistencia en tiempo real.
- Mayor colaboración entre expertos en salud y tecnología para la mejora continua de herramientas basadas en IA.
- Uso de *Big Data* y modelado predictivo para personalizar aún más la atención gineco-obstétrica.

La IA está revolucionando la obstetricia y ginecología al proporcionar herramientas más precisas, eficientes y personalizadas para la atención de las pacientes. Sin embargo, su implementación debe ir acompañada de consideraciones éticas, regulaciones adecuadas y capacitación médica para garantizar su uso seguro y efectivo. La combinación de tecnología e inteligencia clínica promete una medicina reproductiva más avanzada y equitativa en los próximos años.

Retos y Perspectivas Futuras:

- **Ética y regulación:**

- Es esencial garantizar la privacidad de los datos y evitar sesgos en los algoritmos.
- La validación clínica rigurosa y la aprobación regulatoria son desafíos clave.

- **Integración en la práctica clínica:**

- A pesar de los avances, la adopción de la IA en hospitales y clínicas sigue siendo lenta debido a la resistencia al cambio y la falta de infraestructura.

- **Perspectivas futuras:**

- Mayor personalización de los tratamientos.
- Desarrollo de sistemas capaces de predecir enfermedades antes de que se manifiesten.
- IA colaborativa que actúe como complemento para los médicos, mejorando la precisión y eficiencia en el cuidado de la salud.
- IA generativa: Capaz de diseñar nuevas estructuras moleculares para el desarrollo de fármacos.
- Cirugía asistida por robots: Mejora la precisión y reduce el tiempo de recuperación de los pacientes.
- Modelos multimodales: Combinan datos de diferentes fuentes, como imágenes, texto y datos genéticos, para ofrecer diagnósticos más completos.
- Medicina preventiva: Sistemas de IA para monitorizar la salud de las personas y anticipar brotes epidémicos.

En resumen, la IA en medicina ha evolucionado desde sistemas básicos basados en reglas hasta complejas redes neuronales capaces de manejar datos masivos. Su impacto sigue creciendo, transformando el diagnóstico, tratamiento y prevención de enfermedades. La historia de la IA en medicina es un ejemplo claro de cómo la tecnología puede transformar un campo tan fundamental como la salud. Desde sistemas expertos hasta el aprendizaje profundo y las aplicaciones futuras, la IA tiene el potencial de mejorar la calidad de vida de millones de personas y seguir redefiniendo el papel de los profesionales médicos en el siglo XXI. La realidad es que, cuando nos centramos en el futuro que nos depara en el ámbito de la medicina, las posibilidades que se abren son de un gran valor en todos los campos. Solo a título de ejemplo, a continuación, se señalan los más avanzados.

1.2.5. Prospección de Futuro sobre la Asistencia Obstétrica y Ginecológica

1. Diagnóstico Temprano y Prevención:

La IA revolucionará el diagnóstico temprano y la prevención de enfermedades ginecológicas y complicaciones obstétricas. Algunos ejemplos incluyen:

- **Detección temprana de cánceres ginecológicos:** Algoritmos capaces de analizar imágenes histológicas y de resonancia magnética para identificar cáncer de ovario, cuello uterino y endometrio en etapas tempranas.
- **Predicción de complicaciones obstétricas:** Modelos predictivos basados en datos clínicos y de imágenes para anticipar preeclampsia, parto prematuro y diabetes gestacional.
- **Evaluación automatizada del bienestar fetal:** Sistemas que analizan patrones en la monitorización cardiotocográfica para detectar signos de sufrimiento fetal.

2. Personalización del Tratamiento:

La integración de la IA permitirá tratamientos más personalizados:

- **Terapias hormonales personalizadas:** Análisis de datos genéticos y hormonales para ajustar tratamientos específicos.
- **Planificación del parto:** Algoritmos que evalúan factores materno-fetales para recomendar el tipo de parto más seguro.
- **Recomendaciones terapéuticas:** Integración de la historia clínica con bases de datos de tratamientos para guiar las decisiones clínicas.

3. Automatización de Procesos y Tareas Administrativas:

- **Generación de informes automáticos:** Herramientas que analizan ecografías y generan informes detallados para su revisión por el especialista.
- **Sistemas de triage inteligente:** Priorización automatizada de consultas según la gravedad y el historial del paciente.
- **Documentación clínica asistida:** IA que registra y documenta automáticamente las consultas y procedimientos.

4. Cirugías Asistidas por IA:

La incorporación de la IA en cirugías ginecológicas mejorará la precisión y reducirá los riesgos:

- **Robótica quirúrgica asistida:** IA que ayuda a los cirujanos a identificar estructuras críticas en tiempo real.
- **Planificación quirúrgica inteligente:** Sistemas que simulan procedimientos quirúrgicos basados en imágenes preoperatorias.

5. Monitoreo Continuo del Embarazo:

- **Dispositivos portátiles inteligentes:** Sensores que recopilan datos del embarazo en tiempo real, como la frecuencia cardíaca fetal y contracciones uterinas, analizados por IA para identificar riesgos.
- **Aplicaciones móviles personalizadas:** Plataformas que ofrecen recomendaciones basadas en el análisis de datos de salud de la madre y el bebé.

6. Telemedicina y Diagnóstico Remoto:

- **Consultas virtuales asistidas por IA:** Análisis automático de datos de las pacientes para asistir a los médicos en las consultas remotas.
- **Diagnóstico remoto de ecografías:** Plataformas que permiten a especialistas revisar imágenes de forma remota, con asistencia de algoritmos de IA.

7. Educación y Capacitación de Profesionales:

- **Simuladores de entrenamiento asistidos por IA:** Plataformas de realidad aumentada y virtual que utilizan IA para entrenar a ginecólogos y obstetras en procedimientos complejos.
- **Asistencia durante las consultas:** Herramientas que proporcionan recomendaciones basadas en evidencia durante la consulta clínica.

8. Mejora de la Investigación Clínica:

- **Análisis de Big Data:** IA que analiza grandes conjuntos de datos para identificar patrones y tendencias en la salud reproductiva.
- **Identificación de biomarcadores:** Algoritmos que aceleran el descubrimiento de biomarcadores para enfermedades ginecológicas y complicaciones del embarazo.

Así pues, el futuro de la asistencia obstétrica y ginecológica estará marcado por la integración de la IA en cada etapa del cuidado, desde el diagnóstico hasta el tratamiento y el monitoreo. Esto permitirá una atención más personalizada, eficiente y segura, mejorando los resultados clínicos para las pacientes y facilitando la labor de los profesionales de la salud.

Con el fin de pormenorizar sobre aspectos clínicos de gran interés, se presentan toda una serie de patologías y procedimientos sobre los que ya se está avanzando de manera muy veloz. Gracias a su capacidad para analizar grandes cantidades de datos, identificar patrones complejos y ofrecer predicciones precisas, la IA ha permitido avances significativos en diversas áreas relacionadas con el cuidado específico de las mujeres. A continuación, se destacan algunas aplicaciones generales:

1. Detección y Diagnóstico Temprano de Enfermedades:

- **Cáncer de mama:** La IA, mediante el análisis de imágenes de mamografías, puede detectar anomalías con alta precisión y a menudo en etapas tempranas, mejorando significativamente las tasas de diagnóstico temprano. Herramientas como los sistemas de detección asistida por computadora (CAD) ayudan a los radiólogos a identificar microcalcificaciones y masas sospechosas.
- **Cáncer cervical:** Algoritmos de IA analizan imágenes de pruebas de Papanicolaou y detección de VPH (virus del papiloma humano) para identificar células precancerosas y cáncer cervical.
- **Endometriosis:** Mediante la integración de datos clínicos, la IA puede ayudar a identificar patrones en síntomas y diagnósticos, reduciendo los largos períodos de diagnóstico comúnmente asociados con esta enfermedad.

2. Salud Reproductiva y Fertilidad:

- **Predicción del ciclo menstrual y fertilidad:** Aplicaciones como Flo o Clue usan IA para predecir ciclos menstruales y ventanas de fertilidad, ayudando a las mujeres en la planificación familiar o identificación de irregularidades.
- **Apoyo en tratamientos de fertilidad:** La IA analiza datos en procedimientos de fertilización *in vitro* (FIV), como la selección de embriones, prediciendo cuáles tienen mayores probabilidades de implantar con éxito.
- **Seguimiento del embarazo:** Plataformas con IA monitorean la salud de la madre y el feto mediante datos de dispositivos portátiles, alertando sobre posibles complicaciones como preeclampsia o diabetes gestacional.

3. Monitoreo de la Salud Materna y Neonatal:

- **Prevención de complicaciones en el embarazo:** Algoritmos de aprendizaje automático predicen riesgos de complicaciones como parto prematuro, hipertensión gestacional y hemorragias posparto.
- **Monitoreo remoto:** Dispositivos conectados con IA permiten a las mujeres embarazadas realizar un seguimiento de signos vitales y datos clave, transmitiéndolos a los médicos para una atención personalizada.

4. Atención a la Salud Mental de la Mujer:

- **Depresión posparto:** La IA ayuda a identificar mujeres en riesgo mediante el análisis de respuestas a cuestionarios, interacciones en plataformas digitales y cambios en el comportamiento.
- **Apoyo emocional:** *Chatbots* de salud mental basados en IA ofrecen recursos y apoyo emocional en tiempo real, diseñados específicamente para abordar los desafíos únicos que enfrentan las mujeres, como el estrés relacionado con el embarazo o la menopausia.

5. Tratamiento y Manejo de Enfermedades Crónicas:

- **Osteoporosis:** Sistemas de IA analizan densitometrías óseas y otros datos para predecir el riesgo de fracturas, facilitando intervenciones tempranas.
- **Diabetes y enfermedades cardiovasculares:** La IA personaliza planes de tratamiento y monitoreo, considerando factores específicos de género que afectan la progresión y tratamiento de estas enfermedades en mujeres.

6. Personalización de Tratamientos y Medicina de Precisión:

La IA integra datos genómicos, hormonales y de estilo de vida para diseñar terapias personalizadas, especialmente en áreas como:

- Tratamientos hormonales para menopausia.
- Medicamentos para enfermedades relacionadas con el sistema reproductivo.
- Terapias específicas para mujeres con cánceres hormonales (mama, ovario, endometrio).

7. Prevención y Educación:

- **Educación personalizada:** Herramientas basadas en IA ofrecen información personalizada sobre salud menstrual, reproductiva y general, ayudando a las mujeres a tomar decisiones informadas.
- **Predicción de riesgos a largo plazo:** Modelos predictivos identifican riesgos futuros basados en factores como antecedentes familiares, hábitos y datos médicos.

8. Innovaciones Tecnológicas en Dispositivos Portátiles (*Wearables*):

- **Monitoreo continuo:** Dispositivos como relojes inteligentes y rastreadores de actividad monitorean parámetros como frecuencia cardíaca, niveles de estrés y sueño.
- **Salud menstrual y hormonal:** *Wearables* especializados rastrean los ciclos hormonales y ofrecen información sobre fertilidad o síntomas premenstruales.

9. Tratamiento de Trastornos Específicos:

- **Síndrome de ovario poliquístico (SOP):** La IA analiza síntomas, datos hormonales y resultados de imágenes para diagnosticar y monitorear el SOP, facilitando el manejo personalizado.
- **Menopausia:** Aplicaciones digitales personalizadas ayudan a las mujeres a manejar síntomas de la menopausia con recomendaciones basadas en datos.

En resumen, la IA está transformando la salud de la mujer al ofrecer diagnósticos más precisos, tratamientos personalizados y herramientas para el monitoreo continuo. Su impacto sigue expandiéndose, prometiendo una atención más inclusiva.

1.2.6. Técnicas de Inteligencia Artificial de Aparición Inmediata en Medicina

La IA en salud está evolucionando rápidamente con técnicas innovadoras que están a punto de implementarse o ya están en fase temprana de adopción. Estas tecnologías prometen transformar la práctica médica en los próximos 1-3 años.

1. IA Multimodal para Diagnóstico y Predicción:

- **Uso de múltiples tipos de datos clínicos en un solo modelo de IA:**
 - **Cómo funciona:** Los nuevos modelos de IA pueden combinar imágenes médicas, análisis de laboratorio, datos genéticos, notas clínicas y registros médicos electrónicos (EHRs) en un único sistema de predicción.
 - **Aplicación en salud:**
 - Diagnóstico más preciso de enfermedades ginecológicas, oncológicas y cardiovasculares.
 - Detección de patrones en múltiples fuentes de datos para mejorar la medicina personalizada.
- **Ejemplo:** Google Med-PaLM 2 y DeepMind Med-Gemini, que combinan imágenes médicas con texto clínico para diagnósticos más precisos.
- **Impacto inmediato:** Reducción de diagnósticos erróneos y mejora en la toma de decisiones clínicas.

2. Modelos Generativos en Medicina

Chatbots y Asistentes Médicos con IA Generativa

- **Funcionamiento:** Modelos como GPT, Gemini y Mistral AI pueden interpretar síntomas, redactar informes clínicos y sugerir diagnósticos basados en evidencia médica.
- **Aplicación en salud:**
 - Automatización de notas médicas: Conversión de diálogos médico-paciente en registros clínicos estructurados.
 - Asistentes de diagnóstico y tratamiento: IA integrada en telemedicina y consulta médica para apoyo en la toma de decisiones.
 - Personalización de planes de tratamiento: La IA ajusta terapias según el perfil del paciente.

- **Impacto inmediato:** Menos carga administrativa para profesionales de la medicina y mayor tiempo para la atención al paciente.

3. IA para Medicina de Precisión y Farmacogenómica

Desarrollo de Terapias Personalizadas con IA

- **Funcionamiento:** Algoritmos de *machine learning* analizan datos genómicos, clínicos y de estilo de vida para optimizar tratamientos.
- **Aplicación en salud:**
 - Selección de tratamientos específicos según el perfil genético.
 - Optimización de terapias hormonales en ginecología y menopausia.
 - Desarrollo acelerado de nuevos medicamentos con IA (Ejemplo: Insilico Medicine).
- **Impacto inmediato:** Mayor eficacia en tratamientos y reducción de efectos adversos.

4. Visión Computacional Avanzada para Diagnóstico por Imágenes

IA en Radiología, Ultrasonidos y Endoscopias

- **Funcionamiento:** Modelos de *deep learning* mejoran la interpretación de imágenes médicas en tiempo real.
- **Aplicación en salud:**
 - Mamografías y ultrasonidos con detección temprana de anomalías.
 - Endoscopias asistidas por IA para detectar cáncer gástrico y colorrectal.
 - Diagnóstico automatizado en dermatología y oftalmología.
- **Ejemplo:** Lunit AI y Qure.ai, que ya están en implementación clínica.
- **Impacto inmediato:** Diagnósticos más rápidos y precisos con menor margen de error.

5. IA en Cirugía Robótica y Asistida

Optimización de Procedimientos Quirúrgicos con IA

- **Funcionamiento:** Algoritmos de IA mejoran la precisión de robots quirúrgicos y guían procedimientos con visión aumentada.
- **Aplicación en salud:**
 - Cirugías laparoscópicas y ginecológicas más seguras con IA predictiva.
 - Modelado 3D en tiempo real para planificación quirúrgica personalizada.
- **Ejemplo:** Robots como Da Vinci y Hugo™ RAS ya están integrando IA para mejorar la precisión quirúrgica.
- **Impacto inmediato:** Menos complicaciones postoperatorias y recuperación más rápida.

6. Inteligencia Artificial Explicable (XAI) en Medicina

IA más Transparente para la Toma de Decisiones Clínicas

- **Funcionamiento:** Algoritmos de IA diseñados para explicar su razonamiento, aumentando la confianza de los profesionales de la medicina en sus predicciones.
- **Aplicación en salud:**
 - Interpretación clara de predicciones de cáncer y enfermedades crónicas.
 - IA en cardiología y neurología con justificación de diagnósticos.
 - Regulación más estricta en FDA y EMA, que exigen transparencia en modelos de IA.
- **Impacto inmediato:** Mayor aceptación de la IA en hospitales y clínicas al hacerla más comprensible para los médicos.

7. IA en *Wearables* y Salud Digital

Monitoreo Continuo con Dispositivos Inteligentes

- **Funcionamiento:** Sensores de IA en relojes inteligentes, parches y ropa inteligente recopilan datos biométricos en tiempo real.
- **Aplicación en salud:**
 - Monitoreo del embarazo para detección temprana de complicaciones.
 - Control de enfermedades metabólicas y cardiovasculares con alertas predictivas.
 - Integración con expedientes clínicos electrónicos (EHRs) para mejorar la prevención de enfermedades.
- **Ejemplo:** Oura Ring, Apple Watch y Whoop están integrando IA para salud femenina y monitoreo cardíaco avanzado.
- **Impacto inmediato:** Detección temprana de enfermedades sin necesidad de visitas constantes al médico.

1.2.7. IA de Aparición Inmediata en Medicina

En los próximos 1-3 años, la IA en salud pasará de la fase experimental a la práctica clínica con tecnologías que incluyen:

- Diagnóstico multimodal con IA, combinando datos clínicos e imágenes.
- Asistentes médicos generativos que automatizan notas y apoyan decisiones clínicas.
- Terapias personalizadas basadas en IA y genética.
- Cirugía asistida por IA con robots inteligentes.
- *Wearables* con IA que detectan enfermedades en tiempo real.

1.3. Futuro de la Inteligencia Artificial en la Salud de la Mujer

El impacto de la inteligencia artificial (IA) en la salud de la mujer continuará expandiéndose, impulsando avances en diagnóstico, tratamiento, prevención y medicina personalizada. A continuación, se presentan las principales tendencias y desarrollos esperados en los próximos años:

1. Medicina Personalizada y Genómica

Predicción de Enfermedades con IA y Genética

- La IA analizará miles de datos genéticos y clínicos para predecir el riesgo de cáncer de mama, cáncer de ovario y otras enfermedades ginecológicas.
- Edición genética con IA: CRISPR y modelos de IA ayudarán a diseñar tratamientos personalizados para enfermedades hereditarias en mujeres.
- **Ejemplo futuro:** Una prueba basada en IA podrá indicar qué tratamiento hormonal o terapéutico es más efectivo según la genética y el historial clínico de cada mujer.

2. Avances en Diagnóstico Temprano y Preciso

IA + Imágenes Médicas

- Los algoritmos de IA serán capaces de detectar anomalías en mamografías, ecografías y resonancias magnéticas con mayor precisión que los radiólogos.
- Diagnóstico temprano de cáncer de mama, endometriosis, síndrome de ovario poliquístico (SOP) y enfermedades autoinmunes gracias a redes neuronales avanzadas.
- **Diagnóstico con *smartphones***
 - La IA en dispositivos móviles permitirá detectar infecciones vaginales, cáncer cervicouterino y otros problemas ginecológicos con imágenes tomadas desde el celular.
- **Ejemplo futuro:** Un *software* de IA podrá analizar un ultrasonido fetal en tiempo real y alertar a los profesionales de la medicina sobre posibles anomalías.

3. Reproducción Asistida y Salud Materno-Fetal

IA en Fertilidad y Embarazo

- Modelos predictivos mejorarán las tasas de éxito en la fertilización *in vitro* (FIV) al seleccionar los embriones con mayor probabilidad de implantación.
- Seguimiento inteligente del embarazo con *wearables* y sensores de IA que alertarán sobre posibles complicaciones en tiempo real.
- **Ejemplo futuro:** Un parche con IA monitoreará signos vitales maternos y fetales, enviando alertas inmediatas si detecta señales de preeclampsia o parto prematuro.

4. IA y Salud Mental en la Mujer

Intervenciones Personalizadas para Depresión y Ansiedad

- Chatbots y asistentes de IA avanzados detectarán la depresión posparto, la ansiedad y los síntomas asociados a la menopausia con análisis de voz y patrones de conversación.
- Plataformas de terapia con IA ofrecerán soporte emocional basado en la neurociencia, reduciendo la brecha en el acceso a la salud mental.
- **Ejemplo futuro:** Un *smartwatch* con IA podrá analizar patrones de sueño y voz para predecir episodios depresivos y recomendar intervenciones personalizadas.

5. Optimización de la Telemedicina y Atención Remota

Asistentes Virtuales para Salud Ginecológica

- Los chatbots médicos avanzados darán orientación confiable en salud sexual, anticoncepción y menopausia, eliminando barreras de acceso.
- Diagnósticos remotos con IA + biosensores permitirán a las mujeres realizar autoevaluaciones de infecciones urinarias, enfermedades de transmisión sexual (ETS) y otras condiciones.
- **Ejemplo futuro:** Un dispositivo portátil podrá realizar una prueba de ITS en casa y enviar los resultados a una IA médica que recomendará tratamientos.

6. Eliminación de Sesgos de Género en la Medicina

IA con Enfoque de Género

- Desarrollo de modelos de IA diseñados específicamente para enfermedades que afectan más a las mujeres, como enfermedades autoinmunes, osteoporosis y migrañas.
- Corrección de sesgos en la investigación médica, ya que muchas enfermedades cardiovasculares en mujeres han sido subdiagnosticadas debido a la falta de datos específicos.
- **Ejemplo futuro:** Algoritmos de IA podrán ajustar tratamientos cardiovasculares teniendo en cuenta diferencias biológicas entre mujeres y hombres.

7. IA y Avances en Tratamientos Médicos

Desarrollo de Fármacos con IA

- Modelos de IA acelerarán la creación de nuevos medicamentos para enfermedades ginecológicas y hormonales.
- Optimización de terapias hormonales según el perfil genético y metabólico de cada mujer.
- **Ejemplo futuro:** Una IA podrá predecir cómo responderá cada paciente a un tratamiento para la menopausia, reduciendo efectos secundarios.

8. Monitoreo Continuo con *Wearables* de IA

Seguimiento en Tiempo Real de la Salud Femenina

- Sensores de IA integrados en relojes inteligentes, parches y ropa inteligente permitirán el monitoreo continuo de la salud menstrual, embarazo y menopausia.
- Identificación de anomalías en los ciclos menstruales que podrían indicar problemas de salud como SOP o deficiencias hormonales.
- **Ejemplo futuro:** Un anillo con IA detectará cambios en temperatura y ritmo cardíaco para predecir el mejor momento para la concepción.

IA y el Futuro de la Salud Femenina

- La IA revolucionará la atención médica de la mujer con diagnósticos más precisos, tratamientos personalizados y monitoreo continuo.
- El acceso a la salud mejorará gracias a la telemedicina, chatbots y dispositivos inteligentes.
- La medicina será más equitativa, eliminando sesgos de género en la investigación y el tratamiento de enfermedades.

El impacto futuro de la IA en la asistencia obstétrica y ginecológica proporcionará:

1. Diagnóstico Temprano y Prevención

La IA revolucionará el diagnóstico temprano y la prevención de enfermedades ginecológicas y complicaciones obstétricas. Algunos ejemplos incluyen:

- **Detección temprana de cánceres ginecológicos:** Algoritmos capaces de analizar imágenes histológicas y de resonancia magnética para identificar cáncer de ovario, cuello uterino y endometrio en etapas tempranas.
- **Predicción de complicaciones obstétricas:** Modelos predictivos basados en datos clínicos y de imágenes para anticipar preeclampsia, parto prematuro y diabetes gestacional.
- **Evaluación automatizada del bienestar fetal:** Sistemas que analizan patrones en la monitorización cardiotocográfica para detectar signos de sufrimiento fetal.

2. Personalización del Tratamiento

La integración de la IA permitirá tratamientos más personalizados:

- **Terapias hormonales personalizadas:** Análisis de datos genéticos y hormonales para ajustar tratamientos específicos.
- **Planificación del parto:** Algoritmos que evalúan factores materno-fetales para recomendar el tipo de parto más seguro.
- **Recomendaciones terapéuticas:** Integración de la historia clínica con bases de datos de tratamientos para guiar las decisiones clínicas.

3. Automatización de Procesos y Tareas Administrativas

- **Generación de informes automáticos:** Herramientas que analizan ecografías y generan informes detallados para su revisión por el especialista.
- **Sistemas de triage inteligente:** Priorización automatizada de consultas según la gravedad y el historial del paciente.
- **Documentación clínica asistida:** IA que registra y documenta automáticamente las consultas y procedimientos.

4. Cirugías Asistidas por IA

La incorporación de la IA en cirugías ginecológicas mejorará la precisión y reducirá los riesgos:

- **Robótica quirúrgica asistida:** IA que ayuda a los cirujanos a identificar estructuras críticas en tiempo real.
- **Planificación quirúrgica inteligente:** Sistemas que simulan procedimientos quirúrgicos basados en imágenes preoperatorias.

5. Monitoreo Continuo del Embarazo

- **Dispositivos portátiles inteligentes:** Sensores que recopilan datos del embarazo en tiempo real, como la frecuencia cardíaca fetal y contracciones uterinas, analizados por IA para identificar riesgos.
- **Aplicaciones móviles personalizadas:** Plataformas que ofrecen recomendaciones basadas en el análisis de datos de salud de la madre y el bebé.

6. Telemedicina y Diagnóstico Remoto

- **Consultas virtuales asistidas por IA:** Análisis automático de datos de las pacientes para asistir a los profesionales de la medicina en las consultas remotas.
- **Diagnóstico remoto de ecografías:** Plataformas que permiten a especialistas revisar imágenes de forma remota, con asistencia de algoritmos de IA.

7. Educación y Capacitación de Profesionales

- **Simuladores de entrenamiento asistidos por IA:** Plataformas de realidad aumentada y virtual que utilizan IA para entrenar a ginecólogos y obstetras en procedimientos complejos.
- **Asistencia durante las consultas:** Herramientas que proporcionan recomendaciones basadas en evidencia durante la consulta clínica.

8. Mejora de la Investigación Clínica

- **Análisis de *big data*:** IA que analiza grandes conjuntos de datos para identificar patrones y tendencias en la salud reproductiva.
- **Identificación de biomarcadores:** Algoritmos que aceleran el descubrimiento de biomarcadores para enfermedades ginecológicas y complicaciones del embarazo.

Así pues, el futuro de la asistencia obstétrica y ginecológica estará marcado por la integración de la IA en cada etapa del cuidado, desde el diagnóstico hasta el tratamiento y el monitoreo. Esto permitirá una atención más personalizada, eficiente y segura, mejorando los resultados clínicos para las pacientes y facilitando la labor de los profesionales de la salud.

Si miramos la evolución de la inteligencia artificial (IA) en medicina, en general, ha sido impresionante y se puede dividir en varias etapas clave:

1. Inicios (1950-1980): Sistemas Basados en Reglas

- **Década de 1950-1960:** Se desarrollan los primeros modelos de IA, como las redes neuronales iniciales y los sistemas de lógica simbólica.
- **Años 70 y 80:** Se crean los sistemas expertos, que usan reglas predefinidas para el diagnóstico y la toma de decisiones clínicas. Ejemplos:
 - **MYCIN (1970s):** Diagnóstico de infecciones bacterianas y recomendación de antibióticos.
 - **Internist-1 (1970s):** Diagnóstico de enfermedades complejas en medicina interna.

2. Desarrollo del Aprendizaje Automático (1980-2000)

- Se implementan algoritmos de aprendizaje automático, aunque con limitaciones por la falta de datos clínicos digitalizados.
- Aparece la informática médica con el desarrollo de sistemas de historia clínica electrónica (HCE).
- Se comienzan a integrar sistemas de apoyo a la decisión clínica en hospitales.

3. Big Data e IA Moderna (2000-2020)

- **Auge del Big Data:** Digitalización masiva de datos de salud, incluyendo imágenes médicas, registros electrónicos y datos genómicos.
- **2010s: Aprendizaje Profundo (*Deep Learning*):**

- Redes neuronales convolucionales (CNNs) mejoran el análisis de imágenes médicas (radiografías, tomografías, resonancias).
- Procesamiento del Lenguaje Natural (NLP) ayuda en la extracción de información de historias clínicas electrónicas.
- **IBM Watson (2011)**: IA aplicada al diagnóstico y tratamiento en oncología.
- **Google DeepMind (2016)**: Algoritmos para diagnóstico ocular y predicción de enfermedades.

4. IA en Medicina de Precisión y Aplicaciones Clínicas (2020-Actualidad)

- **IA generativa**: Modelos como ChatGPT y MedPaLM ayudan en la redacción de informes médicos y en la educación médica.
- **Medicina personalizada**: Uso de IA para predecir respuestas a tratamientos basados en el perfil genético del paciente.
- **Cirugía robótica asistida por IA**: Mayor precisión en procedimientos quirúrgicos.
- **IA en monitorización de salud**: Sensores inteligentes y dispositivos portátiles que analizan datos en tiempo real para prevenir enfermedades.
- **Regulación y ética**: Aumento de normativas para garantizar la seguridad y la equidad en los sistemas de IA médica.

En síntesis, las tendencias de la IA siguen los pasos para:

- IA combinada con nanotecnología y biotecnología para diagnósticos más rápidos y tratamientos personalizados.
- Sistemas de IA más explicables y transparentes para mejorar la confianza en la toma de decisiones médicas.
- Avances en modelado de proteínas para el desarrollo de nuevos fármacos.

Después de hacer un somero repaso a la evolución e impacto esperado, hay un tema que considero de crucial importancia y que no se puede olvidar: la administración de los riesgos.

1.3.1. Administración de los Riesgos en Medicina: Conceptos Básicos

La administración de riesgos en medicina es un conjunto de procesos destinados a identificar, evaluar y minimizar los riesgos que puedan afectar la seguridad de los pacientes, el personal sanitario y la calidad de la atención médica. Aquí se resumen los conceptos básicos:

¿Qué es el Riesgo en Medicina?

El riesgo es la probabilidad de que ocurra un evento adverso que pueda causar daño a un paciente, a un profesional o al funcionamiento del sistema sanitario.

Objetivo de la Administración de Riesgos

- Prevenir errores médicos y eventos adversos.
- Mejorar la calidad y la seguridad de la atención.
- Reducir los costos asociados a negligencias o reclamaciones.
- Cumplir con normativas legales y éticas.

Pasos Básicos de la Administración de Riesgos

- **Identificación del riesgo:**
 - Ej: errores de medicación, infecciones nosocomiales, fallos de equipos, errores diagnósticos.
- **Análisis del riesgo:**
 - Evaluar la frecuencia y gravedad del riesgo.
 - Herramientas: matrices de riesgo, análisis causa-raíz.
- **Evaluación del riesgo:**
 - ¿El riesgo es aceptable o necesita intervención?
- **Control y mitigación del riesgo:**
 - Protocolos, *checklists*, formación del personal, uso de tecnología (ej. sistemas de alerta).
- **Monitoreo y revisión:**
 - Evaluar la eficacia de las medidas tomadas.
 - Retroalimentación y mejora continua.

Tipos Comunes de Riesgos en Medicina

- **Riesgos clínicos:** Errores en tratamientos, diagnósticos o procedimientos.
- **Riesgos legales:** Demandas por mala praxis.
- **Riesgos operativos:** Fallos en procesos internos, errores administrativos.
- **Riesgos tecnológicos:** Mal funcionamiento de equipos médicos o *software*.
- **Riesgos humanos:** Comunicación deficiente, fatiga del personal.

Herramientas Clave

- Eventos centinela y notificación de incidentes.
- Análisis causa-raíz (*Root Cause Analysis* - RCA).
- FMEA (*Failure Mode and Effects Analysis*).
- *Checklists* quirúrgicos (ej. lista de verificación de la OMS).
- Comités de seguridad del paciente.

1.3.2. Cómo nos Puede Ayudar la IA en la Prevención de Riesgos en Medicina

La inteligencia artificial (IA) puede ser una herramienta muy poderosa en la prevención de riesgos en medicina, especialmente en entornos hospitalarios complejos. Aquí se resume cómo puede ayudar en diferentes áreas:

1. Detección Temprana de Eventos Adversos

- La IA puede analizar historias clínicas electrónicas en tiempo real para identificar patrones que anticipan complicaciones (como infecciones, caídas, eventos cardiovasculares...).
- **Ejemplo:** Un algoritmo predice el riesgo de sepsis 12-24 horas antes de que aparezcan síntomas clínicos claros.

2. Apoyo a la Toma de Decisiones Clínicas

- Sistemas de IA pueden alertar sobre interacciones medicamentosas, dosis inadecuadas o alergias.
- Ayudan a elegir el tratamiento más seguro según las características del paciente.
- **Ejemplo:** Alertas inteligentes para prevenir errores de medicación en neonatología.

3. Monitoreo Continuo de Pacientes

- Sensores + IA permiten vigilar constantes vitales en tiempo real.
- Detectan alteraciones antes de que se conviertan en emergencias.
- **Ejemplo:** IA integrada en monitores en Unidades de Cuidados Intensivos (UCIs) que alerta sobre deterioro clínico.

4. Análisis Predictivo de Riesgos

- Algoritmos que calculan el riesgo de reingreso hospitalario, caídas, úlceras por presión, etc.
- Ayuda a priorizar intervenciones preventivas.
- **Ejemplo:** Modelos que predicen riesgo de parto prematuro en obstetricia.

5. Revisión Automatizada de Procesos y Errores

- La IA puede revisar miles de registros clínicos para encontrar errores sistemáticos o 5. cuellos de botella.
- Ayuda a mejorar protocolos y prevenir eventos repetitivos.

6. Mejora de la Comunicación Clínica

- Asistentes inteligentes pueden facilitar la documentación médica y reducir errores por mala comunicación o duplicidad.
- Traducción automática, resúmenes clínicos, asistentes conversacionales.

¿Qué se Necesita para Aplicar IA en Prevención de Riesgos?

- Datos clínicos estructurados y bien registrados.
- Infraestructura digital (HCE, sensores, interoperabilidad).
- Colaboración entre personal clínico, técnicos y expertos en IA.
- Ética, transparencia y explicabilidad de los modelos.

Ejemplos Reales

Hospital / Proyecto	Aplicación IA	Resultado
Hospital General de Massachusetts	IA para predecir sepsis	Reducción de mortalidad
Stanford Health Care	Detección de errores en medicación	Disminución de eventos adversos
Mount Sinai (NY)	IA para deterioro clínico en planta	Mejora en tiempos de respuesta

A continuación, se analiza un caso práctico adaptado a obstetricia y neonatología, centrado en la prevención de riesgos mediante IA. Se inicia con una primera idea de proyecto piloto sencilla, realista y con impacto clínico.

Proyecto Piloto: "IA para Detección Temprana de Riesgo de Sepsis Neonatal"

- **Objetivo:** Desarrollar o implementar un modelo de IA que identifique recién nacidos con alto riesgo de desarrollar sepsis en las primeras horas/días de vida, utilizando datos clínicos disponibles de forma rutinaria.
- **Justificación:**
 - La sepsis neonatal tiene alta morbilidad y mortalidad, y su diagnóstico precoz es difícil.
 - Las manifestaciones clínicas iniciales son inespecíficas.
 - Un sistema basado en IA puede detectar patrones sutiles en constantes, analíticas y antecedentes que predicen el riesgo de sepsis antes de que sea clínicamente evidente.
- **Variables que puede usar el modelo de IA:**
 - **Datos maternos:** Fiebre intraparto, corioamnionitis, colonización por estreptococo, duración de la rotura de membranas.
 - **Datos neonatales:** APGAR, peso, edad gestacional, tipo de parto.
 - **Signos vitales:** Frecuencia cardíaca, temperatura, frecuencia respiratoria.
 - **Analíticas tempranas:** PCR, leucocitos, procalcitonina.
- **¿Cómo funcionaría?**
 - **Recolección de datos:** Anónimos y estructurados, de recién nacidos ingresados.
 - **Entrenamiento del modelo:** Usando *machine learning* (por ejemplo, árboles de decisión, XGBoost o redes neuronales simples).
 - **Validación:** Evaluar precisión, sensibilidad, especificidad.
 - **Implementación inicial (modo sombra):** El sistema da alertas de riesgo, pero sin intervenir aún en la clínica.
 - **Evaluación del impacto clínico:** ¿Se mejora el tiempo de detección y tratamiento? ¿Se reducen las complicaciones?
- **Posibles beneficios:**
 - Diagnóstico más temprano de sepsis.
 - Uso más racional de antibióticos.
 - Menor estancia hospitalaria.
 - Mejora de la seguridad del paciente.

- ¿Qué se necesita para empezar?

Recurso	Descripción
Datos	Hojas clínicas neonatales y maternas estructuradas (mínimo 200-500 casos).
Soporte técnico	Colaboración con ingeniero de datos o bioinformático.
Comité ético	Aprobación para uso de datos anónimos.
Software	Python (<i>scikit-learn</i> , <i>pandas</i>) o plataforma como DataRobot, Google AutoML.

1.3.3. Informe de la OMS (2021)

La OMS Publica el Primer Informe Mundial sobre Inteligencia Artificial (IA) Aplicada a la Salud y Seis Principios Rectores Relativos a su Concepción y Utilización.

El uso cada vez mayor de la IA en el ámbito de la salud plantea oportunidades y desafíos para los gobiernos, los proveedores y las comunidades.

28 de junio de 2021
Comunicado de prensa
Ginebra.

Según las nuevas orientaciones de la OMS publicadas hoy, la inteligencia artificial (IA) ofrece grandes expectativas para mejorar la prestación de atención de salud y la medicina en todo el mundo, siempre y cuando la ética y los derechos humanos ocupen un lugar central en su concepción, despliegue y utilización.

El informe, titulado *Ethics and governance of artificial intelligence for health* (ética y gobernanza de la inteligencia artificial en el ámbito de la salud), es el resultado de dos años de consultas celebradas por un grupo de expertos internacionales nombrados por la OMS.

«Como toda nueva tecnología, la inteligencia artificial ofrece grandes posibilidades para mejorar la salud de millones de personas en todo el mundo; ahora bien, como toda tecnología, también puede utilizarse indebidamente y causar daño», dijo el Dr. Tedros Adhanom Ghebreyesus, Director General de la OMS. «Este nuevo e importante informe proporciona a los países una valiosa guía sobre la manera de aumentar al máximo los beneficios de la IA, al tiempo que se minimizan sus riesgos y se evitan sus trampas».

La inteligencia artificial puede utilizarse, lo que ya se está haciendo en algunos países ricos, para mejorar la velocidad y la precisión del diagnóstico y la detección de enfermedades; facilitar la atención clínica; reforzar la investigación en el ámbito de la salud y el desarrollo de medicamentos, y apoyar diversas intervenciones de salud pública, como la vigilancia de la morbilidad, la respuesta a los brotes y la gestión de los sistemas de salud.

La IA también podría permitir que los pacientes tuvieran un mayor control de su propia atención de salud y comprendieran mejor la evolución de sus necesidades. Además, podría facilitar el acceso a los servicios de salud en los países con escasos recursos y las comunidades rurales, donde los pacientes a menudo tienen dificultades para acceder a los agentes de salud o al personal médico.

Sin embargo, en el nuevo informe de la OMS se advierte del peligro de sobreestimar las ventajas de la IA en el ámbito de la salud, sobre todo cuando esto se hace en detrimento de inversiones y estrategias básicas que son necesarias para lograr la cobertura sanitaria universal.

Además, en él también se señala que las oportunidades conllevan desafíos y riesgos, como la recopilación y utilización poco éticas de los datos sobre salud; los sesgos codificados en los algoritmos, y los riesgos que presenta la IA para la seguridad del paciente, la ciberseguridad y el medio ambiente.

Así, por ejemplo, si bien la inversión de los sectores público y privado en el desarrollo y despliegue de la IA es fundamental, el uso no regulado de la IA podría subordinar los derechos e intereses de los pacientes y las comunidades a los poderosos intereses comerciales de las empresas tecnológicas o a los intereses de los gobiernos en materia de vigilancia y control social.

El informe también pone de relieve que los sistemas entrenados principalmente a partir de datos recopilados de personas que viven en países de alto ingreso pueden no funcionar bien en el caso de las poblaciones de entornos de ingreso bajo o mediano.

Por lo tanto, los sistemas de IA deberían diseñarse cuidadosamente a fin de reflejar la diversidad de los entornos socioeconómicos y de atención de salud. Estos deberían acompañarse de formación en aptitudes digitales, de implicación comunitaria y de sensibilización, en particular para los millones de agentes de salud cuya alfabetización digital o readaptación profesional serán necesarias en caso de que se automaticen sus cometidos y funciones, y que deberán lidiar con máquinas que podrían poner en entredicho las facultades decisorias y la autonomía de los prestadores y los pacientes.

En última instancia, y guiándose por las leyes existentes y las obligaciones en materia de derechos humanos, así como por las nuevas leyes y políticas que incorporan principios éticos, los gobiernos, los proveedores y los diseñadores deben trabajar conjuntamente para abordar las preocupaciones éticas y de derechos humanos en cada etapa de la concepción, desarrollo y despliegue de una tecnología basada en la IA.

1.3.4. Seis Principios para Garantizar que la IA se Utilice en Aras del Interés Público en Todos los Países

A fin de limitar los riesgos y aumentar al máximo las oportunidades que conlleva la utilización de la IA en el ámbito de la salud, la OMS propone que la reglamentación y gobernanza de la IA se basen en los principios siguientes:

- **Preservar la autonomía del ser humano:** En el contexto de la atención de salud, ello significa que los seres humanos deberían seguir siendo dueños de los sistemas de atención de salud y las decisiones médicas; se debería preservar la privacidad y la confidencialidad, y los pacientes deben dar su consentimiento informado y válido por medio de marcos jurídicos adecuados para la protección de datos.
- **Promover el bienestar y la seguridad de las personas y el interés público:** Los diseñadores de tecnologías de IA deberían cumplir los requisitos normativos en materia de seguridad, precisión y eficacia para indicaciones o usos bien definidos. Se deben instaurar medidas de control de la calidad en la práctica y de mejora de la calidad en la utilización de la IA.
- **Garantizar la transparencia, la claridad y la inteligibilidad:** La transparencia exige que se publique o documente información suficiente antes de la concepción o el despliegue de una tecnología de IA. Esa información debe ser fácilmente accesible y facilitar consultas y debates provechosos sobre la concepción de la tecnología y sobre el uso que se debería hacer o no de esta.
- **Promover la responsabilidad y la rendición de cuentas:** Las tecnologías de IA permiten realizar tareas específicas; ahora bien, incumbe a las partes interesadas velar por que estas sean utilizadas en

condiciones apropiadas y por personas debidamente formadas. Se deberían instaurar mecanismos eficaces para que las personas y los grupos que se vean perjudicados por decisiones basadas en algoritmos puedan cuestionarlas y obtener reparación.

- **Garantizar la inclusividad y la equidad:** La inclusividad requiere que la IA aplicada a la salud sea concebida de manera que aliente la utilización y el acceso equitativos en la mayor medida de lo posible, con independencia de la edad, el sexo, el género, el ingreso, la raza, el origen étnico, la orientación sexual, la capacidad u otras características amparadas por los códigos de derechos humanos.
- **Promover una IA con capacidad de respuesta y sostenible:** Los diseñadores, desarrolladores y usuarios deberían evaluar de forma continua y transparente las aplicaciones de la IA en situación real a fin de determinar si esta responde de manera adecuada y apropiada a las expectativas y las necesidades. Los sistemas de IA también se deberían concebir de modo que se reduzcan al mínimo sus efectos medioambientales y se aumente la eficiencia energética. Los gobiernos y las empresas deberían anticipar las perturbaciones ocasionadas en el lugar de trabajo, en particular la formación que se deberá impartir a los agentes de salud para que se familiaricen con el uso de los sistemas de IA, y las posibles pérdidas de empleos debidas a la utilización de sistemas automatizados.

Estos principios orientarán la labor futura de la OMS para respaldar los esfuerzos encaminados a garantizar que todas las posibilidades que ofrece la IA para la atención de salud y la salud pública se utilicen en beneficio de todos.

2. FUNDAMENTOS DE APRENDIZAJE AUTOMÁTICO EN INTELIGENCIA ARTIFICIAL

2. Fundamentos de aprendizaje automático en inteligencia artificial

Romeo Sánchez Nigenda, romeo.sanchezng@uanl.edu.mx

Luis Martín Torres Treviño, luis.torrestrv@uanl.edu.mx

Sara Elena Garza Villarreal, sara.garzavl@uanl.edu.mx

Erick de Jesús Ordaz Rivas, erick.ordazrv@uanl.edu.mx

Dr. Nasser Mohamed Noriega

Facultad de Ingeniería Mecánica y Eléctrica, Universidad Autónoma de Nuevo León.

2.1 Aprendizaje Automático (Machine Learning)

El Aprendizaje Automático (ML, por sus siglas en inglés) es un campo de la inteligencia artificial que permite a los sistemas informáticos aprender y hacer predicciones basadas en datos [1]. A diferencia de la programación tradicional, donde se codifican instrucciones explícitas, los algoritmos de ML identifican patrones en los datos y utilizan estos patrones para inferir resultados. Esta capacidad de mejorar a través de la experiencia sin intervención humana directa convierte al aprendizaje automático en una piedra angular de la inteligencia artificial moderna. Es particularmente transformador en el ámbito de la salud, donde existen grandes volúmenes de datos heterogéneos, complejos y, a menudo, no estructurados.

En esencia, el aprendizaje automático consiste en crear modelos que puedan generalizarse a partir de ejemplos. Los algoritmos de ML se exponen a datos (ejemplos de entrenamiento) y desarrollan modelos que pueden realizar predicciones sobre datos nuevos e inéditos. En ginecología y obstetricia, el ML desempeña un papel fundamental al mejorar la precisión diagnóstica, predecir riesgos y automatizar el análisis de imágenes y señales. Por ejemplo, se utilizan algoritmos de ML para predecir el riesgo de parto prematuro, detectar anomalías fetales a partir de imágenes de ultrasonido, clasificar el estado de salud fetal con base en señales cardiotocográficas y personalizar rutas de atención para pacientes con diabetes gestacional.

El proceso general de aprendizaje automático sigue estos pasos:


1. **Recopilación de datos:** Obtención de datos relevantes y de alta calidad que representen el espacio del problema.
2. **Preprocesamiento:** Limpieza, normalización y transformación de los datos a un formato adecuado.
3. **Selección de características:** Identificación o creación de los atributos más relevantes de los datos.
4. **Selección del modelo:** Elección del algoritmo adecuado para la tarea.
5. **Entrenamiento:** Exposición del modelo a los datos para que pueda aprender patrones.
6. **Evaluación:** Prueba del modelo con datos no vistos para evaluar su rendimiento.
7. **Implementación:** Despliegue del modelo en aplicaciones reales.
8. **Monitoreo y actualización:** Garantizar el rendimiento continuo y refinarlo según sea necesario.

Este proceso es iterativo y, a menudo, requiere varios ciclos para lograr resultados satisfactorios. La distinción entre los diferentes tipos de aprendizajes automáticos comienza con la estructura de este proceso de aprendizaje y la retroalimentación disponible [2]:

- **Aprendizaje supervisado:** Los algoritmos aprenden a partir de ejemplos etiquetados, asignando entradas a salidas conocidas.
- **Aprendizaje no supervisado:** Los algoritmos encuentran patrones en datos no etiquetados.
- **Aprendizaje por refuerzo:** Los algoritmos aprenden interactuando con un entorno y recibiendo retroalimentación mediante recompensas o penalizaciones.

En esta sección se exploran los enfoques más relevantes de ML, visualmente descritos en la Figura 2.1, con énfasis en aplicaciones médicas prácticas.

Figura 2.1 Taxonomía Simplificada de Técnicas de Aprendizaje Automático (Machine Learning).



2.1.1 Aprendizaje Supervisado

El aprendizaje supervisado es la técnica de ML más comúnmente utilizada en aplicaciones médicas. Consiste en entrenar un modelo con un conjunto de datos donde las características de entrada están emparejadas con etiquetas de salida conocidas. El objetivo es aprender una función de mapeo que relacione las entradas con las salidas con un error mínimo. Una vez entrenado, el modelo puede generalizarse para hacer predicciones con datos no vistos.

Formalmente, el aprendizaje supervisado se puede definir matemáticamente de la siguiente manera: Dado un conjunto de entrenamiento:

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$$

donde:

- x_i representa las características de entrada (típicamente un vector de atributos)
- y_i representa la salida objetivo (etiqueta) correspondiente

El objetivo es aprender una función:

$$f: X \rightarrow Y$$

tal que, para nuevas entradas x' , la salida predicha sea lo más cercana posible a la salida verdadera y' .

Esto se logra típicamente minimizando una función de pérdida $L(f(x), y)$, que mide la discrepancia entre los valores predichos $f(x)$ y los valores reales y :

$$\hat{f} = \arg \min_f \sum_{i=1}^n L(f(x_i), y_i)$$

Los distintos algoritmos de aprendizaje supervisado varían en cómo representan esta función de pérdida f y en cómo optimizan los parámetros para minimizar la pérdida. A continuación se explican las dos categorías más importantes de aprendizaje supervisado: clasificación y regresión.

2.1.1.1 Clasificación

La clasificación es una tarea de aprendizaje supervisado cuyo objetivo es predecir etiquetas categóricas. Por ejemplo, determinar si un correo electrónico es spam o no es un problema de clasificación binaria. En clasificación, los modelos aprenden, durante la fase de entrenamiento, de datos que están etiquetados; es decir, de ejemplos cuyos atributos tienen una categoría conocida, con el objetivo de predecir las categorías de nuevos datos no vistos. Los problemas de clasificación pueden ser de tipo binario o multiclase. Existen múltiples algoritmos para clasificación; a continuación, se detallan algunos de los más populares.

Regresión Logística

La regresión logística es un algoritmo fundamental de clasificación que modela la probabilidad P de que una instancia x pertenezca a una clase y en particular. Se utiliza para la clasificación binaria, ya que predice uno de dos posibles resultados. El proceso toma un vector de variables independientes (atributos) y los combina usando una ecuación lineal para calcular un valor [3]:

$$z = W_0 + W_1 x_1 + W_2 x_2 + W_3 x_3 + \dots + W_n x_n = W^T x + b$$

Donde $x_1, x_2, x_3, \dots, x_n$ es el vector de atributos, y $W_0, W_1, \dots, W_n$ son los coeficientes o pesos que el modelo aprende durante la fase de entrenamiento. Para clasificación binaria, modelamos entonces:

$$P(y = 1 | x) = \sigma(w^T x + b)$$

Donde es la función sigmoide, la cual toma cualquier valor como entrada y lo correlaciona a un valor entre 0 y 1; es decir, la probabilidad de predicción de la instancia:

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

Si la combinación lineal z es un número positivo grande, la salida de la función sigmoide estará cercana a 1. Si z es un número negativo grande, la salida de la función estará cercana a 0. Si z es exactamente 0, la salida será 0.5. Para determinar la probabilidad de que una instancia de datos pertenezca a la clase positiva, se establece un umbral de decisión. Un umbral común es 0.5. Si la probabilidad de salida es mayor o igual al umbral, el modelo predice la clase positiva (1); en caso contrario, predice la clase negativa (0).

La frontera de decisión en regresión logística es lineal, lo que la hace adecuada para problemas linealmente separables. Esto significa que el resultado del modelo depende de la suma de entradas y parámetros. En caso contrario, las fronteras de decisión no lineales son curvas o superficies que delimitan un conjunto de categorías. Estas fronteras pueden aprenderse usando modelos no lineales como árboles de decisión, máquinas de vectores de soporte (SVM) o redes neuronales.

Un ejemplo clásico de clasificación lineal usando regresión logística sería en el área de diagnóstico médico para predecir la probabilidad de que un paciente tenga cierta enfermedad de acuerdo con sus síntomas o resultados clínicos. Supongamos que construimos un modelo de regresión logística para predecir si una paciente desarrollará preeclampsia. En este ejemplo hipotético, se pudieran considerar características como la

edad de la paciente, el índice de masa corporal, el promedio de lecturas de presión arterial, historial de diabetes, historia familiar, entre otros atributos, para predecir la variable objetivo, ocurrencia de preeclampsia. Cada caso clínico, para el proceso de entrenamiento, se representaría como un vector de características x , y el modelo aprendería los pesos w para estimar la probabilidad de que la paciente desarrolle preeclampsia. Si esta probabilidad supera un umbral (típicamente 0.5), la paciente se clasifica con ocurrencia de preeclampsia.


El modelo se entrena minimizando la función de pérdida de entropía cruzada:

$$L(w) = -\frac{1}{n} \sum_{i=1}^n [y_i \log \log \hat{y}_i + (1 - y_i) \log \log (1 - \hat{y}_i)]$$

Donde $\hat{y}_i = \sigma(w^T x_i + b)$ es la probabilidad predicha.

Podemos observar en la Figura 2.2 un ejemplo ilustrativo de regresión logística, donde los atributos descritos anteriormente se han utilizado para generar un *score* de riesgo compuesto, y vemos cómo el modelo predice la probabilidad de ocurrencia de preeclampsia dado el factor de riesgo.

Figura 2.2 Ejemplo de regresión logística para predecir la probabilidad de ocurrencia de preeclampsia dado un *score* compuesto de riesgo.



Naïve Bayes

El algoritmo de Naïve Bayes es un clasificador lineal de aprendizaje automático supervisado basado en el Teorema de Bayes [4]. Se considera "ingenuo" (Naïve) porque asume que todos los atributos en los datos son condicionalmente independientes entre sí y contribuyen equitativamente; es decir, son igualmente importantes para la variable de decisión. La suposición de independencia casi nunca es correcta en la realidad, pero funciona bien en la práctica. No necesitamos ser tan exactos en la probabilidad de salida, siempre que la probabilidad mayor se le asigne a la clase correcta.

El Teorema de Bayes establece la probabilidad de una hipótesis (A) dada cierta evidencia observada (B):

$$P(B) = \frac{P(A) \cdot P(A)}{P(B)}$$

Para la tarea de clasificación, la ecuación anterior la podemos replantear como:

$$P(\text{Características}) = \frac{P(\text{Clase}) \cdot P(\text{Clase})}{P(\text{Características})}$$

Bajo la interpretación que:

$P(\text{Características})$: Representa la probabilidad posterior de que un punto de datos, dadas sus características, pertenezca a una clase específica.

$P(\text{Clase})$: representa la posibilidad de observar las características proporcionadas dentro de una clase específica.

$P(\text{Clase})$: representa la probabilidad previa de que cierta clase ocurra, independientemente de las características.

$P(\text{Características})$: representa la probabilidad de observar las características (evidencia), independientemente de la clase. Dado que esto es constante para todas las clases, a menudo se ignora en la regla de decisión final.

Para calcular la probabilidad $P(\text{Clase})$, el algoritmo utiliza la simplificación Naïve. Si tenemos n atributos o características $(x_1, x_2, x_3, \dots, x_n)$, esta simplificación de independencia permite separar la probabilidad combinada general en un producto de probabilidades individuales para cada característica:

$$P(x_1, x_2, x_3, \dots, x_n | \text{Clase}) = P(x_1 | \text{Clase}) \cdot P(x_2 | \text{Clase}) \cdot \dots \cdot P(x_n | \text{Clase})$$

Podemos utilizar Naïve Bayes para clasificar el riesgo de que una mujer embarazada desarrolle Preeclampsia (clase 1) o no (clase 0). Imagina que tenemos la siguiente Tabla 2.1 de características, donde MAP corresponde a la Presión Arterial Media:

Tabla 2.1 Datos de entrenamiento de pacientes clasificados con bajo y alto riesgo de desarrollar preeclampsia.

Característica o Atributo	Bajo Riesgo (clase 0) Total	Alto Riesgo (clase 1) Total
Total de Pacientes	70	30
$MAP \leq 90$	55	5
$MAP > 90$	15	25
No Historial de Diabetes	65	10
Si Historial de Diabetes	5	20
No Historial Familiar	60	5
Si Historial Familiar	10	25

El primer paso del algoritmo consiste en calcular las probabilidades previas de cada clase dado nuestro conjunto de datos de entrenamiento:

$$P(\text{Clase} = 0) = P(\text{No Preeclampsia}) = \frac{70}{100} = 0.7$$

$$P(\text{Clase} = 1) = P(\text{Preeclampsia}) = \frac{30}{100} = 0.3$$

El paso 2 consiste en calcular las posibilidades de que las características ocurran dados los pacientes de cada clase $P(Clase)$.

Tabla 2.2 de posibilidades $P(\text{Características} | \text{Clase})$.

Característica	$P(\text{No Preeclampsia})$	$P(\text{Preeclampsia})$
Total de Pacientes	70	30
$MAP \leq 90$	$\frac{55}{70} \approx 0.78$	$\frac{5}{30} \approx 0.16$
$MAP > 90$	$\frac{15}{70} \approx 0.21$	$\frac{25}{30} \approx 0.83$
No Historial de Diabetes	$\frac{65}{70} \approx 0.92$	$\frac{10}{30} \approx 0.33$
Si Historial de Diabetes	$\frac{5}{70} \approx 0.07$	$\frac{20}{30} \approx 0.66$
No Historial Familiar	$\frac{60}{70} \approx 0.85$	$\frac{5}{30} \approx 0.16$
Si Historial Familiar	$\frac{10}{70} \approx \text{es. } 0.14$	$\frac{25}{30} \approx 0.83$

El paso 3 consiste en calcular la probabilidad posterior $P(\text{Características})$ para clasificar a un nuevo paciente. Consideremos que el nuevo paciente tiene las siguientes características: {MAP = 95, Historial de Diabetes = No, Historial Familiar = Sí}. Usando la presunción Naïve de que las características son independientes, calculamos estas probabilidades de la siguiente forma:

Probability de No Preeclampsia (clase 0) dada la evidencia (características) X:

$$\begin{aligned}
 P(\text{Características}) &= P(MAP > 90 | 0) \cdot P(\text{Diabetes} = \text{No} | 0) \cdot P(\text{Historial Familiar} = \text{Si} | 0) \cdot P(\text{Clase} = 0) \\
 P(\text{Características}) &= 0.21 \cdot 0.92 \cdot 0.14 \cdot 0.70 \approx 0.020
 \end{aligned}$$

Probability de Preeclampsia (clase 1) dada la evidencia:

$$\begin{aligned}
 P(\text{Características}) &= P(MAP > 90 | 1) \cdot P(\text{Diabetes} = \text{No} | 1) \cdot P(\text{Historial Familiar} = \text{Si} | 1) \cdot P(\text{Clase} = 1) \\
 P(\text{Características}) &= 0.83 \cdot 0.33 \cdot 0.83 \cdot 0.30 \approx 0.069
 \end{aligned}$$

El último paso consiste en determinar la predicción final comparando las predicciones de clase no normalizadas. Dado que:

$$P(\text{Características}) \approx 0.069 > P(\text{Características}) \approx 0.020$$

El clasificador Naïve Bayes predice que el nuevo paciente desarrollará preeclampsia (Clase 1). Para obtener la probabilidad actual de cada clase necesitaríamos normalizar los valores:

$$P(\text{Características}) = \frac{0.069}{0.020+0.069} \approx 0.775 \approx 77.5\%$$

K-Vecinos Cercanos (K-NN)

El algoritmo de K-Vecinos Cercanos (K-NN - K-Nearest Neighbors) es un algoritmo de clasificación de aprendizaje supervisado que memoriza el conjunto de datos de entrenamiento [5]. A diferencia de la Regresión Logística que aprende coeficientes, o de las SVM que aprenden un hiperplano, K-NN no aprende ningún parámetro o estructura durante el entrenamiento. En su lugar, para clasificar un nuevo registro, K-NN simplemente busca en memoria los datos más similares. Para determinar la similitud entre datos, K-NN utiliza funciones para calcular distancias entre ellos, por lo que datos más similares son aquellos más cercanos.

Para clasificar un nuevo dato x , el algoritmo K-NN completa el siguiente proceso:

1. Define el parámetro K ; es decir, elige el número de vecinos cercanos K a considerar para clasificar a x . Utiliza un número impar para eliminar empates en la votación final.
2. Calcula las distancias entre x y cada punto de datos en el conjunto de entrenamiento. Existen diferentes métricas de distancias que se pueden utilizar como la Euclidiana, la de Manhattan, o la de Minkowski.
3. Selecciona los K **vecinos** dentro del conjunto de entrenamiento que se encuentren a menor distancia de x . Estos son los K vecinos más cercanos.
4. Vota (cuenta) entre los K vecinos seleccionados el número de etiquetas de cada clase.
5. Asigna la clase a x de acuerdo a la clase mayoritaria entre los K vecinos cercanos.

La parte central del algoritmo de K-NN es la función de distancia. Continuando con el ejemplo de clasificación de ocurrencia de preeclampsia en pacientes, para dos puntos de datos (pacientes) x e y , cada uno con n características, la Distancia Euclidiana se define como:

$$Euclidiana(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Mientras que la distancia de Manhattan como:

$$Manhattan(x, y) = \sum_{i=1}^n |x_i - y_i|$$

Y la distancia de Minkowski:

$$Minkowski(x, y) = (\sum_{i=1}^n |x_i - y_i|^p)^{\frac{1}{p}}$$


Donde $(\mathbf{x}, \mathbf{y})$ son los vectores de características de dos pacientes (p.ej., [Edad, Índice de Masa Corporal (IMC), Presión Arterial Media (MAP)]), por lo que x_i y y_i son los valores de la i -ésima característica para cada paciente. Supongamos que tenemos un conjunto de entrenamiento con pacientes previamente clasificados y hemos elegido $K = 5$, y deseamos clasificar a un nuevo paciente $x = [\text{Edad} = 0.8, \text{IMC} = 0.6, \text{MAP} = 0.9]$, cuyos valores han sido normalizados. Asuma que los 5 vecinos más cercanos, una vez calculadas las distancias al nuevo paciente x son:

Tabla 2.3 K=5 vecinos cercanos a un nuevo paciente $x = [\text{Edad} = 0.8, \text{IMC} = 0.6, \text{MAP} = 0.9]$

Ve- cino	Edad	IMC	MAP	Distancia Euclidiana	Clase Real
P1	0.7	0.7	0.8	$\sqrt{(0.8 - 0.7)^2 + (0.6 - 0.7)^2 + (0.9 - 0.8)^2}$ ≈ 0.17	(1)Preeclampsia
P2	0.9	0.5	0.8	$\sqrt{(0.8 - 0.9)^2 + (0.6 - 0.5)^2 + (0.9 - 0.8)^2}$ ≈ 0.17	(0)No Preeclampsia
P3	0.8	0.5	0.7	$\sqrt{(0.8 - 0.8)^2 + (0.6 - 0.5)^2 + (0.9 - 0.7)^2}$ ≈ 0.22	(1)Preeclampsia
P4	0.7	0.9	0.8	$\sqrt{(0.8 - 0.7)^2 + (0.6 - 0.9)^2 + (0.9 - 0.8)^2}$ ≈ 0.33	(1)Preeclampsia
P5	0.6	0.8	0.7	$\sqrt{(0.8 - 0.6)^2 + (0.6 - 0.8)^2 + (0.9 - 0.7)^2}$ ≈ 0.34	(1)Preeclampsia

Por lo que, la clase mayoritaria para $K = 5$ en este ejemplo es (1) Preeclampsia, y esa es la clase que se asigna al nuevo paciente x . Podemos observar en la Figura 2.4 una ilustración gráfica del ejemplo y el radio de vecinos más cercanos seleccionados dados los datos de entrenamiento.

Figura 2.4 Ejemplo gráfico del algoritmo K-NN para K=5.



Máquinas de Vectores de Soporte (SVM)

Las Máquinas de Vectores de Soporte (SVM) son clasificadores potentes que encuentran el hiperplano óptimo que maximiza el margen de separación entre clases [6]. A diferencia de la regresión logística o Naïve Bayes, los cuales utilizan probabilidades, las máquinas de vectores de soporte son clasificadores de frontera de decisión pura, inherentemente lineales. El modelo puede extenderse a problemas no lineales mediante una técnica denominada el "Truco de Kernel".

El objetivo de SVM es encontrar un plano de separación (hiperplano) que maximice la distancia a los puntos de datos más cercanos de las clases. A estos puntos de datos más cercanos al hiperplano se les conoce como los vectores de soporte. La SVM busca maximizar la distancia (margen) entre el hiperplano y los vectores de soporte para asegurar que la frontera de decisión sea lo más robusta posible.

El problema de optimización para datos linealmente separables se expresa como:


$$\max_{w,b} ||w||^{-2}$$

Sujeto a:

$$\begin{aligned} w^T x_i + b &\geq 1, \forall i \in \text{Clase 1} \\ w^T x_i + b &\leq -1, \forall i \in \text{Clase 2} \end{aligned}$$

Donde x_i es un vector de características, w^T es el vector de pesos al hiperplano, y b es el sesgo o intercepto. Por ejemplo, para el caso de diagnóstico de preeclampsia, la salida del SVM podría clasificar como preeclampsia a la clase 1, y no preeclampsia a la clase 2.

Figura 2.5 Ejemplo gráfico de clasificación de preeclampsia con dos atributos usando SVMs.



Podemos observar en la Figura 2.5 la clasificación de ocurrencia de preeclampsia usando SVM, simplificando la clasificación a solamente dos atributos, el IMC y la MAP. Se muestran dos hiperplanos, donde el margen de separación del primer hiperplano, en la parte superior de la figura, es mayor que el del segundo hiperplano, observando sus vectores de soporte. En este ejemplo simple, el primer hiperplano presenta una mejor frontera de decisión.

Para datos no linealmente separables, las SVM usan el truco del *kernel* para mapear implícitamente los datos a espacios de mayor dimensión donde la separación lineal es posible. Para tal efecto, la SVM utiliza una función *kernel* (p. ej., Kernel Gaussiano o Radial (RBF)) para calcular la similitud entre dos puntos de datos en el espacio original, la cual es equivalente a las distancias de los puntos en el nuevo espacio de dimensiones superiores, donde se vuelven linealmente separables.

Por ejemplo, en diagnósticos médicos, las SVM pueden clasificar pacientes con base en mediciones de biomarcadores o análisis clínicos. El truco del *kernel* permite capturar relaciones complejas y no lineales entre atributos y estados de la enfermedad.

Usando un *kernel* de base radial (RBF), la función de decisión de la SVM es:


$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b)$$

Donde α_i son los coeficientes de Lagrange, distintos de cero para los vectores de soporte x_i , y

$$K(x_i, x) = \exp(-\gamma \|x_i - x\|^2)$$

es el *kernel* RBF, que mide la similitud entre el punto x y cada vector de soporte x_i en un espacio implícito de mayor dimensión. Podemos observar, en la Figura 2.5, un ejemplo de la aplicación del truco de *Kernel* al ejemplo de clasificación de preeclampsia.

Figura 2.6 Transformación conceptual de datos no separables linealmente a un espacio donde sí lo son.



Árboles de Decisión

Los árboles de decisión son otro algoritmo de aprendizaje supervisado que construye un modelo que predice el valor de una variable objetivo (clase) aprendiendo reglas de decisión inferidas a partir de las características de los datos. A diferencia de los algoritmos basados en distancias como K-NN, o los que buscan una frontera de decisión como SVM, los árboles de decisión segmentan el espacio de características en regiones para tomar decisiones, asignando una predicción constante a cada región.

En un principio, la raíz del árbol de decisión representa el conjunto de datos completo y es el primer punto de división. Cada nodo interno del árbol representa una prueba sobre un atributo (característica), por lo que cada rama que emerge de un nodo interno corresponde a un posible valor o rango de valores para el atributo evaluado. Los nodos hoja, o nodos terminales, representan la predicción del modelo; es decir, la etiqueta de clase como resultado final de la decisión. Los árboles de decisión, además de usarse para clasificación, también pueden utilizarse en regresión, donde la predicción de una hoja es un valor numérico derivado del promedio de los ejemplos en esa región.

Uno de los algoritmos básicos para construir árboles de decisión es CART (Classification and Regression Trees) [7], el cual se ilustra a continuación:

1. El nodo raíz considera todo el conjunto de datos de entrenamiento.
2. Se selecciona el mejor atributo para dividir: Examinando todos los atributos disponibles y sus posibles puntos de corte para encontrar la mejor división. La mejor división es aquella que maximiza la ganancia de información o minimiza la impureza de los nodos hijos resultantes. La impureza mide el grado de incertidumbre en un nodo. Un nodo puro contiene solo ejemplos de una clase; es decir, no hay incertidumbre. Las métricas comunes para medir la impureza son:
 - a. **Entropía/Ganancia de Información:** La entropía mide la incertidumbre de un conjunto de datos, mientras que la Ganancia de Información mide la reducción en la entropía después de una división.
 - b. **Índice de Gini:** Mide la probabilidad de clasificar erróneamente un elemento elegido al azar de un nodo. Un valor más bajo indica mayor pureza.
3. El nodo se divide en dos o más hijos, según los atributos y el punto de corte seleccionados.
4. Se repiten los pasos 2 y 3 recursivamente para cada nodo hijo hasta que se cumplan algunas de las siguientes condiciones:
 - a. Todos los nodos hoja son puros (contienen solo ejemplos de una clase).
 - b. Se alcanza una profundidad máxima predefinida para el árbol.
 - c. Un número mínimo de ejemplos en un nodo no puede ser dividido más.

El Índice de Gini para un nodo t , para una clase binaria, se calcula como:

$$Gini(t) = 1 - \sum_{i=1}^C (P_i)^2$$

Donde C es el número de clases, en nuestro ejemplo $C=2$ (Preeclampsia y No Preeclampsia), y P_i es la proporción de ejemplos de la clase i en el nodo t .

Para evaluar una división, calculamos la Ganancia de Gini utilizando el Gini de los nodos hijos ponderado por el número de ejemplos en cada hijo, y lo restamos del Gini del nodo padre:

$$Ganancia\ de\ Gini = Gini(padre) - \sum_{k=1}^m \left(\frac{N_k}{N} \right) Gini(k)$$

Donde m es el número de nodos hijos creados por la división, N_k es el número de ejemplos en el nodo hijo k , y N es el número de ejemplos en el nodo padre. El algoritmo elige la división que maximiza la Ganancia de Gini.

Asumamos el siguiente conjunto de datos simplificado con 10 pacientes, presentado en la Tabla 2.4, para ilustrar el procedimiento del algoritmo de árboles de decisión para determinar la ocurrencia de Preeclampsia. El *dataset* contiene en total 6 pacientes de Clase 1 (Preeclampsia) y 4 de la Clase 0 (No Preeclampsia).

Tabla 2.4 Dataset de entrenamiento para modelo de árboles de decisión.


Paciente	Edad	IMC	MAP	Clase Real (Preeclampsia)
P1	0.7	0.7	0.8	1 (Sí)
P2	0.8	0.5	0.7	1 (Sí)
P3	0.7	0.8	0.7	1 (Sí)
P4	0.5	0.6	0.5	0 (No)
P5	0.9	0.4	0.9	1 (Sí)
P6	0.4	0.7	0.6	0 (No)
P7	0.6	0.5	0.6	0 (No)
P8	0.6	0.6	0.8	1 (Sí)
P9	0.6	0.6	0.5	0 (No)
P10	0.7	0.7	0.9	1 (Sí)

En un principio, la raíz del árbol contiene los 10 registros de pacientes, por lo que su índice Gini es:

$$Gini(raíz) = 1 - \left[\left(\frac{6}{10} \right)^2 + \left(\frac{4}{10} \right)^2 \right] = 1 - [0.36 + 0.16] = 1 - 0.52 = 0.48$$

Se consideran diferentes divisiones hipotéticas para identificar el mejor atributo. En este ejemplo, la primera división correspondería al atributo MAP con el punto de corte MAP > 0.7, como se ilustra en la Figura 2.6, y la segunda división correspondería a la característica IMC con el punto de corte IMC > 0.6.

Figura 2.7 Cómputo del Índice de Gini para 2 atributos diferentes.



Una vez calculados los índices de Gini para cada atributo, procedemos a calcular la Ganancia de Gini para cada división y seleccionamos aquella división que maximice la Ganancia. En este ejemplo, tendríamos las siguientes Ganancias de Gini:


$$Ganancia\ de\ Gini\ (MAP) = Gini(raíz) - \left[\left(\frac{4}{10} \right) \cdot Gini(> 0.7) + \left(\frac{6}{10} \right) \cdot Gini(\leq 0.7) \right]$$

$$= 0.48 - [0.4 \times 0 + 0.6 \times 0.44] = 0.48 - 0.26 = 0.21$$

$$Ganancia\ de\ Gini\ (IMC) = Gini(raíz) - \left[\left(\frac{4}{10} \right) \cdot Gini(> 0.6) + \left(\frac{6}{10} \right) \cdot Gini(\leq 0.6) \right] = 0.48 - [0.4 \times 0.37 + 0.6 \times 0.50] = 0.48 - [0.14 + 0.30] = 0.04$$

Podemos observar que la Ganancia de Gini es mayor para la división con el atributo IMC (0.08) en comparación con MAP (0.03), por lo que el algoritmo elegiría el atributo IMC para la primera división para el árbol. El algoritmo ahora recurre para encontrar el siguiente atributo para continuar las divisiones en el árbol. La Figura 2.8 muestra el árbol completo para este ejemplo hipotético.

Figura 2.8 Árbol completo para ejemplo de Preeclampsia.



Este enfoque no paramétrico y no lineal de los árboles de decisión puede capturar interacciones complejas entre variables sin asumir una forma funcional específica, generando modelos con alto grado de explicabilidad dadas las reglas que genera implícitamente. Sin embargo, los árboles de decisión son inestables, lo que se traduce en una varianza alta en las predicciones, y propensos al sobreajuste (*overfitting*), ya que pueden crecer, si no tienen restricciones de profundidad, hasta el punto de aprender el ruido y valores atípicos, memorizando los datos de entrenamiento en lugar de generalizar.

2.1.1.2 Regresión

Aunque los modelos de clasificación y regresión pertenecen a la categoría de aprendizaje supervisado, se diferencian en el tipo de variable de salida o variable objetivo que predicen. Mientras que un modelo de clasificación predice una variable de salida discreta o categórica, un modelo de regresión predice una variable de salida continua o de valor real. Es decir, la salida de un modelo de regresión es un valor numérico que puede estar en cualquier punto dentro de un rango, por lo que un problema típico que abordan estos modelos es estimar o pronosticar un valor futuro.

Regresión Lineal

La regresión lineal modela la relación entre variables de entrada (independientes) y una salida continua (variable dependiente) usando una ecuación lineal:

$$\hat{y} = \beta_0 + \beta_1 x$$

Donde $\hat{y}$ representa el valor estimado de la variable dependiente. Por ejemplo, en el caso de preeclampsia podría ser la Presión Arterial Media (MAP). β_0 representa el intercepto o sesgo; es decir, el valor de $\hat{y}$ cuando la variable independiente x (o atributo) es cero. Y β_1 es el coeficiente o pendiente, que representa la cantidad en que cambia $\hat{y}$ por cada cambio de una unidad en x . La formulación anterior puede generalizarse a n atributos o características ($x_1, x_2, \dots, x_n$).

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$

Cada β_i representa la influencia (peso) del atributo x_i en la predicción final $\hat{y}$.

El objetivo del modelo de regresión lineal es encontrar los valores óptimos para los coeficientes $\beta_0, \beta_1, \dots, \beta_n$ que minimicen la diferencia (error) entre el valor predicho ($\hat{y}$) y el valor real (y). Estos parámetros se estiman típicamente minimizando el error cuadrático medio (MSE):

$$MSE = \frac{1}{m} \sum_{j=1}^m (y_j - \hat{y}_j)^2$$

Donde m representa el número total de puntos de datos (por ejemplo, número de pacientes), y_j representa el valor real observado de la variable dependiente para el paciente j , y $\hat{y}_j$ es el valor predicho por el modelo para el paciente j .

Como la Regresión Lineal no predice una clase binaria (Preeclampsia Sí/No), predeciremos una variable continua relacionada con el riesgo de desarrollar preeclampsia; por ejemplo, predecir la Presión Arterial Media (MAP) futura de una paciente. Supongamos que queremos predecir la MAP de una paciente en la semana 30 de gestación ($\hat{y}$) utilizando solamente 2 atributos o características: su IMC y su edad.

$$MAP_{semana\ 30} = \beta_0 + \beta_1(IMC) + \beta_2(Edad)$$

Durante el proceso de entrenamiento, el algoritmo va ajustando los valores de los coeficientes $\beta_0, \beta_1, y \beta_2$, los cuales pueden inicializarse de manera aleatoria, con los datos históricos de pacientes, a través de la minimización del MSE. El proceso se detiene cuando el modelo converge; es decir, el cambio en el valor de los coeficientes es muy pequeño o se alcanza un número máximo de iteraciones. Supongamos, en nuestro ejemplo hipotético, que el modelo converge a:

$$MAP_{semana\ 30} = 60 + 1.5(IMC) + 0.8(Edad)$$

Por lo que la predicción a una nueva paciente con un IMC de 28 y una edad de 35 años es:

$$MAP_{semana\ 30} = 60 + 1.5(28) + 0.8(35) = 130$$

2.1.2 Aprendizaje No Supervisado

Los algoritmos de aprendizaje no supervisado trabajan con datos no etiquetados, buscando descubrir estructuras o patrones inherentes sin una guía explícita. A diferencia del aprendizaje supervisado, estos modelos no tienen una variable objetivo (respuesta) para comparar y guiar su aprendizaje.

Dado un conjunto de datos $D = \{x_1, x_2, x_3, \dots, x_n\}$ sin etiquetas o clases correspondientes, los algoritmos de aprendizaje no supervisado típicamente intentan modelar la distribución subyacente de los datos para identificar estructuras dentro de los mismos. Esto puede implicar:

- **Agrupamiento o *Clustering*:** Agrupar puntos de datos similares en clústeres homogéneos, donde los miembros de un grupo son más parecidos entre sí y disímiles a los miembros de otros grupos.
- **Asociación:** Descubrir reglas de asociación entre características de los datos (ej., si ocurre A, es probable que ocurra B).
- **Reducción de Dimensionalidad:** Reducir el número de variables de entrada para simplificar el proceso de entrenamiento y aprendizaje del modelo, preservando información importante.

2.1.2.1 Clustering

Los algoritmos de *clustering* agrupan puntos de datos basándose en sus características, utilizando medidas de similitud y sin usar etiquetas en los datos. Estos algoritmos buscan maximizar la similitud de los individuos dentro de los grupos (intraclúster), mientras que minimizan la similitud entre grupos (interclúster). Generalmente, se utilizan medidas de similitud basadas en distancias, como la distancia euclidiana o la similitud coseno. Existen diferentes tipos de *clustering*:

- ***Clustering* Duro:** Cada punto de datos se asigna exactamente a un clúster, sin permitir el traslape de elementos entre clústeres. En este enfoque, la membresía de los datos es clara, lo que facilita la interpretación para tareas de segmentación de datos, pero no puede representar ambigüedad entre grupos.
- ***Clustering* Suave:** Cada punto de datos pertenece, con cierta probabilidad, a múltiples clústeres simultáneamente. El *clustering* suave captura la ambigüedad en los datos al considerar características interclústeres, permitiendo modelar transiciones graduales en los mismos.

A continuación, se ilustran dos ejemplos de algoritmos dentro de estas categorías: K-medias (*K-means*) y el algoritmo de EM (*Expectation Maximization*).

K-medias

El algoritmo de K-medias o *K-means* es un algoritmo de *clustering* basado en centroides que particiona los datos en K grupos (clústers) $C_1, C_2, \dots, C_k$. En este algoritmo, el número de clústeres es un parámetro de entrada, y los clústeres se construyen mediante la asignación iterativa de puntos de datos al centroide más cercano, actualizando los centroides con los puntos de datos que les fueron asignados. Esta técnica obviamente produce clústeres duros, ya que los datos no se comparten entre clústeres. El algoritmo es rápido y escalable a conjuntos de datos grandes, pero requiere conocimiento del valor de K , y es sensible a la inicialización de los centroides y a valores atípicos en los datos. A continuación, se presenta el algoritmo general de K-medias (Forgy, 1965):

1. Inicializar K centroides $\mu_1, \mu_2, \mu_3, \dots, \mu_k$, donde cada μ_j es la media del clúster C_j , inicializada en un principio aleatoriamente.
2. Repetir hasta converger:
 - Asignar cada punto de datos x_i al clúster C_j identificando el centroide μ_j más cercano, utilizando una función de distancia; por ejemplo, distancia euclidiana:

Asignar x_i a $C_j \Leftrightarrow \arg \min_j ||x_i - \mu_j||^2$

- Actualizar cada centroide μ_j como el promedio de los puntos de datos asignados al clúster C_j :
-

$$\mu_j = \frac{1}{|C_j|} \sum_{x_i \in C_j} x_i$$

El objetivo de K-means es minimizar la suma de las distancias cuadradas entre cada punto de datos y el centroide de su clúster asignado para converger. Esta métrica se conoce como la Suma de Cuadrados dentro del Clúster (WCSS – *Within-Cluster Sum of Squares*):


$$WCSS = \min_{C_j} \sum_{j=1}^K \sum_{x_i \in C_j} ||x_i - \mu_j||^2$$

El aprendizaje no supervisado es invaluable en medicina para descubrir subtipos o fenotipos de enfermedades que no son obvios clínicamente. Imaginemos el siguiente escenario hipotético: descubrimiento de subtipos de riesgos de preeclampsia. En lugar de predecir si una paciente tiene preeclampsia (aprendizaje supervisado), el objetivo es descubrir si existen grupos naturales y distintos de pacientes basados en sus mediciones (atributos) de MAP, IMC, edad, etc., ignorando el diagnóstico clínico final.

Asumamos que seleccionamos $K = 3$ para que el algoritmo identifique tres clústeres. El resultado hipotético agrupa a los pacientes y descubre tres fenotipos distintos, los cuales pueden observarse gráficamente:

- **Clúster 1:** Mujeres jóvenes con MAP promedio e IMC bajos, las cuales constituyen un clúster de riesgo bajo.
- **Clúster 2:** Mujeres de edad media con MAP e IMC promedios, las cuales constituyen un clúster de riesgo medio que el modelo ha detectado.
- **Clúster 3:** Mujeres mayores con IMC y MAP altos, el cual constituye en nuestro análisis un grupo de riesgo muy alto.

Figura 2.10 Ejemplo K-means para ejemplo de preeclampsia



Algoritmo de Maximización de Expectativas EM (Expectation Maximization).

El algoritmo de Maximización de Expectativas (EM) es un método iterativo que se utiliza para encontrar las estimaciones de máxima verosimilitud de los parámetros de un modelo estadístico cuando los datos observados son incompletos o contienen variables latentes (ocultas) (Ng, et al., 2012). A diferencia del algoritmo de K-medias que produce clústeres duros, EM puede ser utilizado en *clustering* para asignar probabilidades de pertenencia de los elementos a múltiples clústeres; es decir, se le puede considerar un método de *clustering* suave.

EM es el motor matemático detrás de modelos probabilísticos de aprendizaje no supervisado, como la mezcla de modelos Gaussianos (*Gaussian Mixture Models* – GMM). En el contexto médico, por ejemplo, el EM se utilizaría para modelar las poblaciones de riesgo de preeclampsia, asumiendo que el riesgo real sigue una distribución de probabilidad que no podemos observar directamente; es decir, la probabilidad de pertenencia de cada paciente a un subgrupo de riesgo.

El algoritmo itera a través de dos fases: la fase de Expectación o cálculo de probabilidades, y la fase de Maximización (verosimilitud de los datos). El proceso comienza con una estimación inicial aleatoria de los parámetros del modelo para cada una de las K distribuciones Gaussianas:

- Los Pesos (π_k) que representan la probabilidad inicial que un paciente pertenezca a subgrupo k .
- Las Medias (μ_k) que representan los centroides iniciales de los subgrupos k , y
- Las covarianzas (Σ_k) que definen la forma inicial de la distribución para el subgrupo k .

Durante la fase de Expectación, el algoritmo calcula los valores esperados de las variables latentes (los datos faltantes), asignando probabilidades o responsabilidades a las mismas usando los datos observados. El objetivo de este paso es calcular la probabilidad esperada γ_{ik} de que cada punto de datos x_i pertenezca a cada uno de los K subgrupos.

$$\gamma_{ik} = \frac{\pi_k^{\text{anterior}} \prod (x_i | \mu_k^{\text{anterior}}, \Sigma_k^{\text{anterior}})}{\sum_{j=1}^K \pi_j^{\text{anterior}} \prod (x_i | \mu_j^{\text{anterior}}, \Sigma_j^{\text{anterior}})}$$

Donde, γ_{ik} es la probabilidad de pertenencia del paciente i al subgrupo k . $\prod (x_i | \mu_k, \Sigma_k)$ es la densidad de probabilidad de la distribución k en el punto x_i . El resultado de esta fase es una matriz de responsabilidades,

donde cada fila (paciente) suma 1, indicando la distribución de probabilidad de su pertenencia a los K subgrupos.

En la fase de Maximización se utilizan las responsabilidades calculadas en el paso anterior para re-estimar los parámetros del modelo de una manera que maximice la verosimilitud de los datos observados. Primeramente, se calcula el número efectivo de pacientes que pertenecen al subgrupo k .

$$N_K = \sum_{i=1}^m \gamma_{ik}$$

Después, se actualizan los pesos; es decir, la probabilidad de encontrar a un paciente en el subgrupo k .

$$\pi_k^{nuevo} = \frac{N_K}{m}$$

Se actualizan las medias de cada subgrupo k como la suma ponderada de sus miembros (pacientes en nuestro ejemplo).

$$\mu_k^{nuevo} = \frac{1}{N_K} \sum_{i=1}^m \gamma_{ik} x_i$$

Finalmente, se actualizan las covarianzas Σ_k :

$$\Sigma_k^{nuevo} = \frac{1}{N_K} \sum_{i=1}^m \gamma_{ik} (x_i - \mu_k^{nuevo}) (x_i - \mu_k^{nuevo})^T$$

Los pasos de expectación y maximización se repiten hasta que el cambio en la verosimilitud (o los parámetros del modelo) cae por debajo de un umbral, indicando que las distribuciones Gaussianas han encontrado su posición óptima para modelar la estructura subyacente de los datos.

2.1.2.2 Asociación

Algoritmo APRIORI

El algoritmo APRIORI cae dentro de la categoría de aprendizaje no supervisado, específicamente dentro de una subcategoría de aprendizaje de reglas de asociación o minería de reglas de asociación. Se le considera una técnica no supervisada porque analiza datos transaccionales, sin etiquetas, para descubrir relaciones y patrones entre los mismos sin una variable objetivo. El objetivo del algoritmo es generar reglas de asociación a partir de los patrones frecuentes encontrados en los datos. Por ejemplo, en el caso de preeclampsia, no se busca predecir una clase, sino descubrir combinaciones de síntomas o factores de riesgo que ocurren juntos con frecuencia (Agrawal & Srikant, 1994).

El objetivo de APRIORI es identificar reglas que cumplen con tres métricas principales:

- **Soporte (Support):** Para establecer la frecuencia con la que aparece una combinación de elementos en el conjunto de datos.
- **Confianza (Confidence):** Para determinar si, cuando el antecedente de una regla es verdadero, el consecuente también lo es.
- **Lift (Elevación):** Para determinar el grado de dependencia entre el antecedente y el consecuente en una regla, y así evitar asociar elementos por casualidad.

Para una regla de asociación del tipo $A \Rightarrow B$, por ejemplo $\{MAP\ alto\} \Rightarrow \{Proteinuria\}$; MAP alto implica presencia excesiva de proteínas en la orina. El soporte se calcula como la popularidad del conjunto de elementos $(A \cup B)$ como una proporción del total de elementos N (ej. Pacientes).

$$Soporte(A \cup B) = \frac{\text{Número de pacientes con } A \text{ y } B}{\text{Total de paciente } (N)}$$

La fiabilidad de la regla, para establecer su confianza (¿De todos los pacientes que tienen A, cuántos también tienen B?) se mide:

$$Confianza(A \Rightarrow B) = \frac{Soporte(A \cup B)}{Soporte(A)}$$

Por último, el lift (elevación) que mide el aumento de la probabilidad de B dado A, en comparación con la probabilidad de B de forma aislada:

$$Lift(A \Rightarrow B) = \frac{Confianza(A \Rightarrow B)}{Soporte(B)} = \frac{Soporte(A \cup B)}{Soporte(A) \times Soporte(B)}$$

Si el $Lift > 1$, indica que existe una asociación positiva, y en consecuencia la regla es útil. $Lift = 1$ indica que los elementos A y B son independientes. Finalmente, un $Lift < 1$ indica una asociación negativa; es decir, la presencia de A disminuye la probabilidad de B.

El algoritmo itera en fases, construyendo conjuntos de elementos de 1, 2, ..., N elementos, y utiliza la propiedad Apriori para reducir el espacio de búsqueda. Si un conjunto de $eLift < 1$ elementos es frecuente, entonces todos sus subconjuntos también lo son. En contraposición, si un subconjunto es infrecuente, cualquier superconjunto que lo contenga también lo es y puede ser descartado. El algoritmo requiere, como entrada, los umbrales mínimos de Soporte y Confianza para eliminar subconjuntos. A continuación, se describe el algoritmo de forma simplificada, el cual se construye en dos fases:

Fase 1: Generación de Subconjuntos de Elementos Frecuentes

1. Subconjuntos de 1-elemento (L_1): Se cuenta la frecuencia de cada elemento, y se eliminan los elementos cuyo soporte esté por debajo del umbral de soporte mínimo. Los restantes forman el conjunto L_1 .
2. Paso k : Subconjuntos de k -elementos (L_k):
 - a. Se combinan subconjuntos frecuentes de tamaño $k - 1$ para crear nuevos subconjuntos candidatos de tamaño k (C_k).
 - b. Se descarta cualquier candidato en C_k que contenga un subconjunto infrecuente de tamaño $k - 1$ (propiedad Apriori).
 - c. Se cuenta la frecuencia de los elementos restantes en los datos.
 - d. Se eliminan aquellos elementos que caen debajo del umbral de soporte mínimo. El resto forma el subconjunto L_k para la siguiente iteración.
3. Se repite el proceso hasta que no se encuentran nuevos subconjuntos frecuentes.

Fase 2: Generación de Reglas de Asociación

En la fase 2 se generan las reglas de asociación a partir de los subconjuntos de elementos frecuentes.

1. Para cada subconjunto frecuente L (ej. $\{A, B, C\}$), se generan todas las posibles reglas no vacías (ej. $A \Rightarrow \{B, C\}$; $\{A, C\} \Rightarrow B$, etc.)
2. Se calcula la confianza para cada regla y se desechan aquellas reglas cuya confianza cae por debajo del umbral de confianza mínimo establecido.
3. Finalmente, se calcula el Lift para las reglas restantes, para determinar su poder predictivo.

Continuando con nuestro ejemplo de preeclampsia, supongamos que tenemos el siguiente conjunto de datos observado en la Tabla 2.1.5, y que los umbrales para el Soporte Mínimo y la Confianza Mínima son 30% y 80% respectivamente.

Tabla 2.1.5 Ejemplo de conjunto de datos transaccional para algoritmo APRIORI.

Paciente	MAP	IMC	Proteinuria	Resultado
P1	Alta	Baja	Sí	Preeclampsia
P2	Alta	Baja	No	Preeclampsia
P3	Baja	Alta	Sí	No Preeclampsia
P4	Alta	Alta	Sí	Preeclampsia
P5	Alta	Alta	Sí	Preeclampsia
P6	Baja	Baja	No	No Preeclampsia
P7	Alta	Alta	Sí	Preeclampsia
P8	Baja	Alta	No	No Preeclampsia
Total				$N = 8$

Primeramente, encontramos los subconjuntos frecuentes de 1 elemento (L_1):

- $\{\text{MAP Alta}\}$: Frecuencia 5, soporte $5/8 = 62.5\%$ (Frecuente)
- $\{\text{Proteinuria Sí}\}$: Frecuencia 5, soporte $= 62.5\%$ (Frecuente)
- $\{\text{IMC Alta}\}$: Frecuencia 5, soporte: 62.5% (Frecuente), etc.

Se buscan combinaciones de los elementos frecuentes anteriores para generar subconjuntos de 2 elementos (L_2):

- $\{\text{MAP Alta, Proteinuria Sí}\}$: Frecuencia 4, soporte $4/8 = 50\%$.
- $\{\text{MAP Alta, IMC Alta}\}$: Frecuencia 3, soporte $3/8 = 37.5\%$.
- $\{\text{IMC Alta, Proteinuria Sí}\}$: Frecuencia 4, soporte $= 50\%$.

Generamos ahora reglas de asociación en base a nuestro ejemplo; tomemos un subconjunto frecuente $\{\text{MAP Alta, Proteinuria Sí}\}$ con soporte de 50%:

Regla 1: $\{\text{MAP Alta}\} \Rightarrow \{\text{Proteinuria Sí}\}$

- $\text{Confianza} = \frac{\text{Soporte}(\text{MAP Alta, Proteinuria Sí})}{\text{Soporte}(\text{MAP Alta})} = \frac{50\%}{62.5\%} = 80\%$, esta es una regla fuerte ya que su nivel de confianza satisface el umbral establecido.
- $\text{Lift} = \frac{80\%}{\text{Soporte}(\text{Proteinuria Sí})} = \frac{80\%}{62.5\%} = 1.28$, ya que el Lift > 1 entonces la asociación es real.

El análisis anterior permite generar la interpretación de que los pacientes con MAP Alta tienen un 28% más de probabilidades de tener Proteinuria que un paciente promedio.

2.1.2.3 Reducción de Dimensionalidad

Las técnicas de reducción de dimensionalidad transforman datos de alta dimensión en representaciones de menor dimensión; es decir, simplifican los datos de entrada al eliminar características o atributos, mientras se conserva información relevante. Al eliminar atributos, los procesos de aprendizaje pueden ser más eficientes y efectivos, mitigando el famoso problema de la maldición de la dimensionalidad (*the curse of dimensionality*), que impacta a ciertos algoritmos en espacios de alta dimensión.

PCA es un algoritmo versátil de aprendizaje automático no supervisado, comúnmente utilizado para reducción de dimensionalidad. El algoritmo encuentra nuevas variables no correlacionadas (componentes principales) que capturan la mayor varianza en el conjunto de datos. De esta manera, simplifica datos complejos conservando información esencial. Por ejemplo, en el caso de preeclampsia, hipotéticamente permitiría reducir docenas de datos de biomarcadores y mediciones a solo dos o tres Componentes Principales que representen las dimensiones clave de riesgo, facilitando la visualización y el modelado.

El objetivo de PCA no es agrupar ni predecir, sino encontrar un nuevo conjunto de dimensiones K (llamadas Componentes Principales) que sean ortogonales (no correlacionadas) y que capturen la máxima varianza posible de los datos originales, ya que los componentes con mayor varianza contienen la mayor parte de información y estructura de los datos.

El procedimiento del PCA considera lo siguiente:

1. Dada que la métrica de varianza es sensible a la escala de los datos, estos deben estandarizarse para que todas las características contribuyan por igual. Por lo tanto, se transforma cada punto $x_{i,j}$ restando la media μ_j y dividiendo por la desviación estándar σ_j de la característica j :

$$x'_{i,j} = \frac{x_{i,j} - \mu_j}{\sigma_j}$$

2. Se calcula la Matriz de Covarianza (Σ), la cual para un conjunto de datos con N características es una matriz de $N \times N$. Los valores de la diagonal representan la varianza de cada característica, mientras los valores fuera de ella representan la covarianza entre dos características para m observaciones:

$$\Sigma = \frac{1}{m-1} (X')^T X'$$

3. Se calculan los vectores propios $\mathbf{v}$ que definen la dirección de cada Componente Principal en el espacio de características original, y los valores propios λ (*Eigendecomposition*) que miden la magnitud de la varianza a lo largo de cada Componente Principal. Cuanto mayor sea el valor propio, más importante es ese componente. Se obtienen N pares de $(\lambda_k, \mathbf{v}_k)$:

$$\Sigma \mathbf{v} = \lambda \mathbf{v}$$

4. Se ordenan los Componentes Principales y se seleccionan K componentes. Este número se determina típicamente eligiendo los K componentes que acumulan un porcentaje predefinido de la varianza total, la cual es la suma de todos los valores propios $\sum_{k=1}^N \lambda_k$.

5. Se proyectan los datos creando una matriz de proyección (W) utilizando los K vectores propios seleccionados, y se multiplican los datos estandarizados originales por esta matriz para obtener los datos transformados.

$$Z = X'W$$

Z es el nuevo conjunto de datos de dimensión reducida, donde cada columna es un Componente Principal. PCA se utiliza a menudo como un paso preliminar antes de aplicar algoritmos de aprendizaje automático, ya que al reducir el número de atributos se mejora la eficiencia computacional para construir los modelos de aprendizaje y se remueve ruido de los datos.

2.1.3 Aprendizaje por Refuerzo

El aprendizaje por refuerzo (*Reinforcement Learning*) es un tipo de aprendizaje automático que se caracteriza por agentes aprendiendo a través de la interacción con su entorno o ambiente mediante procesos de prueba y error. El agente puede recibir premios o castigos por sus acciones, y su objetivo consiste en maximizar la recompensa total a largo plazo, permitiéndole identificar la política óptima de comportamiento.

La entrada al proceso de aprendizaje por refuerzo no es un subconjunto de datos, como lo es en el caso de aprendizaje supervisado y no supervisado, sino un modelo que representa el estado (*state*) del ambiente. El agente interactúa con el ambiente tomando una acción basada en el estado actual en el que se encuentra. En respuesta a la acción, el ambiente retroalimenta al agente con una recompensa (positiva o negativa) que indica el desempeño de la acción, y un nuevo estado, que representa las condiciones de cambio en el ambiente una vez que la acción se ha tomado.

El ciclo continuo de retroalimentación de estado, acción y recompensa le permite al agente aprender a desarrollar una política (*policy*); es decir, una estrategia para seleccionar acciones que maximicen la acumulación de recompensas a través del tiempo.

Las técnicas de aprendizaje por refuerzo se agrupan típicamente en tres categorías principales, las cuales se relacionan a cómo el agente aprende y representa su conocimiento sobre el ambiente. Estas categorías no son mutuamente excluyentes, ya que algunos algoritmos avanzados combinan elementos de las mismas.

1. **Métodos basados en valor (*Value-based*) vs. basados en políticas (*Policy-Based*):** Los métodos basados en valor se enfocan en aprender una función de valor que estime la recompensa acumulada para un estado dado. El agente deriva su política de esta función, típicamente al seleccionar la acción que conduce al valor estimado más alto. Los métodos basados en políticas ignoran la función de valor y aprenden directamente una política que relaciona estados con acciones. Esta política es generalmente una función que genera una distribución de probabilidad sobre las posibles acciones. El objetivo del agente es ajustar los parámetros de la política para maximizar la recompensa esperada.
2. **Métodos basados en Modelos (*Model-based*) vs. Sin Modelos (*Model-free*):** En los métodos basados en modelos, el agente aprende un modelo del ambiente; es decir, una representación de cómo el ambiente funciona a través de simular resultados futuros de sus acciones sin necesidad de interactuar directamente con el ambiente. En el otro caso, el agente aprende directamente de sus interacciones con el ambiente a través de prueba y error sin construir un modelo explícito del mismo.
3. **Métodos On-Policy vs Off-Policy:** En métodos On-Policy, el agente aprende a través de mejorar la misma política que está utilizando para interactuar con el ambiente. Evalúa sus acciones a través de los datos recolectados bajo la política actual. En el caso contrario, el agente aprende observando las acciones de una política diferente, la cual puede ser una versión previa de la que utiliza actualmente o de un agente diferente.

2.1.4 Entrenamiento y Validación de Modelos

El proceso para entrenar y validar modelos de aprendizaje automático (*Machine Learning*) es un ciclo estandarizado conocido como Flujo de Trabajo de ML. Este flujo o *workflow* busca asegurar que los modelos no solamente aprendan de los datos, sino que también se generalicen a nuevos datos nunca antes vistos. El flujo de trabajo considera los siguientes pasos:

1. **Recolección y preparación de datos:** Esta fase se relaciona con el pre-procesamiento de los datos, que puede incluir la limpieza de los mismos (manejar ruido, corregir errores de entrada y valores faltantes, y datos atípicos u *outliers*). Además, puede incluir la generación de nuevas características que sean más útiles (*feature engineering*), como, por ejemplo, agrupar la edad de pacientes en categorías. También, dependiendo del tipo de modelos a desarrollar, puede ser importante normalizar o escalar los datos para que tengan rangos similares.
2. **Entrenamiento y validación:** El proceso estándar para el entrenamiento y validación de modelos de aprendizaje automático se conoce como Validación Cruzada, el cual proporciona estimaciones robustas del rendimiento de un modelo al dividir los datos en múltiples conjuntos para entrenamiento y prueba (*Train & Test*). La validación cruzada K-Fold divide los datos en k subconjuntos iguales, entrena al modelo en $k-1$ subconjuntos y prueba en el restante, rotando por todos los subconjuntos. En esta fase también se optimizan hiperparámetros, por ejemplo, el valor de K en el algoritmo de K-NN, de ser necesario.
3. **Evaluación del Modelo:** Una vez que el modelo está entrenado, se evalúa su rendimiento utilizando métricas de desempeño relevantes en un conjunto de prueba nunca antes visto. Existen diferentes métricas de desempeño dependiendo del tipo de modelo a evaluar. Por ejemplo, para modelos de regresión se puede utilizar el error cuadrático medio (MSE), mientras que para tareas de clasificación la exactitud, precisión, *recall* y *F1-Score* son algunas de las métricas más utilizadas.
4. **Interpretación, despliegue y monitoreo:** Finalmente, se analizan los resultados de los modelos. Si los rendimientos son satisfactorios, el modelo se integra a un sistema en tiempo real, donde puede recibir nuevos datos, generando nuevas predicciones o clasificaciones.

Es importante resaltar que este proceso enfrenta desafíos y ciertas consideraciones clave. Por ejemplo, la introducción de sesgo en los datos, la varianza y el desbalance de los mismos. Además, el proceso de entrenamiento puede generar sobreajuste (*overfitting*), el cual se produce cuando el modelo se ajusta muy bien a los datos de entrenamiento, pero tiene un mal rendimiento en datos nunca vistos; es decir, no se generaliza correctamente. O, en el extremo opuesto, puede producir subajuste (*underfitting*), cuando el modelo es demasiado simple para capturar los patrones subyacentes en la información.

Los algoritmos de aprendizaje automático siguen evolucionando, con avances recientes significativos en áreas como el aprendizaje profundo y el aprendizaje por refuerzo. A medida que estas técnicas maduran y los recursos computacionales se expanden, se espera que los sistemas de IA aborden problemas cada vez más complejos con mayor autonomía y eficacia. Los principios fundamentales cubiertos en esta sección—enfoques de aprendizaje supervisado y no supervisado—forman la base sobre la cual se construyen estos avances. Comprender estos conceptos básicos proporciona el contexto necesario para explorar algoritmos y técnicas más sofisticadas a medida que surgen.


2.2 Redes Neuronales y Aprendizaje Profundo (Deep Learning)

Las redes neuronales clásicas, como los perceptrones multicapa (MLP), son adecuadas para datos tabulares. Sin embargo, su eficacia está limitada por problemas como el desvanecimiento del gradiente y la dificultad para generalizar con datos complejos.

2.2.2 Aprendizaje Profundo (Deep Learning)

El aprendizaje profundo es una subárea del aprendizaje automático que se basa en el uso de redes neuronales artificiales con múltiples capas (redes neuronales profundas). Estas arquitecturas permiten modelar relaciones complejas y no lineales en datos de alta dimensión, como imágenes, señales y texto. Su éxito ha sido impulsado por el aumento de datos disponibles, la capacidad computacional y las mejoras en los algoritmos. La Figura 2.2.1 muestra un ejemplo de una red neuronal multicapa que requiere aprendizaje profundo.

Figura 2.2.1 Red neuronal multicapa que requiere aprendizaje profundo



De manera general, las redes neuronales consisten en capas de neuronas artificiales interconectadas, capaces de aproximar funciones complejas.

Una red neuronal *feedforward* sencilla puede representarse como:

$$fa(x) = \frac{1}{(1 + \exp(-x))}$$
$$L_{l,m} = fa\left(\sum_{i=1}^{l-1} w_{l,n,i} L_{l-1,i} + b_l\right)$$

Donde $fa(x)$ es la función de activación de las capas, que usualmente es una función sigmoideal, L representa la respuesta de las neuronas de la capa l que corresponde a las entradas para la capa posterior, y w representa los pesos de la capa actual l . La red neuronal es más eficiente cuando se utiliza una entrada extra b conocida como polaridad.

Estas redes se entrenan mediante **retropropagación** (*backpropagation*), que aplica la regla de la cadena para calcular los gradientes del error respecto a los parámetros representados por los pesos w .

Las Redes Neuronales Convolucionales (CNNs) están diseñadas para tareas de procesamiento de imágenes. En un sistema de clasificación de lesiones cutáneas, una CNN podría incluir:

- Capas convolucionales que aplican filtros para detectar características en diferentes escalas.
- Capas de agrupamiento (*pooling*) que reducen la dimensionalidad.
- Capas completamente conectadas que realizan la clasificación final.

La red aprende representaciones jerárquicas, desde bordes simples hasta patrones complejos como asimetrías o bordes irregulares, que indican lesiones malignas.

2.2.3 Redes Neuronales Convolucionales (CNN)

Las CNN fueron introducidas para el procesamiento de imágenes (LeNet, 1998) y emplean filtros convolucionales para extraer características espaciales locales. Han evolucionado hacia arquitecturas más profundas y eficientes como VGG, ResNet y EfficientNet. Son aplicables no solo en 2D, sino también en:

- **1D-CNN:** para series temporales y señales (como ECG o audio).
- **3D-CNN:** para análisis volumétrico (como MRI o TAC tridimensional).

2.2.4 Redes Neuronales Recurrentes (RNN)

Las RNN están diseñadas para secuencias temporales. Sus variantes, como LSTM y GRU, abordan limitaciones de memoria a largo plazo y son muy usadas en señales médicas como EEG y registros cardíacos.


2.2.5 Modelos Basados en Atención y Transformadores

Propuestos inicialmente en Procesamiento de Lenguaje Natural (NLP) con "Attention Is All You Need" (Vaswani et al., 2017), utilizan mecanismos de autoatención que permiten aprender relaciones globales en datos secuenciales sin recurrencia. Se han adaptado para visión con modelos como Vision Transformer (ViT), Swin Transformer, y variantes híbridas CNN+Transformer. Sus beneficios incluyen escalabilidad, paralelización y atención a características clave.

Arquitecturas Híbridas

Estas arquitecturas combinan CNNs y Transformadores para aprovechar lo mejor de ambos mundos (ejemplos: CoAtNet, ConvNeXt). Son usadas en contextos donde se requiere tanto la extracción local como el análisis de relaciones globales.

Figura 2.2.2 Una red neuronal de aprendizaje profundo se divide en dos bloques: La parte de convolución que usualmente es preentrenado y la parte de aplicación que se entrena dependiendo de la aplicación.



Convolución 1D: Definición y Usos

La 1D-CNN realiza convoluciones sobre vectores, capturando patrones en series temporales o señales. Se aplica en:

- Diagnóstico cardíaco a partir de señales de ECG.
- Análisis de señales cerebrales EEG para epilepsia o trastornos del sueño.
- Monitorización remota de pacientes con sensores.

Transformadores en Aprendizaje Profundo

Superan a los modelos tradicionales en varias tareas al capturar relaciones de largo alcance y se adaptan a múltiples dominios:

- ViT para imágenes médicas.
- BioBERT y Med-BERT para procesamiento de texto clínico.
- TransUNet para segmentación de imágenes anatómicas.

Aplicaciones en Medicina

La Tabla 2.2.1 muestra ejemplos de las diversas aplicaciones del aprendizaje profundo en medicina.

Tabla 2.2.1 Aplicaciones de redes neuronales en Medicina

Técnica	Aplicación Médica
CNN (2D/3D)	Clasificación de tumores, detección de neumonía, segmentación de órganos.
1D-CNN	Diagnóstico de arritmias a partir de ECG, análisis de respiración y voz.

RNN / LSTM	Modelado de series temporales médicas (monitorización ICU, predicción de evolución).
Transformers (ViT)	Diagnóstico automatizado en radiología, histopatología, clasificación de imágenes.
BERT / BioBERT	Análisis de notas clínicas, extracción de síntomas y eventos adversos.
Modelos híbridos	Segmentación multiescala de imágenes médicas, diagnóstico multimodal.

2.2.6 Desafíos y Futuro

Uno de los principales desafíos en la aplicación de técnicas de aprendizaje profundo en medicina es el manejo adecuado de la privacidad y la ética en el uso de datos clínicos. Los modelos requieren grandes volúmenes de información sensible, lo que plantea preocupaciones sobre la anonimización, el consentimiento informado y la protección contra accesos no autorizados. Además, la explicabilidad del modelo, conocida como *Explainable AI (XAI)*, es crucial para generar confianza en los profesionales de la salud, quienes necesitan comprender cómo y por qué un sistema automatizado llega a determinadas conclusiones diagnósticas. Finalmente, existe el reto de la integración efectiva en entornos clínicos reales, donde los sistemas deben ser interoperables, confiables y ajustarse a los flujos de trabajo existentes sin interrumpir la atención médica ni sobrecargar al personal. Estos aspectos son fundamentales para una adopción ética y segura de la inteligencia artificial en medicina.

El futuro de la inteligencia artificial en medicina se perfila hacia el desarrollo de modelos multimodales que integran diversas fuentes de información, como imágenes médicas, textos clínicos y señales fisiológicas, lo que permitirá diagnósticos más completos y contextualmente informados. Paralelamente, se espera una mayor adopción de modelos federados, que permiten el entrenamiento de algoritmos personalizados directamente en dispositivos locales o instituciones médicas sin necesidad de compartir datos sensibles, favoreciendo tanto la privacidad como la precisión individualizada. Además, la IA tendrá un papel cada vez más destacado en áreas como el diagnóstico preventivo, la cirugía asistida por robots inteligentes y la medicina personalizada, contribuyendo a tratamientos más tempranos, seguros y adaptados a las características únicas de cada paciente. Estas innovaciones apuntan a una transformación profunda del sistema de salud hacia una atención más proactiva, eficiente y centrada en el paciente.

El aprendizaje profundo ha transformado el análisis de datos en medicina. Desde CNNs que analizan imágenes radiológicas hasta transformadores que comprenden registros clínicos, estas técnicas permiten diagnósticos más rápidos, precisos y accesibles. Su integración cuidadosa promete avances sustanciales en la salud global.

Tabla 2.2.2 Resumen de modelos de redes neuronales en Medicina

Técnica	Descripción Breve	Aplicaciones en Medicina
CNN (Redes Convolucionales)	Redes con filtros que detectan patrones espaciales en imágenes o señales.	Diagnóstico por imágenes (radiografías, resonancias), detección de tumores, segmentación de órganos.
1D-CNN (Convolución 1D)	Convolución aplicada a señales unidimensionales o series temporales.	Análisis de ECG y EEG, detección de arritmias, respiración anormal, seguimiento de voz.

RNN / LSTM / GRU	Redes diseñadas para secuencias, con memoria a corto y largo plazo.	Predicción de evolución clínica, análisis de series temporales en UCI, monitoreo continuo.
Transformadores (ViT)	Modelo basado en atención que captura relaciones globales en datos visuales.	Clasificación de imágenes médicas, diagnóstico de cáncer, histopatología digital.
BERT / BioBERT / Med-BERT	Transformadores preentrenados en lenguaje médico.	Análisis de textos clínicos, extracción de síntomas, codificación automatizada, soporte a decisiones clínicas.
Modelos híbridos (CNN + Transformer)	Combinación de atención global con extracción local de características.	Segmentación médica precisa, análisis multimodal (imagen + texto), clasificación avanzada.

2.3 Procesamiento de Lenguaje Natural (NLP) en Salud

Un lenguaje de programación, como Python, es un lenguaje formal; es decir, un conjunto de palabras con un alfabeto, vocabulario, estructura y significado bien definidos. Otro ejemplo de este tipo de lenguaje es la lógica de primer orden. En un lenguaje formal, cada enunciado es claro y tiene un significado único.

A diferencia de los lenguajes formales, el lenguaje natural —si bien también consiste en alfabeto, vocabulario, estructura y significado— depende del contexto, y puede contener ambigüedades e imprecisiones; también puede ser interpretado de manera subjetiva y cambiar con el paso del tiempo. Por tanto, para una máquina, resulta más desafiante trabajar con este tipo de lenguaje.

El Procesamiento de Lenguaje Natural (NLP, por sus siglas en inglés) es el área de la Inteligencia Artificial encargada del entendimiento y la generación de lenguaje natural. Los algoritmos de NLP contribuyen, en parte, a una comunicación más fluida con los seres humanos, como en el caso de los agentes conversacionales (*chatbots*); a su vez, apoyan tareas de aprendizaje automático mediante la extracción de información de textos manuales o grabaciones; y ayudan a una mejor comprensión del lenguaje en sí (Russell & Norvig, 2021).

En general, las tareas del NLP se dividen en tareas de entendimiento y tareas de generación. Mientras que el primer tipo de tarea se basa en reconocer diferentes elementos y estructuras en un texto, el segundo tipo se enfoca en producir lenguaje natural. Un ejemplo de entendimiento sería reconocer los verbos en una oración, o clasificar un texto como positivo o negativo; un ejemplo de generación consistiría, más bien, en seguir una conversación o dar respuesta a una pregunta. A continuación, se mencionan algunas de las tareas más representativas para cada tipo (esta lista no es exhaustiva):

- **Entendimiento de lenguaje natural**

- **Reconocimiento de voz.** Consiste en pasar de lenguaje oral (audio) a lenguaje escrito (texto).
- **Extracción y recuperación de información.** Mientras que la extracción de información consiste en identificar elementos importantes dentro de un texto, la recuperación de información consiste en obtener documentos que sean relevantes de acuerdo con una consulta (*query*). Dentro de la extracción de información, la extracción de entidades nombradas (NER, por sus siglas en inglés) consiste en identificar nombres, lugares y organizaciones.

- **Análisis de sentimiento.** También conocida como minería de opinión, esta tarea se subdivide en otras, a saber: determinar si un texto es objetivo (neutral) o subjetivo (opinión); determinar la polaridad de un texto (positiva o negativa); determinar aspectos en una opinión (por ejemplo, en una reseña de un producto, poder identificar qué parte del producto gustó o no gustó).

- **Generación de lenguaje natural**

- **Generación automática de resúmenes.** Consiste en sintetizar un texto, ya sea por medio de extracción (copiar directamente las oraciones más importantes) o paráfrasis (interpretar el texto y producir una versión más concisa).
- **Traducción automática.** Consiste en pasar texto de un lenguaje a otro. En ocasiones, se apoya en un lenguaje intermedio para hacer la traducción del lenguaje fuente al lenguaje objetivo.
- **Procesamiento de voz.** Incluye el mejoramiento del discurso y la contestación de preguntas de manera oral.
- **Agentes conversacionales e IA generativa.** Se refiere a *software* que es capaz de contestar preguntas y requisiciones (*prompts*). Para ello, debe tener la capacidad de identificar el contexto de la pregunta y recordar lo anteriormente dicho en la conversación. Esto incluye tareas como la resolución de anáforas y referencias, el reconocimiento de nombres propios y la generación de texto con base en probabilidades.

El procesamiento de lenguaje natural no puede verse de manera aislada, pues se relaciona con otras áreas, ya sea de manera directa o transversal. Algunas de estas son:

- **Aprendizaje automático.** Los modelos de aprendizaje apoyan a las diferentes tareas de NLP —por ejemplo, mediante la predicción de la siguiente palabra en un texto, o mediante la clasificación de emociones. También ayudan cuando la tarea es tan compleja que no puede resolverse mediante reglas lingüísticas obtenidas de manera manual. Los modelos de aprendizaje, a su vez, se apoyan en técnicas de NLP. Por ejemplo, las técnicas de preprocesamiento ayudan a limpiar y filtrar los datos antes de generar un modelo de aprendizaje.
- **Lingüística.** Debido a que la lingüística estudia el lenguaje, está intrínsecamente relacionada con el procesamiento de lenguaje natural. Por ejemplo, las técnicas clásicas de NLP, al estar basadas en reglas gramaticales, reciben un fundamento sólido por parte de esta área. También existen áreas interdisciplinarias relacionadas, como la lingüística computacional.
- **Psicología cognitiva.** Al ser el lenguaje un proceso mental, la psicología cognitiva también impacta el procesamiento de lenguaje natural. Por ejemplo, es posible evaluar la usabilidad de agentes conversacionales (como ChatGPT o Copilot) bajo esta perspectiva.
- **Neurociencia.** Debido a que el lenguaje es una capacidad mental, la neurociencia contribuye a un mejor entendimiento del mismo. Por esta razón, las técnicas de NLP se enriquecen con los descubrimientos de la neurociencia.

Las técnicas de procesamiento de lenguaje natural pueden dividirse principalmente en tres generaciones:

1. Primera generación: Técnicas basadas en lingüística.
2. Segunda generación: Técnicas basadas en estadística y aprendizaje automático.
3. Tercera generación: Técnicas basadas en aprendizaje profundo.

A continuación, se describe brevemente cada una de estas generaciones, junto con algunas de las técnicas más significativas.

2.3.1 Técnicas Basadas en Lingüística

La primera generación de técnicas está basada en reglas gramaticales. La Tabla 2.3.1, por ejemplo, muestra una gramática libre de contexto para reconocer una oración simple. El proceso de reconocimiento generalmente se hace mediante un árbol sintáctico, es decir, mediante una estructura jerárquica que va identificando los diferentes componentes de la oración. La Figura 2.3.1 muestra un árbol sintáctico para la oración “El perro corre”.

Tabla 2.3.1 Ejemplo de gramática libre de contexto (seis reglas)

Regla	Descripción
R1. Oración $\rightarrow$ SN SV	Una oración se compone de un sintagma nominal (SN) seguido de un sintagma verbal (SV).
R2. SN $\rightarrow$ Det N	Un sintagma nominal se compone de un determinante (Det) seguido de un nombre (N).
R3. SV $\rightarrow$ V	Un sintagma verbal se compone de un verbo (V).
R4. Det $\rightarrow$ "El" "La" "Los" "Una"	Determinantes posibles
R5. N $\rightarrow$ "gato" "niña" "niños"	Nombres posibles
R6. V $\rightarrow$ "duerme" "canta" "juegan"	Verbos posibles

Esta gramática permite reconocer oraciones como "El gato duerme", "Una niña canta" o "Los niños juegan".

Fig. 2.3.1 Ejemplo de árbol sintáctico

```

Oración (O)
/  \
Sintagma Nominal (SN) Sintagma Verbal (SV)
/  \  |
Determinante Nombre Verbo
|    |    |

```

El perro corre

Otra herramienta clásica en el procesamiento de lenguaje natural es la de expresiones regulares. Una expresión regular representa un patrón de texto, es decir, engloba palabras que cumplen con ciertas características en particular. Por ejemplo, la expresión ab^+ denota una "a" seguida de —al menos— una "b". De esta manera, podrían reconocerse patrones como ab , abb , $abbb$, $abbbbbbb$, etc. Por ejemplo, en las redes sociales, los usuarios tienden a escribir variantes de la interjección "ah" (como "ahh" o "ahhhhh") para denotar diferentes intensidades emocionales. Estas variantes podrían reconocerse con la expresión regular ah^+ . Otro ejemplo viene dado por la expresión $[Mm]edicina$, que engloba las palabras "Medicina" y "medicina".

Las expresiones regulares, por lo tanto, pueden ser utilizadas para tareas como la búsqueda de coincidencias o la contestación de preguntas. El *chatbot* ELIZA, uno de los pioneros en esta área, utiliza expresiones regulares para sostener una conversación. En la Tabla 2.3.2, se muestra un ejemplo, basado en el texto de Jurafsky & Martin (2025).

Tabla 2.3.2 Ejemplos de respuestas en el sistema ELIZA

Expresión	Ejemplo	Contestación ELIZA
*[Ee]stoy (deprimid[oa] triste) *	<i>Estoy triste.</i>	Lamento escuchar eso.
* todos *	<i>Todos son unos mentirosos.</i>	¿En qué sentido?

Si bien las expresiones regulares aquí mencionadas son simples por propósitos didácticos, existen expresiones más complejas con diferentes tipos de operadores (ver ejemplos en la Tabla 2.3.3), que pueden incluso reconocer la estructura de un documento —una página web, por ejemplo—. A pesar de tener esta capacidad, las expresiones regulares también tienen sus límites, ya que solamente pueden reconocer lenguajes regulares, que son lenguajes considerablemente más simples que el lenguaje natural. En el sentido práctico, también son rígidas, pues el texto o cumple o no cumple con la expresión (no existe un término medio). Lo anterior es benéfico para ciertas aplicaciones (como en ciberseguridad para verificar contraseñas), pero para otras —como el procesamiento de lenguaje natural—, resulta ser una desventaja.

Tabla 2.3.3 Ejemplos de operadores en expresiones regulares

Operador	Nombre	Ejemplo expresión	Significado
	Disyunción	$a b$	Acepta una "a" o una "b"
*	Repetición	a^*b	Acepta cero o más "a" seguida de una "b"
[]	Agrupamiento	$[a b]c$	Acepta una "a" o una "b" seguida de una "c"
^	Negación	a	Acepta cualquier símbolo, excepto "a"

En general, las técnicas clásicas incurren en costos considerables al producir reglas lingüísticas de manera manual, pues esta tarea requiere experiencia, tiempo y esfuerzo. Por otro lado, las bases de reglas generadas resultan rígidas en diferentes contextos, donde más bien se buscan coincidencias aproximadas o existe un gran número de excepciones.

2.3.2 Técnicas Basadas en Estadística y Aprendizaje Automático

Una segunda generación de técnicas de NLP se fundamenta en conceptos estadísticos, como frecuencias, probabilidades, estadística bayesiana y recuperación de modelos, entre otras. Dentro de estas técnicas, también se contempla el uso de aprendizaje automático para abordar diferentes tareas relacionadas con el lenguaje natural, como la clasificación de textos.

Para las técnicas basadas en estadística y aprendizaje, una cuestión relevante es cómo representar texto en términos numéricos. Una de las representaciones más populares de esta segunda generación es el modelo de espacio vectorial (Baeza-Yates & Ribeiro-Neto, 1999), donde se construye una matriz *documento-palabra* de para la colección de documentos a procesar, donde N es la cantidad de documentos en la colección y M es la cantidad de palabras. El contenido de cada celda comúnmente se obtiene mediante la técnica *term frequency-inverse document frequency* (TF-IDF, por sus siglas en inglés).

La técnica de TF-IDF calcula una ponderación para cada palabra en un documento de la colección de acuerdo con dos factores: (1) la frecuencia normalizada de w y (2) la frecuencia inversa de w en la colección de documentos (denotada por C). Supongamos, por ejemplo, que tenemos tres documentos (descritos en la Tabla 2.3.4) y deseamos calcular el TF-IDF de la palabra "gato" en el documento d_1 . En este caso, $TF(gato, d_1) = 1/4 = 0.25$; $IDF(gato) = \log_{10}(3/2) = 0.176$; y $TFIDF(gato, d_1) = 0.25 \cdot 0.176 = 0.044$.

Tabla 2.3.4 Ejemplo de una colección de documentos

Documento	Contenido
d_1	El gato come pescado.
d_2	El perro come carne.
d_3	El gato duerme.

De esta manera, las palabras que son particulares al documento obtienen una mayor ponderación, mientras que las palabras generales (o poco relevantes al documento) obtienen una ponderación menor.

$$[tfidf(d_1, w_1) \cdots tfidf(d_1, w_M) : \vdots : tfidf(d_N, w_1) \cdots tfidf(d_N, w_M)]$$

$$TFIDF(w, d, C) = \left(\frac{f_{w,d}}{\sum_{w \in d} f_{w,d}} \right) \times \log \log \left(\frac{|C|}{|\{d \in C : w \in d\}|} \right)$$

Algunas variantes de esta representación incluyen el uso de n-gramas en lugar de palabras, donde un unigrama se refiere ya sea a una palabra o a un carácter. Por ejemplo, la palabra "gato" se consideraría un unigrama, mientras que la frase "lenguaje natural" se consideraría un bigrama; si lo vemos por caracteres, la palabra "gato" se descompondría por unigramas en "g", "a", "t", "o", y por bigramas se descompondría como "ga", "at", "to". De igual manera, algunos métodos, como el análisis semántico latente (Dumais, 2004) o LSA, por sus siglas en inglés, realizan reducción de dimensiones a la matriz documento-palabra mediante descomposición singular de valores (SVD) para obtener una representación más concisa y significativa, pues al reducir dimensiones se quitan palabras del vocabulario y, al hacer descomposición, se obtiene la información esencial de la colección de documentos.

Otra característica importante de las técnicas estadísticas es el uso de recursos léxicos. Estos recursos han sido generalmente utilizados para calcular probabilidades u obtener información adicional de palabras o frases (de hecho, en la primera generación de técnicas ya se usaban listas de palabras con este segundo propósito). Algunos ejemplos de recursos léxicos incluyen:

- **WordNet** (Miller, 1995). Sentidos de palabras y conceptos.
- **SentiWordNet** (Esuli & Sebastiani, 2007). Polaridad de palabras (positiva o negativa). Similar a WordNet.

- **ANEW** (Bradley & Lang, 1999). Normas afectivas en palabras (placer, excitación, control).
- **Yago** (Suchanek et al., 2007). Base general de conocimiento.

De igual manera, en esta segunda generación de técnicas, se hace uso intensivo de los conjuntos de datos, tales como los de Kaggle (<http://www.kaggle.com>) o los de la Universidad de California en Irvine, también conocidos como UCI data sets (<https://archive.ics.uci.edu/datasets>). Estos conjuntos se dan como entrada a los algoritmos de aprendizaje automático para realizar el entrenamiento de modelos de aprendizaje supervisado (Belcic & Striker, 2024).

El aprendizaje automático supervisado, en esencia, realiza la calibración sucesiva de parámetros (variables) con base en errores cometidos. Estos errores se obtienen mediante el conjunto de entrenamiento. Dentro de las técnicas más conocidas de aprendizaje automático supervisado para NLP, se encuentran las redes neuronales, las máquinas de soporte vectorial, los clasificadores bayesianos y los clasificadores basados en vecinos más cercanos. Una de las tareas principales para las que se han usado estas técnicas es la clasificación de texto —por ejemplo, determinar si un texto es positivo o negativo, o si es correo no deseado, o si es un texto agresivo (y en qué categoría de agresividad cae).

Además de la clasificación de texto, otra tarea con relevancia dentro de esta segunda generación es el etiquetado morfológico (Martínez, 2012), que consiste en identificar cada componente de una oración (sujeto, predicado, verbo, etc.). Como función principal, contribuye al entendimiento del texto. Uno de los algoritmos más populares para llevar a cabo este etiquetado es el Algoritmo Viterbi (Viterbi, 2003), el cual se apoya en modelos ocultos de Markov. De esta manera, se genera una tabla de probabilidades de secuencias de palabras.

2.3.3 Técnicas Basadas en Aprendizaje Profundo

La última generación de algoritmos está basada en el uso de aprendizaje profundo. A diferencia del aprendizaje supervisado convencional, los algoritmos de aprendizaje profundo son aptos para procesar datos no estructurados, tales como imágenes, texto y video. Por otra parte, en varios contextos se han obtenido mejores resultados que estas otras técnicas, sobre todo en el área de NLP. A continuación, se hace un repaso de las principales arquitecturas utilizadas para esta área.

Redes recurrentes y redes LSTM. En una red neuronal simple de "encadenamiento hacia adelante" (*feedforward*), se obtiene una salida a partir de la red. En una red recurrente, a diferencia de la simple, dicha salida se puede tomar como entrada —e incluso este proceso se puede llevar a cabo de manera repetida. De esta forma, la salida se considera para calcular la salida, la para la, y así sucesivamente. Por esta razón, las redes recurrentes han sido en su mayoría utilizadas para la predicción o generación de datos secuenciales, como texto, video, *streaming* o series de tiempo en general.

Si bien las redes recurrentes han ayudado en problemas relacionados con datos secuenciales, una de sus mayores desventajas es que no tienen la capacidad de procesar grandes secuencias; en ese sentido, carecen de una "memoria a largo plazo". Las redes LSTM (*Long Short-Term Memory*), que son un subtipo de red recurrente, precisamente abordan este problema a través del uso de celdas especiales que conservan (o desechan) parte de los datos de entrenamiento (Russell & Norvig, 2021).

Otras arquitecturas profundas. Los autocodificadores (Bank, 2023) son un tipo de red neuronal que sirve para realizar reducción de dimensiones. Lo anterior se hace en dos fases: la codificación y la decodificación. Mientras que en la codificación se aprende una representación reducida de los datos, en la decodificación se asegura que esta representación reducida pueda reconstruir los datos originales con fidelidad. En general, el entrenamiento tiene el objetivo de aprender una representación más concisa. De esta manera, se logra extraer las características más importantes de los datos.

Por otra parte, las redes por convolución evitan la pérdida de dependencias espaciales a través de operaciones con filtros, donde cada filtro puede verse como una plantilla sobre la cual se puede establecer la correspondencia entre el mismo y los datos de entrada. De esta manera, las relaciones entre datos cercanos se conservan, pues quedan establecidas en la correspondencia calculada. Aunque estas redes se han usado

principalmente para el procesamiento de imágenes (con un éxito considerable), también pueden aplicarse para el procesamiento de lenguaje natural.


Incrustaciones de palabras (*word embeddings*). Con el modelo de espacio vectorial, utilizamos una matriz documento-palabra. Con la incrustación de palabras, utilizamos una matriz palabra-palabra. En lugar de realizar conteos y calcular frecuencias, los valores de la matriz se extraen mediante una red neuronal convencional (no profunda). Debido a que la matriz palabra-palabra es generalmente muy extensa, se puede realizar reducción de dimensiones. Por ejemplo, podríamos tener incrustaciones representadas por vectores en 2D (es decir, con solamente dos valores), como las que se presentan en la Tabla 2.3.5. De esta forma, las palabras que son similares quedan cerca dentro del espacio (ver Figura 2.3.2).

Cabe destacar que algunas de las técnicas de incrustación más importantes son word2vec (Mikolov et al., 2013) y GloVe (Pennington et al., 2014). Mientras que la primera se enfoca en predecir el texto circundante a una palabra, la segunda se basa en co-ocurrencias de palabras. Estas técnicas utilizan grandes colecciones de documentos para el entrenamiento, de tal forma que los valores obtenidos terminan representando la cercanía semántica entre las palabras.

Tabla 2.3.5 Ejemplo de una incrustación de palabras

Palabra	Vector	
perro	0.9	0.1
gato	0.85	0.25
carro	0.3	0.9
Bicicleta	0.25	0.8

Fig. 2.3.2 Ejemplo de una incrustación de palabras (gráfica)



Técnicas avanzadas de aprendizaje profundo. En los últimos años, el área de procesamiento de lenguaje natural ha cambiado sustancialmente a raíz de las técnicas avanzadas de aprendizaje profundo. Explicaremos algunas de las más sobresalientes.

Aprendizaje por transferencia. Un concepto importante dentro del área de aprendizaje profundo es el de aprendizaje por transferencia, ya que este hace posible la reutilización de modelos grandes de aprendizaje. Para comprender este tipo de aprendizaje, tomemos en cuenta que las redes neuronales consisten en una

serie de capas donde, por cada capa, se debe calibrar una cantidad de parámetros. Dependiendo de la cantidad de parámetros, este proceso de calibración (llamado entrenamiento) puede ser costoso —tanto en términos de tiempo, energía y recursos físicos (como GPUs). Las redes profundas, por su parte, tienen una cantidad considerable de capas y, por ende, de parámetros para calibrar. Por ejemplo, la red por convolución de AlexNet (Krizhevsky, 2012) contiene 60 millones de parámetros, mientras que ChatGPT contiene 175 mil millones, aproximadamente.

También es importante destacar que las primeras capas de las redes profundas suelen realizar tareas generales. Por ejemplo, en un contexto de reconocimiento de rostros, en las primeras capas de una red por convolución se reconocerían líneas o curvas, mientras que en capas intermedias ya se reconocerían partes del rostro, como ojos o nariz; finalmente, en las últimas capas se reconoce el rostro completo de la persona. En vista de lo anterior, es posible reutilizar estas capas generales (que ya fueron entrenadas para una tarea similar), conectarlas a capas específicas para la tarea que se vaya a realizar y entrenar solamente estas capas específicas. A esto se le conoce como aprendizaje por transferencia.

Mecanismos de atención. En las redes recurrentes y LSTM, debido a que el texto se procesa de manera secuencial, el entrenamiento suele ser lento. Los mecanismos de atención (Vaswani et al., 2017), a diferencia de estas redes, permiten analizar las palabras del texto de manera paralela —y esta es una de las razones por las cuales han marcado un hito dentro del aprendizaje profundo. La otra ventaja de estos mecanismos es que consideran no solamente palabras circundantes o vecinas, sino que consideran todo el conjunto de palabras para determinar la importancia que tienen unas con respecto de otras.

Transformadores. Un transformador es una arquitectura que se apoya en los mecanismos de atención para procesar secuencias. Debido a que el mecanismo de atención permite procesar los elementos de la secuencia en paralelo, los transformadores también son más rápidos que las redes recurrentes. Además, incorporan otras técnicas como la incrustación posicional para poder generar una respuesta coherente y ordenada ante el *prompt* proporcionado. Debido a lo anterior, los transformadores han logrado realizar tareas de NLP con gran éxito, tales como la traducción automática y la respuesta a preguntas. Por esta razón, han marcado un antes y un después dentro del procesamiento de lenguaje natural.

Modelos grandes de lenguaje (Large Language Models - LLM). El uso de transformadores ha permitido la obtención de modelos grandes de lenguaje (LLM, por sus siglas en inglés). Estos modelos se entrenan con cantidades masivas de texto (por ejemplo, el modelo BERT está entrenado sobre la Wikipedia), y se utilizan específicamente para tareas relacionadas con el lenguaje. Además de BERT, otros ejemplos de LLM incluyen LLaMA, Gemini, GPT-4 y Claude.

2.3.4 Aplicaciones

Las técnicas de procesamiento de lenguaje natural, en general, han contribuido a crear sistemas de salud basados en los pacientes. Esto no solo implica un trato directo con el mismo por parte de la tecnología, sino que también abarca el apoyo al personal médico —tanto para realizar sus tareas de manera más fácil y eficiente, como para brindarles entrenamiento y una capacitación accesible en cuanto a sus temas de interés.

Algunas de las principales aplicaciones de las técnicas de NLP en medicina incluyen: (a) asistentes médicos virtuales, (b) análisis de historiales clínicos electrónicos, (c) traducción automática y accesibilidad multilingüe, y (d) investigación biomédica y extracción de conocimiento. A continuación, se describen diferentes trabajos dentro de estas aplicaciones.

Asistentes médicos virtuales

En el contexto médico, los *chatbots* han sido utilizados como asistentes médicos virtuales, valiéndose para ello de las distintas técnicas que hemos mencionado. Dentro del estado del arte, se pueden resaltar tres usos básicos para estos asistentes en el área de medicina: (1) mejorar el diálogo entre pacientes y médicos; (2) atender a los pacientes de manera rápida, asegurando la disponibilidad de atención 24/7, desahogando la

consulta y reduciendo los tiempos de espera para esta —principalmente, a través de la resolución de dudas; y (3) entrenar estudiantes de medicina.

En cuanto a la interacción entre pacientes y médicos, el trabajo de Rose-Davis et al. (2018) propone un sistema de diálogo encaminado a padres de jóvenes con artritis idiopática. Este sistema de diálogo codifica el conocimiento acerca de la enfermedad a través de reglas (específicamente, mediante una ontología en OWL) y emplea un motor de inferencia para resolver las preguntas (en este caso, razonamiento semántico). Por tanto, se apoya en lógica matemática para sostener una conversación con el usuario. De manera similar a este sistema, May et al. (2020) proponen el sistema CLAIRE, que combina realidad virtual e interfaz de voz con un *chatbot*. Este sistema se accede mediante teléfonos inteligentes, y contesta preguntas específicas sobre temas médicos. Algunos trabajos similares presentan técnicas estadísticas y de reconocimiento de patrones para asociar los síntomas indicados por el paciente con posibles enfermedades (Divya et al., 2018; Srivastava & Singh, 2020; Rarhi et al., 2017) e incluyen interfaces de voz a texto y texto a voz (Dharwadkar & Deshpande, 2018).

Con respecto a la resolución de dudas en pacientes, los asistentes virtuales se enfocan en proporcionar conocimiento acerca de enfermedades y tratamientos, evitando así que los pacientes y sus familias se vean abrumados por el volumen de información disponible. En ese sentido, la interacción con un *chatbot* es más sencilla, directa y rápida. El trabajo de Prathwini y Prathyakshini (2024), por ejemplo, propone un *chatbot* para identificar enfermedades, dada la información proporcionada por el usuario. Para realizar la clasificación, se basan en técnicas de aprendizaje automático supervisado. Estos autores reportan un 99.59% de exactitud. A final de cuentas, se busca eficientar el proceso —especialmente en lugares donde la demanda médica es alta, pero se cuenta con poco personal. Por tanto, la interacción con el *chatbot* agiliza el proceso de consulta.

En cuanto al entrenamiento de estudiantes de medicina, los asistentes virtuales han fungido un rol importante dentro de esta tarea. En ese sentido, el trabajo de Yang et al. (2019) propone un sistema de tres módulos para la simulación de pacientes (pacientes virtuales) y la evaluación de estudiantes con base en conversaciones con dichos pacientes. En particular, presentan un módulo de entendimiento de lenguaje natural, que procesa las respuestas verbales de los estudiantes. Este procesamiento incluye la limpieza del texto, la clasificación de temas mediante una red por convolución y una base de reglas anidadas para determinar el caso que se está tratando. Un enfoque similar es propuesto por Kazi et al. (2012), que propone un sistema tutor llamado MedChatBot, basado en el lenguaje AIML (*Artificial Intelligence Markup Language*) y el uso de términos médicos pertenecientes al UMLS (*Unified Medical Language System*). Otros trabajos, como el presentado por Moldt et al. (2023), se enfocan más bien en analizar la perspectiva de los estudiantes en cuanto a los *chatbots* dentro de la medicina.

Al igual que el trabajo anterior, una porción considerable de la literatura se ha enfocado en estudiar el impacto de los transformadores dentro del área médica —particularmente, el impacto de ChatGPT. Algunas líneas de estudio incluyen identificar aquellos factores que motivan a las personas a usar asistentes médicos virtuales (Chang et al., 2019), identificar factores que obstaculizan el uso pleno de estos asistentes dentro del ambiente médico (Chow et al., 2023), facilitar la apertura de la inteligencia artificial en medicina (Greene et al., 2019), analizar la manera en que se construyen y utilizan los asistentes médicos (Safi et al., 2020; Walss et al., 2021), o simplemente brindar una panorámica general de la gama de aplicaciones médicas que ahora son posibles usando ChatGPT (Chakraborty et al., 2023).

La compilación de Frangoude et al. (2021) ofrece una revisión más extensa del uso de *chatbots* en medicina —específicamente en el contexto de educación.

Análisis de historiales clínicos electrónicos (EHR)

Los historiales clínicos electrónicos almacenan información relevante sobre la salud de los pacientes a lo largo del tiempo. Si bien gran parte de esta información está estructurada, también es posible incluir texto en formato libre (por ejemplo, notas sobre la última consulta del paciente). Viendo lo anterior, es posible utilizar técnicas de procesamiento de lenguaje natural para realizar diferentes tareas sobre estos expedientes. Algunas de estas incluyen la detección y el diagnóstico de enfermedades, así como la generación automática

de resúmenes médicos. A continuación, se describe brevemente el rol de las técnicas de NLP en cada una de estas tareas.

Para profundización en este tema, además de los trabajos que se describen a continuación, se remite al lector a las compilaciones de Li et al. (2022) y Kreimeyer et al. (2017).

Diagnóstico y detección de enfermedades. Una tarea frecuente dentro del procesamiento de lenguaje natural es la clasificación de texto (predicción, en general). Con respecto al análisis de historiales clínicos electrónicos, los modelos de aprendizaje se han utilizado para detectar enfermedades, así como para predecir el pronóstico de un paciente, o detectar posibles reingresos —entre otros usos.

Con respecto a la detección de enfermedades, se ha investigado de manera recurrente la detección de enfermedades cardíacas. Algunos ejemplos incluyen la identificación de estenosis aórtica mediante ecocardiogramas semiestructurados y algoritmos de NLP basados en reglas (Solomon et al., 2021); la identificación de factores de riesgo mediante incrustaciones apiladas de palabras (Houssein et al., 2023); y la extracción de síntomas y comorbilidades de falla cardíaca en notas clínicas mediante aprendizaje por transferencia (Adejumo et al., 2024). La extracción de signos y síntomas también se ha llevado a cabo para padecimientos renales (pacientes de hemodiálisis) y esclerosis múltiple. En el primer caso, mediante modelos grandes de lenguaje multilingües y aprendizaje tipo *few-shot* (Chan et al., 2020; Gluck et al., 2025) y, en el segundo caso, mediante clasificadores bayesianos y asociación a términos UMLS (Chase et al., 2017). Los objetivos principales de estos trabajos han sido la detección oportuna y el apoyo a la toma de decisiones por parte del personal médico.

En cuanto a la predicción del pronóstico de un paciente, el trabajo de Suresh et al. (2017), en particular, se centra en predecir intervenciones clínicas mediante redes profundas (inicio, continuación, destete y sin necesidad de intervención). Para ello, se representa a cada paciente como una combinación de series de tiempo, tópicos y datos estáticos. Los dos tipos de redes utilizados para esta tarea son las redes por convolución y las redes LSTM. Además de comparar estas dos redes, también proponen un mecanismo (llamado "oclusión") para interpretar los resultados arrojados por estas, donde dicho mecanismo consiste en ir reemplazando cada característica de los datos por ruido aleatorio y medir la calidad del modelo. De esta manera, no solamente buscan la predicción correcta, sino también saber cómo se obtuvo esta predicción.

En esta misma línea, el trabajo de Choi et al. (2016) presenta el *software* Doctor AI, que busca predecir cuándo reingresará el paciente y qué códigos médicos le serán asignados. Lo anterior se realiza mediante redes recurrentes.

Generación automática de informes médicos. Las historias clínicas electrónicas también han sido utilizadas en el contexto de generación automática de resúmenes, pues estos coadyuvan la identificación de información relevante de manera rápida y eficiente. De esta manera, es posible concentrarse en piezas clave de información para el entendimiento de diferentes padecimientos. En este sentido, las técnicas de generación de resúmenes han sido útiles para compilar información sobre un tema médico en particular. Por ejemplo, a lo largo de la pandemia por COVID-19, se usaron distintas técnicas para generar resúmenes sobre los avances más recientes (Batra et al., 2021; Cai et al., 2022; Afsharizadeh et al., 2020). Estas incluyen el uso de modelos grandes de lenguaje, como BERT, y redes neuronales recurrentes.

También ha sido benéfico el uso de modelos compactos de lenguaje y métodos específicos de dominio, es decir, basados solamente en el contexto de medicina (y no en conocimiento general, como los modelos grandes). Lo que se busca en sí es condensar grandes cantidades de textos médicos para una comprensión más rápida, enfocada y eficiente.

Asimismo, ha habido una tendencia progresiva hacia el uso de transformadores. Por ejemplo, Chandraju & Gnanasigamani (2022) utilizan un generador extractivo basado en BERT para la creación de informes de casos clínicos. De manera similar, Ronan & Tabirca (2024) proponen el uso de GPT-3.5 para resumir diálogos clínicos. En ambos casos, se echa mano del ajuste fino (*fine-tuning*) de los modelos generados para obtener una mayor calidad en los resúmenes. El trabajo propuesto por Prakash et al. (2024), por su parte, usa BERT y GPT. Se ha visto que los resultados no solamente son equiparables con los resúmenes generados de manera manual, sino incluso superiores en algunos casos (Van Veen et al., 2024).

Dos retos importantes que se mantienen en la generación de resúmenes son la exactitud y la confiabilidad. Estos atributos no son solamente deseables, sino necesarios si se considera que la mayoría de los lectores carecen del tiempo requerido para leer todas las fuentes primarias por su cuenta y sintetizarlas o verificarlas.

Traducción y accesibilidad multilingüe

En el contexto médico, el propósito de la traducción automática y la accesibilidad multilingüe es traspasar las barreras que dificultan la comunicación entre médicos y pacientes. Para las técnicas de NLP, esto representa un reto, ya que existen lenguajes con pocos recursos lingüísticos como para generar modelos de aprendizaje y otros tipos de herramientas. Lo anterior incluye lenguajes que, por ejemplo, son hablados por minorías o en los que simplemente no se ha avanzado el estado del arte. Buscar alternativas para estos lenguajes ayudaría a disminuir la brecha entre los servicios de salud de diferentes poblaciones. En general, los modelos de lenguaje en estos casos se basan esencialmente en aprendizaje por transferencia. Sin embargo, un reto dentro del contexto de medicina es poder traducir de manera correcta los términos médicos —de ahí que se prefiera hacer modelos específicos para este contexto.

Considerando lo anterior, dentro de los avances para traducción automática y accesibilidad multilingüe se ven dos grandes direcciones: (1) generación de recursos multilingües y (2) el mejoramiento de la interacción con pacientes que hablan en diferentes lenguas.

En cuanto a la generación de recursos multilingües, los trabajos se han enfocado principalmente en generar modelos de lenguaje multilingües; por ejemplo, el modelo de García-Ferrero et al. (2024), acuñado mT5, es específico para el contexto médico y abarca los idiomas de inglés, francés, italiano y español. Por otro lado, el trabajo de Qiu (2024) desarrolla un modelo grande multilingüe específico para medicina, que abarca los idiomas inglés, chino, japonés, francés, ruso y español. Además de esta colección, los autores proponen un recurso para evaluación comparativa (*benchmark*) llamado MMed-Llama. El objetivo de la colección multilingüe es que se pueda adaptar a otros modelos grandes de lenguaje mediante aprendizaje por transferencia.

De igual manera, dado que el contexto médico es altamente sensible, también se han hecho esfuerzos para tratar de asegurar la calidad de los recursos multilingües. Estos incluyen marcos de trabajo para evaluar modelos grandes de lenguaje en cuanto a correctitud, consistencia y verificabilidad (Jin et al., 2024), así como estudios donde se busca encontrar factores que puedan facilitar o dificultar la interacción con los traductores automáticos (Hudelson & Chappuis, 2024).

Otros trabajos incluyen, por ejemplo, la generación automática de subtítulos para emergencias médicas (Utunen et al., 2023). En este caso, la herramienta propuesta cuenta con la "integración del usuario en el ciclo" al permitir corregir errores de manera manual, así como recibir retroalimentación para mejorar los subtítulos.

Debido a que el estado del arte aún no es lo suficientemente confiable como para permitir la interacción directa con pacientes (especialmente en padecimientos como cáncer), los métodos que combinan técnicas de traducción automática con post-procesamiento manual parecen ser prometedores (Lawson & Yen, 2024).

Investigación biomédica y extracción de conocimiento

En cuanto a la investigación biomédica y la extracción de conocimiento, las técnicas de procesamiento de lenguaje natural se han enfocado en generar estructuras de datos para la resolución de preguntas, así como en generar modelos de lenguaje especializados. Con respecto al primer punto, se tiene —por ejemplo— la extracción de grafos de conocimiento, donde un grafo de conocimiento consiste en una red que relaciona conceptos, entidades y eventos. De esta manera, podemos ver trabajos donde se extraen este tipo de grafos para medicina de precisión (Chandak et al., 2023), depresión mayor (Fu et al., 2021; Huang et al., 2017), cardiología y enfermedades cardiovasculares (Wang et al., 2022) y descubrimiento de medicinas (Bonner et al., 2022) —entre otras aplicaciones. La idea, en general, es condensar información de diferentes fuentes y poder contestar preguntas sobre esta información condensada. Para profundizar en el tema, se refiere al lector a la compilación de Murali et al. (2023).

Con respecto a la generación de modelos de lenguaje especializados, se tiene el modelo BioBERT (Lee et al., 2020), cuya finalidad es realizar el descubrimiento de patrones en el área biomédica. Este modelo está entrenado con textos biomédicos, que incluyen Wikipedia y BooksCorpus como fuentes generales, así como PubMed abstracts y PMC Full-text articles como fuentes específicas de biomedicina. Los autores de este modelo reportan resultados superiores a los de BERT en tres tareas: reconocimiento de entidades nombradas biomédicas, extracción de relaciones y contestación de preguntas en el campo biomédico. En general, también ha habido avances en cuanto al reconocimiento de entidades nombradas, adaptadas a contextos biomédicos (Wang et al., 2025).

2.3.5 Desafíos y Consideraciones Éticas

Si bien el área de procesamiento de lenguaje natural ha tenido avances significativos en los últimos años, con cada avance se desprende también una serie de desafíos y consideraciones éticas. Estos desafíos abarcan diferentes dimensiones —no solamente la dimensión técnica propia del campo. A continuación, se describen algunos de los más relevantes.

- **Sesgo.** Los modelos de aprendizaje pueden contar con sesgos debido a los datos con que se entrenan; es decir, son sensibles a los datos de entrada.
- **Confiabilidad de la información proporcionada.** Como es bien sabido, las herramientas de inteligencia artificial generativa pueden sufrir de "alucinaciones". Esto puede poner en tela de juicio la veracidad y exactitud de una respuesta dada por la herramienta. Tratándose del área de medicina, esta situación es más seria, pues se trata con la salud y la vida de las personas.
- **Privacidad.** Debido a que los expedientes médicos contienen datos sensibles de los pacientes, no solamente resulta un reto el anonimizar los registros de los pacientes para generar modelos, sino también asegurarse de que estos datos sensibles no puedan inferirse.
- **Interpretabilidad y explicabilidad.** Los métodos de aprendizaje se consideran de "caja negra". En ese sentido, es considerablemente difícil rastrear el camino que siguió una herramienta para generar un contenido o respuesta en particular. Si bien existen métodos de interpretabilidad y explicabilidad, estos métodos son incipientes e incurrir en un alto costo computacional. Su desarrollo será importante para poder dar una mayor confianza al paciente cuando se utilice alguna herramienta de IA para tomar decisiones.
- **Entrenamiento.** A medida que van creciendo los datos disponibles, y que se ocupan modelos específicos para cada área, se necesitan más recursos computacionales. Es importante encontrar un balance entre las demandas de dichos recursos y la sustentabilidad ambiental. También es importante —y a la vez retador— encontrar maneras para que la generación de modelos grandes no sea monopolizada por una sola empresa o país específico.

El lenguaje natural puede ser subjetivo, ambiguo y poco claro. El procesamiento de lenguaje natural es el área de la inteligencia artificial que se enfoca en el entendimiento y la generación de este tipo de lenguaje. Algunas de las tareas principales incluyen la clasificación de texto, el análisis de sentimiento, la traducción automática y la resolución de preguntas. Esta área se encuentra ligada a otras, tanto de inteligencia artificial como de otras disciplinas; dichas áreas incluyen el aprendizaje automático, la lingüística, la psicología cognitiva y la neurociencia.

Las técnicas de procesamiento de lenguaje natural pueden ubicarse dentro de distintas generaciones. En la primera generación, tenemos técnicas mayormente basadas en lingüística y reglas gramaticales. En la segunda generación, tenemos técnicas basadas en estadística y aprendizaje automático (no profundo). En la tercera generación, tenemos técnicas basadas en aprendizaje profundo. Debido a los avances en aprendizaje profundo, los desarrollos en el procesamiento de lenguaje natural se han incrementado sustancialmente. No obstante, un reto palpable es el costo de producir modelos grandes de lenguaje. Se esperaría que, a medida

que los modelos grandes se vayan generando de manera más eficiente, dicho costo se redujera y permitiera producir modelos de calidad con relativamente pocos recursos. Con relación a líneas futuras de investigación, está el uso y desarrollo de modelos especializados o compactos, la generación de algoritmos y técnicas cuya confiabilidad se pueda constatar (para beneficio tanto del paciente como de los médicos) y la generación de recursos de NLP en países que se encuentran en vías de desarrollo.

2.4. Técnicas de Visión por Computadora

La visión por computadora es un campo de la inteligencia artificial dedicado a que los ordenadores interpreten la información visual en imágenes y videos. Esta tecnología permite analizar secuencias visuales para extraer datos que pueden ser interpretados y utilizados por un sistema automatizado (Litjens et al., 2017).

En medicina, estas técnicas automatizan tareas de interpretación de imágenes, como la detección de lesiones, la segmentación anatómica o el cálculo de biomarcadores.

Un sistema típico sigue cuatro pasos encadenados:

1. **Adquisición de la imagen:** El proceso comienza con la captura. La fuente puede ser tan simple como la cámara de un teléfono o tan especializada como un sistema óptico avanzado. Lo importante es que la señal visual quede digitalizada.
2. **Preprocesamiento:** Igualar el contraste, reducir el ruido y estandarizar el tamaño de la imagen facilita que los algoritmos trabajen de manera fiable. Es comparable a limpiar y calibrar un instrumento óptico antes de examinar una muestra.
3. **Modelado y análisis:** En esta fase, actúan los algoritmos de aprendizaje para realizar diversas tareas:
 - **Clasificación:** Decide a qué categoría pertenece la imagen.
 - **Detección de objetos:** Localiza regiones específicas dentro de la imagen mediante recuadros.
 - **Segmentación:** Dibuja contornos exactos que separan estructuras dentro de la imagen.
 - **Seguimiento temporal:** Rastrea el movimiento de elementos a lo largo de un video.
4. **Presentación de resultados:** El sistema traduce los hallazgos en elementos fáciles de leer: mediciones automáticas, indicadores visuales o mapas de color que resaltan las regiones relevantes. Estas salidas se integran para facilitar la interpretación y toma de decisiones (Chai et al., 2021).

El recorrido histórico muestra una clara evolución. Las primeras soluciones dependían de descriptores diseñados a mano, como los operadores de bordes o los histogramas de gradientes. Con la llegada del aprendizaje profundo, los modelos aprendieron a reconocer patrones jerárquicos directamente a partir de datos, ganando precisión y rapidez (Khan et al., 2022).


2.4.1. Evolución de las técnicas de visión por computadora

La manera en que los sistemas analizan imágenes ha cambiado de forma considerable en las últimas décadas. Se ha pasado de métodos diseñados manualmente por expertos a modelos que aprenden por sí mismos a partir de grandes volúmenes de datos. Cada nueva etapa ha reducido la necesidad de intervención humana y ha aumentado la capacidad de los sistemas para reconocer patrones complejos. Esta evolución puede organizarse en tres momentos clave.

El proceso puede visualizarse en la Figura 2.4.1, que resume la evolución desde el procesamiento clásico hasta las redes convolucionales modernas. Parte del procesamiento clásico de bordes y segmentación; avanza al aprendizaje basado en características manuales, donde la extracción de descriptores se combina con clasificadores estadísticos; y culmina en la era del aprendizaje profundo, en la que las redes convolucionales

automatizan tanto la selección de características como la clasificación, potenciadas por técnicas de transferencia de aprendizaje. Este flujo permite apreciar de un vistazo cómo cada etapa ha elevado el nivel de autonomía y precisión en la interpretación de imágenes.

Fig. 2.4.1 Evolución de las técnicas de visión por computador, desde el procesamiento clásico hasta el aprendizaje profundo con CNN



Procesamiento clásico de imágenes

Los primeros métodos en visión por computadora se basaban en identificar los bordes de los objetos. Estos bordes marcan los límites donde cambia bruscamente el color o la intensidad de una imagen. Para ello, se utilizaban filtros como Sobel o Prewitt, que calculan la variación de intensidad entre un píxel y sus vecinos. El resultado se expresa mediante la magnitud del gradiente:

$$M(x, y) = \sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$$

En esta ecuación:

$I(x, y)$ es la intensidad del píxel ubicado en la posición (x, y) ,

$\frac{\partial I}{\partial x}$ y $\frac{\partial I}{\partial y}$ representan los cambios de intensidad en las direcciones horizontal y vertical, respectivamente,

$M(x, y)$ indica qué tan fuerte es esa variación.

Cuando $M(x, y)$ tiene un valor alto, hay un cambio brusco en la imagen, lo que suele coincidir con un borde (Gonzalez, 2009). El método de Canny mejoró esta idea al aplicar un filtrado adicional que ayuda a eliminar detalles poco relevantes y obtener contornos más continuos.

Además de encontrar bordes, también se buscó separar la imagen en regiones distintas. Para eso se usaron técnicas como:

- **Umbralización:** Asigna a cada píxel una etiqueta dependiendo de si es más claro u oscuro que un valor determinado.
- **Watershed:** Imagina la imagen como un paisaje con montañas y valles. A partir de las zonas más bajas (mínimas), se “inunda” el terreno para crear divisiones.
- **K-means:** Agrupa píxeles similares entre sí, minimizando el siguiente valor:

$$SSE = \sum_{i=1}^N \|x_i - c_{grupo(i)}\|^2$$

Aquí:

- x_i representa las características del píxel i ,
- $c_{grupo(i)}$ es el centro del grupo al que fue asignado ese píxel,
- SSE (suma del error cuadrático) mide cuán compactos son los grupos formados (MacQueen, 1967).

Cuando el problema requería entender más detalles de la imagen, se introdujeron descriptores manuales, como:

- **SIFT y SURF:** Detectan puntos clave que no cambian, aunque la imagen se gire o escale.
- **HOG:** Captura la orientación predominante de los bordes en celdas pequeñas.
- **LBP:** Describe la textura comparando un píxel con sus vecinos inmediatos.

Aunque estas herramientas fueron muy útiles, su éxito dependía en gran medida de las decisiones del usuario sobre qué características calcular y cómo configurarlas.

Aprendizaje basado en características manuales

El siguiente paso consistió en utilizar esas características como entrada para algoritmos de clasificación. El proceso clásico se dividía en dos partes: primero se extraía un conjunto de características por imagen; luego, ese conjunto alimentaba a un clasificador estadístico.

Entre los más usados están:

Máquinas de Vectores de Soporte (SVM): Buscan un plano que separe los datos en distintas clases con el mayor margen posible (Vapnik, 1995). Su ecuación es:

$$w^T x + b = 0$$

donde:

- w es un vector que define la orientación del plano,
- x representa los datos de entrada,
- b ajusta la posición del plano.

Árboles de decisión y Random Forests: Dividen los datos en pasos sucesivos siguiendo reglas simples (por ejemplo, si una característica supera cierto valor, tomar una dirección u otra).

K-Nearest Neighbors (k-NN): Asigna una clase observando las etiquetas de los ejemplos más cercanos.

Estos enfoques ofrecieron mejoras en precisión, pero seguían siendo sensibles a variaciones como el brillo, el ruido o el tamaño de la imagen. Cambios menores podían afectar el resultado y requerir ajustes importantes en todo el sistema.

Aprendizaje profundo y redes neuronales convolucionales (CNN)

El cambio más importante ocurrió con la llegada del aprendizaje profundo, donde las redes aprenden automáticamente tanto las características como el clasificador a partir de los datos, sin intervención manual. Un momento clave fue la aparición de AlexNet en 2012, que duplicó la precisión de los métodos anteriores en una competencia internacional de clasificación de imágenes (Krizhevsky et al., 2012).

A partir de ahí, surgieron otras arquitecturas:

- **VGGNet:** Utiliza bloques repetitivos de filtros pequeños (3×3), lo que facilita su implementación (Simonyan & Zisserman, 2014).
- **Inception:** Agrupa en paralelo filtros de varios tamaños para detectar distintos tipos de patrones (Szegedy et al., 2016).
- **ResNet:** Añade conexiones directas entre capas lejanas, lo que permite entrenar redes más profundas sin perder rendimiento (He et al., 2016).
- **EfficientNet:** Equilibra la profundidad, la anchura y la resolución para usar menos parámetros sin sacrificar precisión (Tan & Le, 2019).

El corazón de estas redes es la operación de convolución 2-D, definida así:

$$(I * K)(x, y) = \sum_{i=-m}^m \sum_{j=-n}^n K(i, j) I(x - i, y - j)$$

Donde:

- $I(x, y)$ es el valor del píxel de la imagen en la posición (x, y) ,
- $K(i, j)$ es el valor del filtro en la posición (i, j) ,
- m, n , definen el tamaño del filtro.

Esta operación se aplica en forma de “ventana móvil” sobre la imagen y permite detectar patrones como bordes, texturas y formas. Las capas iniciales identifican detalles simples, mientras que las finales combinan esos patrones para representar elementos complejos.

Además, el aprendizaje por transferencia facilita reutilizar redes que ya han aprendido patrones generales en millones de imágenes. Con una pequeña cantidad de ejemplos adicionales, estas redes pueden adaptarse a nuevas tareas, incluso cuando hay pocos datos disponibles.

Estas arquitecturas constituyen la base de la mayoría de los sistemas actuales de diagnóstico asistido por computadora en radiología, cardiología y ultrasonido.

2.4.2. Modelos de Aprendizaje Profundo avanzados

Los desarrollos más recientes en visión por computadora se apoyan en redes neuronales profundas que permiten representar y analizar imágenes con mayor detalle. Estas arquitecturas han hecho posible detectar objetos, segmentar imágenes con precisión y procesar información visual de forma más flexible. En términos generales, los modelos avanzados se organizan en tres grupos: detección de objetos, *transformers* de visión y redes de segmentación.

Estos modelos son la base de las herramientas que, por ejemplo, detectan lesiones, cuantifican volúmenes o delimitan órganos de manera automática en estudios radiológicos.

Detección de objetos

Los modelos de detección buscan reconocer qué aparece en una imagen y señalar su ubicación. Para ello, generan recuadros que enmarcan las regiones de interés y les asignan una probabilidad o categoría. Existen dos formas principales de abordar esta tarea:

1. **Modelos en dos etapas (*two-stage*):** En estos sistemas, como *Faster R-CNN*, se sigue un proceso secuencial. Primero, una red auxiliar llamada *Region Proposal Network* (RPN) genera una serie de regiones que podrían contener un objeto. Luego, cada una de estas regiones se analiza por separado usando una red convolucional que ajusta su tamaño y determina a qué clase pertenece. Una extensión de este método, llamada *Mask R-CNN*, también genera una máscara que marca exactamente los píxeles que forman parte del objeto (He et al., 2017). Estos modelos suelen ser precisos, aunque su procesamiento puede ser más lento.
2. **Modelos en una sola etapa (*one-stage*):** A diferencia del método anterior, estos modelos realizan todo el análisis de una sola vez. Dividen la imagen en una cuadrícula y, en cada celda, predicen directamente si hay un objeto, cuál es su categoría y dónde está ubicado. Algunos ejemplos de esta familia son *SSD* y los distintos modelos de la familia *YOLO*.

Este tipo de modelos utiliza varios conceptos clave:

- **Anclas (*anchors*):** En cada celda de la cuadrícula se definen varios rectángulos base, que se ajustan automáticamente durante el entrenamiento.
- **Intersección sobre Unión (IoU):** Mide cuán bien coincide una predicción con la ubicación real de un objeto. Su fórmula es:

$$IoU = \frac{B_p \cap B_g}{B_p \cup B_g}$$

donde B_p es la caja predicha y B_g es la caja real. Un valor de 1 indica coincidencia perfecta.

- **Non-Max Suppression (NMS):** Si el modelo predice múltiples cajas para un mismo objeto, esta técnica elimina las redundantes y conserva solo la de mayor confianza.

Estos modelos se caracterizan por su rapidez. Por ejemplo, las versiones modernas de *YOLO* pueden procesar más de 30 imágenes por segundo en una computadora portátil con tarjeta gráfica (Bochkovskiy et al., 2020).

Transformers de visión

Inspirados en técnicas que inicialmente se desarrollaron para el análisis de texto, los *Vision Transformers* (ViT) han demostrado un desempeño competitivo en segmentación y clasificación médica en tareas visuales. En lugar de analizar la imagen como una matriz continua, la dividen en pequeños bloques cuadrados (por ejemplo, 16×16 píxeles) y los tratan como si fueran elementos de una secuencia.

Cada bloque se convierte en un vector numérico que conserva su posición original dentro de la imagen. Luego, estos vectores se procesan mediante capas de atención, que permiten que cada parte de la imagen “observe” a las demás. Esta operación se describe mediante la siguiente fórmula:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d}}\right)$$

donde:

- Q, K, V son matrices llamadas consultas, claves y valores,
- d es la dimensión del vector,
- el operador *softmax* ajusta los valores para que sumen uno y funcionen como ponderaciones.

El modelo aprende a asignar importancia relativa a cada parte de la imagen, en función de cómo se relaciona con el resto. Si bien los *transformers* requieren muchos datos para funcionar bien, existen versiones más eficientes como el *Swin Transformer*, que divide la imagen en ventanas pequeñas y aplica atención local para reducir el uso de memoria sin perder contexto global (Liu et al., 2021).

Redes de segmentación

La segmentación semántica busca identificar a qué categoría pertenece cada píxel de una imagen. Esta tarea permite delimitar con gran precisión las distintas partes que la componen. Las redes de segmentación más utilizadas siguen una estructura que facilita esta tarea, incluso cuando hay pocos datos disponibles.

- **U-Net:** Tiene una forma simétrica similar a una letra “U”. La primera parte reduce la imagen progresivamente para extraer sus características principales. Luego, otra parte la reconstruye usando técnicas de interpolación. Durante este proceso se conectan las capas correspondientes de entrada y salida para combinar detalles finos con información general. Esto permite generar máscaras detalladas con pocos ejemplos (Ronneberger et al., 2015).
- **U-Net++:** Mejora el diseño anterior al incluir conexiones adicionales entre las distintas escalas. Esto permite una transición más suave entre las resoluciones y mejora el trazo de los bordes.
- **DeepLab:** Esta arquitectura emplea filtros dilatados que capturan información en distintas escalas sin reducir la resolución. También puede incorporar un módulo de afinamiento llamado *Conditional Random Field* que mejora los contornos en la imagen reconstruida.

Para medir la calidad de estas segmentaciones se utiliza el coeficiente Dice, que se calcula como:

$$Dice = \frac{2|P \cap G|}{|P| + |G|}$$

donde:

- P es la máscara generada por el modelo,
- G es la máscara real.

El resultado refleja qué tanto coinciden ambas. Un valor de 1 significa superposición perfecta.

Estas redes son ampliamente empleadas en segmentación de órganos, tumores o estructuras cardíacas en imágenes de resonancia, tomografía y ecografía.

2.4.3. Post-procesamiento y evaluación

Una vez que el modelo ha realizado su predicción, es necesario afinar los resultados y evaluar su desempeño. Este paso es importante para asegurar que las salidas sean comprensibles y útiles en la práctica. En general, se divide en dos partes: el post-procesamiento y la evaluación cuantitativa.

Post-procesamiento

- **Umbral adaptativo:** Cuando un modelo devuelve una probabilidad (por ejemplo, 85% de que haya una determinada estructura), esa probabilidad debe transformarse en una decisión clara. Para ello se define un umbral. Aunque muchas veces se usa un valor estándar como 0.5, en otras situaciones puede convenir ajustarlo. Por ejemplo, si es más riesgoso no detectar un hallazgo que tener un falso positivo, puede usarse un umbral más bajo para ser más sensible.
- **Campos Aleatorios Condicionales (CRF, por sus siglas en inglés):** En el caso de segmentación, los modelos pueden producir contornos irregulares o errores en zonas homogéneas. Los CRF son técnicas que analizan cómo se relacionan los píxeles entre sí para suavizar el resultado. Asignan un “costo” a cada par de píxeles según su similitud: si dos píxeles son parecidos en color o intensidad, se prefiere que tengan la misma etiqueta. Esto ayuda a delinear de forma más natural las estructuras dentro de la imagen (Zheng et al., 2015).
- **Ensamblado de modelos (*ensembles*):** En lugar de depender de un solo modelo, es posible combinar varios que fueron entrenados por separado. Esto se hace para reducir errores y mejorar la estabilidad del resultado. En tareas de clasificación, se promedia la predicción de todos; en segmentación, se combinan las máscaras y se asigna el valor más frecuente en cada punto. Esta estrategia tiende a ofrecer mejores resultados que usar un único modelo (Dietterich, 2000).

Métricas de desempeño

Las métricas cuantitativas permiten juzgar la calidad de un modelo y compararlo con alternativas. La elección depende de la tarea (clasificación, detección o segmentación) y de las prioridades del usuario (sensibilidad, especificidad, localización exacta, etc.). En la Tabla 2.4.1 se incluyen las medidas más habituales, su interpretación y las fórmulas correspondientes.

Cada métrica se elige según la tarea. Por ejemplo, el coeficiente Dice es útil para medir qué tan bien se delineó una estructura. En tareas de detección de objetos, el IoU permite saber si el sistema ubicó correctamente la región deseada. En problemas donde es importante identificar correctamente los casos positivos, la AUC-ROC es más adecuada.

Tabla 2.4.1. Métricas de desempeño para modelos de visión por computadora

Métrica	Qué mide	Fórmula	Referencias orientativas
Exactitud (Accuracy)	Porcentaje global de aciertos.	$Accuracy = \frac{VP + VN}{N}$ <i>VP</i> : verdaderos positivos. <i>VN</i> : verdaderos negativos. <i>N</i>: total de casos.	Útil cuando las dos clases están equilibradas. Valores cercanos a 1 indican un alto grado de acierto.
AUC-ROC	Capacidad de discriminar entre positivos y negativos a lo largo de todos los umbrales.	Área bajo la curva “sensibilidad vs. 1 – especificidad”. Se calcula numéricamente.	AUC $\approx$ 0.5 equivale al azar; $\geq$ 0.9 se interpreta como discriminación muy buena
IoU (Intersection over Union)	Superposición entre la caja predicha y la caja real en detección de objetos.	$IoU = \frac{B_p \cap B_g}{B_p \cup B_g}$ <i>B_p</i>: caja predicha. <i>B_g</i>: caja de referencia.	IoU $\geq$ 0.50 suele marcar el umbral mínimo aceptado en competiciones de detección; valores > 0.75 indican localización precisa

Coefficiente Dice	Coincidencia entre dos máscaras (segmentación).	$Dice = \frac{2 P \cap G }{ P + G }$ P : máscara predicha. G : máscara de referencia.	Dice ≥ 0.80 se considera una segmentación fiable; > 0.90 refleja una coincidencia casi completa
mAP (mean Average Precision)	Precisión media en detección multiclase, promediada sobre varios umbrales de <i>IoU</i> .	$mAP = \frac{1}{C} \sum_{c=1}^C AP_c$ AP_c : área bajo la curva precisión-recobrado de la clase c . C : número de clases.	$mAP > 0.50$ refleja un desempeño aceptable; $mAP > 0.75$ indica detección robusta

Validación cruzada y generalización

Evaluar un modelo solo con los datos usados para entrenarlo conduce a un optimismo artificial. Para aproximar su rendimiento en imágenes nuevas se emplea la validación cruzada K-fold. El procedimiento consiste en dividir el conjunto de datos en K partes iguales, llamadas *folds*. El modelo se entrena con K-1 *folds* y se valida con el *fold* restante; este proceso se repite K veces, de modo que cada parte actúa como prueba una vez. Al final se promedian las métricas obtenidas. Así se estima cómo responderá el sistema cuando reciba información que nunca ha visto (Kohavi, 1995).

Un desafío adicional aparece cuando se utilizan imágenes procedentes de dispositivos o entornos diferentes del conjunto original: se habla de cambio de dominio. Un modelo puede rendir menos si la iluminación, la resolución o las características demográficas cambian. Para reducir este problema se aplican varias estrategias:

- **Afinado local (*fine-tuning*):** Entrenar unas pocas iteraciones adicionales con un lote reducido de imágenes propias permite ajustar los pesos de la red a las particularidades del nuevo entorno.
- **Normalización de estilo:** Ajustar el contraste, la escala de grises o la resolución para que las imágenes nuevas se parezcan estadísticamente a las que vio el modelo durante su aprendizaje.
- **Aprendizaje federado:** Consiste en enviar el modelo a distintos centros para que se actualice de manera descentralizada. Cada sitio entrena el modelo con sus datos y devuelve únicamente los parámetros refinados; los datos originales nunca se comparten, lo cual favorece la privacidad y aumenta la diversidad del entrenamiento (Li et al., 2020).

Una combinación adecuada de post-procesamiento, métricas bien elegidas y validación rigurosa brinda la confianza necesaria para que los sistemas de visión por computadora superen la fase experimental y se empleen con seguridad en entornos reales.

En el ámbito clínico, estas métricas permiten validar la fiabilidad de los modelos antes de su uso asistencial y garantizar su reproducibilidad entre centros.

2.4.4. Aplicaciones clínicas de la visión por computadora

Los avances en aprendizaje profundo han permitido que el análisis automático de imágenes se integre en diferentes etapas de la atención sanitaria. En el ámbito del diagnóstico, redes convolucionales entrenadas con grandes repositorios de radiografías de tórax detectan con alta sensibilidad signos radiológicos de neumonía o tuberculosis, mientras que modelos similares en mamografía señalan microcalcificaciones sospechosas que podrían pasar inadvertidas durante una lectura inicial (Rodríguez-Ruiz et al., 2019). En tomografía

cerebral, algoritmos tridimensionales identifican hemorragias agudas en pocos segundos, agilizando la priorización de pacientes; por su parte, clasificadores basados en mecanismos de atención localizan metástasis microscópicas en láminas de patología digital con precisión comparable al criterio experto (Rajpurkar et al., 2017; Titano et al., 2018; Bejnordi et al., 2017).

La segmentación anatómica asistida por redes tipo U-Net ofrece contornos submilimétricos que resultan útiles para estudios volumétricos y planificación de procedimientos. En resonancia cerebral, estas redes diferencian con exactitud la materia gris y la blanca, mientras que en tomografía abdominal delinean automáticamente el hígado y sus lesiones. De modo análogo, en ecocardiografía tridimensional trazan las cavidades cardíacas y generan fracciones de eyección reproducibles sin intervención manual (Bernard et al., 2018; Christ et al., 2016).

Dentro del quirófano, los detectores en tiempo real de la familia YOLO identifican pinzas, electrodos y tejido sensible durante procedimientos endoscópicos, y al combinarse con algoritmos de seguimiento ayudan a mantener las herramientas dentro de la zona segura. Robots quirúrgicos experimentales incorporan segmentación de vasos en video, lo que reduce el riesgo de sangrado accidental durante la disección (Shvets et al., 2018).

Por último, la portabilidad de los modelos ha impulsado la telemedicina. Aplicaciones móviles basadas en redes profundas clasifican lesiones cutáneas pigmentadas con un nivel de exactitud comparable al dermatólogo, y sistemas de cribado remoto para retinopatía diabética procesan fotografías de fondo de ojo tomadas con cámaras portátiles, enviando a consulta especializada solo los casos de mayor riesgo (Esteva et al., 2017; Gulshan et al., 2016). Estas experiencias muestran cómo la automatización visual aporta rapidez, objetividad y estandarización a lo largo del flujo clínico, desde el diagnóstico inicial hasta la intervención quirúrgica y el seguimiento a distancia.

Ejemplo Práctico: Medición Automática de la Translucencia Nucal

Un ejemplo representativo de cómo la visión artificial puede apoyar la práctica médica se encuentra en la evaluación ecográfica del primer trimestre, donde se valoran marcadores fetales asociados al riesgo de aneuploidías. Entre estos marcadores, la Translucencia Nucal (TN), el espacio anecoico situado en la nuca del feto, es uno de los parámetros más utilizados en los programas de cribado prenatal.

La medición de la TN requiere obtener una imagen sagital media del feto en posición neutra y ubicar los cursores sobre los límites exactos del espacio transluciente. Aunque los protocolos internacionales estandarizan este proceso, la variabilidad entre operadores puede afectar la precisión de la medición.


En este contexto, un modelo de segmentación automática basado en redes neuronales convolucionales (CNNs), como U-Net, puede asistir al profesional al delimitar de forma automática la región de interés, como se ilustra en la Figura 2.4.2.

El procedimiento general se desarrolla en tres etapas:

1. **Entrenamiento:** La red se entrena con una base de datos de ultrasonidos etiquetados por especialistas, donde se ha trazado manualmente el contorno de la TN.
2. **Segmentación automática:** El modelo, una vez entrenado, procesa una nueva imagen y genera una máscara que resalta el área de la TN con alta precisión.
3. **Medición y clasificación:** El sistema calcula el espesor máximo del espacio delimitado y lo compara con los valores de referencia, generando una etiqueta interpretativa (normal o aumentada).

Este tipo de integración de visión por computadora permite agilizar la medición, disminuir la variabilidad y aumentar la reproducibilidad en la evaluación prenatal. Además, sirve como herramienta de apoyo diagnóstico que complementa la valoración del especialista, sin sustituir su criterio clínico.

Fig. 2.4.2. Ejemplo de segmentación automática de translucencia nuchal fetal con U-Net.



2.4.5. Ventajas, limitaciones y consideraciones éticas

El uso de visión por computadora dentro de la práctica clínica promete mejorar la calidad asistencial, aunque plantea retos que deben abordarse con transparencia.

Ventajas clínicas y operativas

Los modelos basados en aprendizaje profundo ofrecen niveles de precisión comparables al lector experto en tareas bien definidas. Esta consistencia reduce la variabilidad entre observadores y disminuye la tasa de falsos negativos y positivos. Al procesar miles de imágenes en cuestión de segundos, ayudan a priorizar estudios urgentes y liberan tiempo del profesional. Su capacidad para señalar hallazgos muy pequeños, como microcalcificaciones o nódulos milimétricos, refuerza la detección temprana y facilita una intervención oportuna (Topol, 2019).

Limitaciones técnicas y operativas

Alcanzar un rendimiento estable requiere amplios conjuntos de datos etiquetados, lo cual demanda esfuerzo coordinado de radiólogos, ingenieros y personal de tecnología. Incluso con volúmenes grandes, el modelo puede comportarse de forma diferente si se cambia el equipo de imagen o la población atendida; este fenómeno se denomina cambio de dominio. Además, muchas redes profundas son difíciles de interpretar. Herramientas de explicación como mapas de calor ayudan a visualizar qué zonas influyeron en la predicción, pero aún no sustituyen el análisis crítico del médico (Tjoa & Guan, 2020).

Consideraciones éticas y regulatorias

El tratamiento de imágenes médicas obliga a salvaguardar la privacidad del paciente según los marcos normativos vigentes, por ejemplo, HIPAA en Estados Unidos y GDPR en la Unión Europea. Durante el entrenamiento es necesario vigilar posibles sesgos que pudieran perjudicar a determinados grupos de población. La decisión final sigue siendo responsabilidad del profesional sanitario, quien interpreta los resultados en el contexto clínico del paciente; el algoritmo funciona como apoyo. Antes de incorporarse a la rutina asistencial, los sistemas deben superar estudios prospectivos y someterse a la revisión de organismos reguladores. También resulta importante que estas innovaciones lleguen a centros con recursos limitados para evitar brechas de acceso (Geis et al., 2019).

En suma, la adopción de visión por computadora exige equilibrar las ventajas de precisión y velocidad con una supervisión humana informada, una explicación transparente de los resultados y una validación clínica permanente.

Retos futuros y conclusiones

La investigación en visión por computadora evoluciona con rapidez y abre líneas que marcarán la práctica en los próximos años. Una primera dirección es el aprendizaje auto-supervisado. Estos modelos se entrenan a partir de la propia imagen, aprendiendo a reconstruir o predecir regiones faltantes antes de recibir etiquetas clínicas. Gracias a este paso previo, adquieren una representación general del contenido visual y precisan menos datos anotados para adaptarse a una tarea específica, lo que reduce el costo de preparar bases de datos (Zhou et al., 2022).

La inferencia en el borde constituye una segunda tendencia. Redes ligeras como YOLO-Nano o EfficientNet-Lite se ejecutan en dispositivos portátiles, por ejemplo, ecógrafos de mano, y procesan la imagen sin necesidad de enviarla a la nube. Esta estrategia recorta la latencia y favorece la privacidad, factores valiosos en entornos con conectividad limitada (Howard et al., 2019).

Un tercer rumbo lo marcan los modelos multimodales, capaces de fusionar la imagen con informes clínicos, notas de evolución o datos de laboratorio. Al integrar texto e imagen en un mismo marco, el sistema genera predicciones más completas y produce explicaciones legibles por el profesional, como la correlación entre un hallazgo radiológico y un resultado histológico (Sun et al., 2024).

El aprendizaje federado cierra la lista de avances. En lugar de centralizar los datos, cada hospital entrena el modelo localmente y comparte solo los parámetros ajustados. De esta forma se preserva la confidencialidad y se reduce el sesgo geográfico al combinar experiencias de varios centros (Li et al., 2020).

Para trasladar estas innovaciones a la práctica son necesarios estudios prospectivos multicéntricos que midan su impacto en resultados de salud y comparen la nueva herramienta con la atención estándar. Médicos, ingenieros e investigadores deben colaborar: el médico define la pregunta y valida el uso, el ingeniero ajusta la arquitectura y el experto en salud pública evalúa los beneficios sobre la calidad de vida y los costos del sistema.

Lejos de reemplazar al profesional, la visión por computadora amplía la capacidad diagnóstica, aporta consistencia y acerca servicios especializados a poblaciones con acceso limitado. Con desarrollo responsable y supervisión continua, esta tecnología puede mejorar la atención y convertirse en un pilar de la medicina centrada en la persona.

Bibliografía

1. Adejumo, P., Thangaraj, P. M., Dhingra, L. S., Aminorroaya, A., Zhou, X., Brandt, C., ... & Khera, R. (2024). Natural language processing of clinical documentation to assess functional status in patients with heart failure. *JAMA Network Open*, 7(11), e2443925-e2443925.
2. Afsharizadeh, M., Ebrahimpour-Komleh, H., & Bagheri, A. (2020). Automatic text summarization of COVID-19 research articles using recurrent neural networks and coreference resolution. *Frontiers in Biomedical Technologies*.

3. Azad, R., Kazerouni, A., Heidari, M., Aghdam, E. K., Molaei, A., Jia, Y., Jose, A., Roy, R., & Merhof, D. (2023). Advances in medical image analysis with vision transformers: A comprehensive review. *arXiv preprint arXiv:2301.03505*. <https://arxiv.org/abs/2301.03505>
4. Badlani, S., Aditya, T., Dave, M., & Chaudhari, S. (2021, May). Multilingual healthcare chatbot using machine learning. In *2021 2nd International Conference for Emerging Technology (INCET)* (pp. 1-6). IEEE.
5. Baeza-Yates, R., & Ribeiro-Neto, B. (1999). *Modern information retrieval* (Vol. 463, No. 1999). New York: ACM press.
6. Banik, D., Paul, R., Rathore, R. S., & Jhaveri, R. H. (2023). Improving Access to Medical Information for Multilingual Patients using Pipelined Ensemble Average based Machine Translation. *ACM Transactions on Asian and Low-Resource Language Information Processing*.
7. Bank, D., Koenigstein, N., & Giryas, R. (2023). Autoencoders. *Machine learning for data science handbook: data mining and knowledge discovery handbook*, 353-374.
8. Batra, H., Jain, A., Bisht, G., Srivastava, K., Bharadwaj, M., Bajaj, D., & Bharti, U. (2021, September). CoVShorts: news summarization application based on deep NLP transformers for SARS-CoV-2. In *2021 9th International conference on reliability, infocom technologies and optimization (Trends and Future Directions)(ICRITO)* (pp. 1-6). IEEE.
9. Bejnordi, B. E., Veta, M., Van Diest, P. J., Van Ginneken, B., Karssemeijer, N., Litjens, G., ... & CAMELYON16 Consortium. (2017). Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. *Jama*, 318(22), 2199-2210.
10. Belcic, I. & Stryker C. (2024, diciembre 28) What is supervised learning? IBM. <https://www.ibm.com/think/topics/supervised-learning>
11. Berard, A., Kim, Z. M., Nikoulina, V., Park, E. L., & Gallé, M. A Multilingual Neural Machine Translation Model for Biomedical Data. In *Workshop on NLP for COVID-19 (Part 2) at EMNLP 2020*.
12. Bernard, O., Lalande, A., Zotti, C., Cervenansky, F., Yang, X., Heng, P. A., ... & Jodoin, P. M. (2018). Deep learning techniques for automatic MRI cardiac multi-structures segmentation and diagnosis: is the problem solved?. *IEEE transactions on medical imaging*, 37(11), 2514-2525.
13. Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
14. Breiman, L., Friedman, J., Olshen, R.A., & Stone, C.J. (1984). *Classification and Regression Trees* (1st ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/9781315139470>
15. Cai, X., Liu, S., Yang, L., Lu, Y., Zhao, J., Shen, D., & Liu, T. (2022). COVIDSum: A linguistically enriched SciBERT-based summarization model for COVID-19 scientific papers. *Journal of Biomedical Informatics*, 127, 103999.
16. Chai, J., Zeng, H., Li, A., & Ngai, E. W. (2021). Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6, 100134.
17. Chaichulee, S., Promchai, C., Kaewkomon, T., Kongkamol, C., Ingviya, T., & Sangsupawanich, P. (2022). Multi-label classification of symptom terms from free-text bilingual adverse drug reaction reports using natural language processing. *PLoS One*, 17(8), e0270595.
18. Chakraborty, C., Pal, S., Bhattacharya, M., Dash, S., & Lee, S. S. (2023). Overview of Chatbots with special emphasis on artificial intelligence ChatGPT in medical science. *Frontiers in Artificial Intelligence*, 6, 1237704.
19. Chan, L., Beers, K., Yau, A. A., Chauhan, K., Duffy, A., Chaudhary, K., ... & Nadkarni, G. N. (2020). Natural language processing of electronic health records is superior to billing codes to identify symptom burden in hemodialysis patients. *Kidney international*, 97(2), 383-392.
20. Chandraju, A. V. & Gnanasigamani, L. J. (2022). Transformer-Based Abstract Generation of Medical Case Reports. *International Journal of Engineering and Advanced Technology*, 12:1, pp. 110-113.
21. Chang, I. C., Shih, Y. S., & Kuo, K. M. (2022). Why would you use medical chatbots? interview and survey. *International Journal of Medical Informatics*, 165, 104827.
22. Chase, H. S., Mitrani, L. R., Lu, G. G., & Fulgieri, D. J. (2017). Early recognition of multiple sclerosis using natural language processing of the electronic health record. *BMC medical informatics and decision making*, 17(1), 24.
23. Chen, J., Lu, Y., Yu, Q., Luo, X., Adeli, E., Wang, Y., Lu, L., Yuille, A. L., & Zhou, Y. (2021). TransUNet: Transformers make strong encoders for medical image segmentation. *arXiv preprint arXiv:2102.04306*. <https://arxiv.org/abs/2102.04306>
24. Chow, J. C., Sanders, L., & Li, K. (2023). Impact of ChatGPT on medical chatbots as a disruptive technology. *Frontiers in artificial Intelligence*, 6, 1166014.
25. Christ, P. F., Elshaer, M. E. A., Ettlinger, F., Tataavarty, S., Bickel, M., Bilic, P., ... & Menze, B. H. (2016). Automatic liver and lesion segmentation in CT using cascaded fully convolutional neural networks and 3D conditional random fields. In *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2016: 19th International Conference, Athens, Greece, October 17-21, 2016, Proceedings, Part II* 19 (pp. 415-423). Springer International Publishing.

26. Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273-297. <https://doi.org/10.1007/BF00994018>
27. Dai, Y., & Gao, Y. (2021). TransMed: Transformers advance multi-modal medical image classification. *arXiv preprint arXiv:2103.05940*. <https://arxiv.org/abs/2103.05940>
28. Dharwadkar, R., & Deshpande, N. A. (2018). A medical chatbot. *International Journal of Computer Trends and Technology (IJCTT)*, 60(1), 41-45.
29. Dietterich, T. G. (2000, June). Ensemble methods in machine learning. In *International workshop on multiple classifier systems* (pp. 1-15). Berlin, Heidelberg: Springer Berlin Heidelberg.
30. Divya, S., Indumathi, V., Ishwarya, S., Priyasankari, M., & Devi, S. K. (2018). A self-diagnosis medical chatbot using artificial intelligence. *Journal of Web Development and Web Designing*, 3(1), 1-7.
31. Dumais, S. T. (2004). Latent semantic analysis. *Annual Review of Information Science and Technology (ARIST)*, 38, 189-230.
32. Eck, M., Vogel, S., & Waibel, A. (2004). Improving statistical machine translation in the medical domain using the Unified Medical Language System. In *Coling 2004: Proceedings of the 20th international conference on Computational Linguistics* (pp. 792-798).
33. Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639), 115-118.
34. Esuli, A., & Sebastiani, F. (2007). SentiWordNet: a high-coverage lexical resource for opinion mining. *Evaluation*, 17(1), 26.
35. Feng, X., Wang, T., Yang, X., Zhang, M., Guo, W., & Wang, W. (2023). ConvWin-UNet: UNet-like hierarchical vision transformer combined with convolution for medical image segmentation. *Mathematical Biosciences and Engineering*, 20(1), 128-144. <https://doi.org/10.3934/mbe.2023007>
36. Forgy, Edward W. (1965). "Cluster analysis of multivariate data: efficiency versus interpretability of classifications". *Biometrics*. 21 (3): 768-769.
37. Fu, C., Jiang, X., He, T., & Jiang, X. (2021, October). MDepressionKG: a knowledge graph for metabolism-depression associations. In *Proceedings of the 2nd international symposium on artificial intelligence for medicine sciences* (pp. 63-68).
38. García-Aguirre, R., Navarro-López, E. M., & Torres-Treviño, L. (2025). Gen-CNN: A framework for the automatic generation of CNNs for image classification. *Neural Computing and Applications*, 37(1), 149-168. <https://doi.org/10.1007/s00521-024-10398-6>
39. García-Ferrero, I., Agerri, R., Salazar, A. A., Cabrio, E., de la Iglesia, I., Lavelli, A., ... & Zaninello, A. (2024, May). MedMT5: An Open-Source Multilingual Text-to-Text LLM for the Medical Domain. In *Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024)* (pp. 11165-11177).
40. Geis, J. R., Brady, A. P., Wu, C. C., Spencer, J., Ranschaert, E., Jaremko, J. L., ... & Kohli, M. (2019). Ethics of artificial intelligence in radiology: summary of the joint European and North American multisociety statement. *Radiology*, 293(2), 436-440.
41. Gluck, A., von der Wense, K., & Pacheco, M. L. (2025). Clix: Cross-lingual explanations of idiomatic expressions. *arXiv preprint arXiv:2501.03191*.
42. Gonzalez, R. C. (2009). *Digital image processing*. Pearson education india.
43. Greene, A., Greene, C. C., & Greene, C. (2019). Artificial intelligence, chatbots, and the future of medicine. *The Lancet Oncology*, 20(4), 481-482.
44. Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., ... & Webster, D. R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *jama*, 316(22), 2402-2410.
45. Guo, P. F., Mei, Y. Q., Zhou, J. Y., Jiang, S. S., & Patel, V. M. (2022). ReconFormer: Accelerated MRI reconstruction using recurrent transformer. *arXiv preprint arXiv:2201.09376*. <https://arxiv.org/abs/2201.09376>
46. Han, L., Gladkoff, S., Erofeev, G., Sorokina, I., Galiano, B., & Nenadic, G. (2024). Neural machine translation of clinical text: an empirical investigation into multilingual pre-trained language models and transfer-learning. *Frontiers in Digital Health*, 6, 1211564.
47. Han, Q., Qian, X., Xu, H., Wu, K., Meng, L., Qiu, Z., Weng, T., Zhou, B., & Gao, X. (2024). DM-CNN: Dynamic multi-scale convolutional neural network with uncertainty quantification for medical image classification. *Computers in Biology and Medicine*, 168, 107758. <https://doi.org/10.1016/j.combiomed.2024.107758>
48. Han, S., Zhang, R. F., Shi, L., Richie, R., Liu, H., Tseng, A., ... & Tsui, F. R. (2022). Classifying social determinants of health from unstructured electronic health records using deep learning-based natural language processing. *Journal of biomedical informatics*, 127, 103984.

49. He, K., Gan, C., Li, Z., Rekik, I., Yin, Z., Ji, W., Gao, Y., Wang, Q., Zhang, J., & Shen, D. (2022). Transformers in medical image analysis: A review. *arXiv preprint arXiv:2202.12165*. <https://arxiv.org/abs/2202.12165>
50. He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).
51. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
52. Himel, G. M. S., Hasan, M. S., Salsabil, U. S., & Islam, M. M. (2024). MedLingua: A conceptual framework for a multilingual medical conversational agent. *MethodsX*, 12, 102614.
53. Hosmer, David W.; Lemeshow, Stanley (2000). *Applied Logistic Regression* (2nd ed.). Wiley.
54. Houssein, E. H., Mohamed, R. E., & Ali, A. A. (2023). Heart disease risk factors detection from electronic health records using advanced NLP and deep learning techniques. *Scientific Reports*, 13(1), 7173.
55. Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., ... & Adam, H. (2019). Searching for mobilenetv3. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 1314-1324).
56. Huang, Z., Yang, J., van Harmelen, F., & Hu, Q. (2017). Constructing knowledge graphs of depression. In *International conference on health information science* (pp. 149-161). Cham: Springer International Publishing.
57. Hudelson, P., & Chappuis, F. (2024). Using voice-to-voice machine translation to overcome language barriers in clinical communication: an exploratory study. *Journal of General Internal Medicine*, 39(7), 1095-1102.
58. Jin, Y., Chandra, M., Verma, G., Hu, Y., De Choudhury, M., & Kumar, S. (2024, May). Better to ask in english: Cross-lingual evaluation of large language models for healthcare queries. In *Proceedings of the ACM Web Conference 2024* (pp. 2627-2638).
59. Jurafsky, D. & Martin, J. H. *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models* (3a. ed.). (2025). Manuscripto en línea. URL:
60. Kaswan, K. S., Gaur, L., Dhattewal, J. S., & Kumar, R. (2021). AI-based natural language processing for the generation of meaningful information electronic health record (EHR) data. In *Advanced AI techniques and applications in bioinformatics* (pp. 41-86). CRC Press.
61. Kazi, H., Chowdhry, B. S., & Memon, Z. (2012). MedChatBot: an UMLS based chatbot for medical students.
62. Khan, S., Naseer, M., Hayat, M., Zamir, S. W., Khan, F. S., & Shah, M. (2022). Transformers in vision: A survey. *ACM computing surveys (CSUR)*, 54(10s), 1-41.
63. Kohavi, R. (1995, August). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai* (Vol. 14, No. 2, pp. 1137-1145).
64. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
65. Lawson McLean, A., & Yen, T. L. (2024). Machine Translation for Multilingual Cancer Patient Education: Bridging Languages, Navigating Challenges. *Journal of Cancer Education*, 39(5), 477-478.
66. Lee, J., Yoon, W., Kim, S., Kim, D., Kim, S., So, C. H., & Kang, J. (2020). BioBERT: a pre-trained biomedical language representation model for biomedical text mining. *Bioinformatics*, 36(4), 1234-1240.
67. Li, T., Sahu, A. K., Talwalkar, A., & Smith, V. (2020). Federated learning: Challenges, methods, and future directions. *IEEE signal processing magazine*, 37(3), 50-60.
68. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
69. Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., ... & Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 10012-10022).
70. Luo, Y., Thompson, W. K., Herr, T. M., Zeng, Z., Berendsen, M. A., Jonnalagadda, S. R., ... & Starren, J. (2017). Natural language processing for EHR-based pharmacovigilance: a structured review. *Drug safety*, 40(11), 1075-1089.
71. MacQueen, J. (1967, January). Some methods for classification and analysis of multivariate observations. In *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics* (Vol. 5, pp. 281-298). University of California press.
72. Martinez, A. R. (2012). Part-of-speech tagging. *Wiley Interdisciplinary Reviews: Computational Statistics*, 4(1), 107-113.
73. Mienye, I. D., Swart, T. G., Obaido, G., Jordan, M., & Ilono, P. (2025). Deep convolutional neural networks in medical image analysis: A review. *Information*, 16(3), 195. <https://doi.org/10.3390/info16030195>
74. Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J. (2013). Distributed representations of words and phrases and their compositionality. *Advances in neural information processing systems*, 26.
75. Miller, G. A. (1995). WordNet: a lexical database for English. *Communications of the ACM*, 38(11), 39-41.

76. Mitchell, T. M. (1997). *Machine learning* (1st. ed.). McGraw Hill.
77. Moldt, J. A., Festl-Wietek, T., Madany Mamlouk, A., Nieselt, K., Fuhl, W., & Herrmann-Werner, A. (2023). Chatbots for future docs: exploring medical students' attitudes and knowledge towards artificial intelligence and medical chatbots. *Medical education online*, 28(1), 2182659.
78. Murali, Lino, G. Gopakumar, Daleesha M. Viswanathan, and Prema Nedungadi. "Towards electronic health record-based medical knowledge graph construction, completion, and applications: A literature study." *Journal of biomedical informatics* 143 (2023): 104403.
79. Narasimha Murty, M.; Susheela Devi, V. (2011). *Pattern Recognition: An Algorithmic Approach*. Springer.
80. Ng, S.K., Krishnan, T., McLachlan, G.J. (2012). The EM Algorithm. In: Gentle, J., Härdle, W., Mori, Y. (eds) *Handbook of Computational Statistics*. Springer Handbooks of Computational Statistics. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-21551-3_6
81. Pengpun, P., Tiankanon, K., Chinkamol, A., Kinchagawat, J., Chairuengjitjaras, P., Supholkhan, P., ... & Limkonchotiwat, P. (2024). On Creating an English-Thai Code-switched Machine Translation in Medical Domain. *arXiv preprint arXiv:2410.16221*.
82. Pu, Q., Xi, Z., Yin, S., Zhao, Z., & Zhao, L. (2024). Advantages of transformer and its application for medical image segmentation: A survey. *BioMedical Engineering OnLine*, 23(1), 14. <https://doi.org/10.1186/s12938-024-01212-4>
83. Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225*.
84. Rakesh Agrawal and Ramakrishnan Srikant. Fast algorithms for mining association rules. *Proceedings of the 20th International Conference on Very Large Data Bases, VLDB*, pages 487-499, Santiago, Chile, September 1994.
85. Rarhi, K., Bhattacharya, A., Mishra, A., & Mandal, K. (2017). Automated medical chatbot. *SSRN Electronic Journal*, 10.
86. Rodríguez-Ruiz, A., Krupinski, E., Mordang, J. J., Schilling, K., Heywang-Köbrunner, S. H., Sechopoulos, I., & Mann, R. M. (2019). Detection of breast cancer with mammography: effect of an artificial intelligence support system. *Radiology*, 290(2), 305-314.
87. Ronan, I. & Tabirca, S. (2024). Fine-Tuning Generative Pre-Trained Transformers for Clinical Dialogue Summarization, 2024 International Conference on Frontiers of Information Technology (FIT), Islamabad, Pakistan, 2024, pp. 01-06, DOI: 10.1109/FIT63703.2024.10838420.
88. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III* 18 (pp. 234-241). Springer international publishing.
89. Russell, S. & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4a. ed.). Pearson.
90. Safi, Z., Abd-Alrazaq, A., Khalifa, M., & Househ, M. (2020). Technical aspects of developing chatbots for medical applications: scoping review. *Journal of medical Internet research*, 22(12), e19127.
91. Shvets, A. A., Rakhlin, A., Kalinin, A. A., & Iglovikov, V. I. (2018, December). Automatic instrument segmentation in robot-assisted surgery using deep learning. In *2018 17th IEEE international conference on machine learning and applications (ICMLA)* (pp. 624-628). IEEE.
92. Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
93. Singleton, J., Li, C., Akpunonu, P. D., Abner, E. L., & Kucharska-Newton, A. M. (2023). Using natural language processing to identify opioid use disorder in electronic health record data. *International journal of medical informatics*, 170, 104963.
94. Solomon, M. D., Tabada, G., Allen, A., Sung, S. H., & Go, A. S. (2021). Large-scale identification of aortic stenosis and its severity using natural language processing on electronic health records. *Cardiovascular digital health journal*, 2(3), 156-163.
95. Srivastava, P., & Singh, N. (2020, February). Automatized medical chatbot (medibot). In *2020 International Conference on Power Electronics & IoT Applications in Renewable Energy and its Control (PARC)* (pp. 351-354). IEEE.
96. Suchanek, F. M., Kasneci, G., & Weikum, G. (2007, May). Yago: a core of semantic knowledge. In *Proceedings of the 16th international conference on World Wide Web* (pp. 697-706).
97. Sun, K., Xue, S., Sun, F., Sun, H., Luo, Y., Wang, L., ... & Dong, J. (2024). Medical Multimodal Foundation Models in Clinical Diagnosis and Treatment: Applications, Challenges, and Future Directions. *arXiv preprint arXiv:2412.02621*.
98. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
99. T. Cover and P. Hart, "Nearest neighbor pattern classification," in *IEEE Transactions on Information Theory*, vol. 13, no. 1, pp. 21-27, January 1967, doi: 10.1109/TIT.1967.1053964.

100. Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning (pp. 6105-6114). PMLR.
101. Titano, J. J., Badgeley, M., Schefflein, J., Pain, M., Su, A., Cai, M., ... & Oermann, E. K. (2018). Automated deep-neural-network surveillance of cranial images for acute neurologic events. *Nature medicine*, 24(9), 1337-1341.
102. Tjoa, E., & Guan, C. (2020). A survey on explainable artificial intelligence (xai): Toward medical xai. *IEEE transactions on neural networks and learning systems*, 32(11), 4793-4813.
103. Topol, E. (2019). *Deep medicine: how artificial intelligence can make healthcare human again*. Hachette UK.
104. Utunen, H., Staubitz, T., George, R., Zhao, Y. U., Serth, S., & Tokar, A. (2023). Scale up multilingualism in health emergency learning: developing an automated transcription and translation tool. In *Caring is sharing—exploiting the value in data for health and innovation* (pp. 408-412). IOS Press.
105. Van Veen, D., Van Uden, C., Blankemeier, L., Delbrouck, J. B., Aali, A., Bluethgen, C., ... & Chaudhari, A. S. (2024). Adapted large language models can outperform medical experts in clinical text summarization. *Nature medicine*, 30(4), 1134-1142.
106. Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20, 273-297.
107. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
108. Viterbi, A. (2003). Error bounds for convolutional codes and an asymptotically optimum decoding algorithm. *IEEE transactions on Information Theory*, 13(2), 260-269.
109. Walss, M., Anzengruber, F., Arafat, A., Djamei, V., & Navarini, A. A. (2021). Implementing medical chatbots: an application on hidradenitis suppurativa. *Dermatology*, 237(5), 712-718.
110. Wang, H., Zu, Q., Lu, M., Chen, R., Yang, Z., Gao, Y., & Ding, J. (2022). Application of medical knowledge graphs in cardiology and cardiovascular medicine: a brief literature review. *Advances in Therapy*, 39(9), 4052-4060.
111. Wang, Y., Tong, H., Zhu, Z., Hou, F., & Li, Y. (2025). Enhancing biomedical named entity recognition with parallel boundary detection and category classification. *BMC bioinformatics*, 26(1), 63.
112. Yao, W., Bai, J., Liao, W., Chen, Y., Liu, M., & Xie, Y. (2024). From CNN to transformer: A review of medical image segmentation models. *Journal of Imaging Informatics in Medicine*, 37(4), 1529–1547. <https://doi.org/10.1007/s10278-024-00981-7>
113. Zeng, Z., Deng, Y., Li, X., Naumann, T., & Luo, Y. (2018). Natural language processing for EHR-based computational phenotyping. *IEEE/ACM transactions on computational biology and bioinformatics*, 16(1), 139-153
114. Zhang, Y., Wang, J., Gorriz, J. M., & Wang, S. (2023). Deep learning and vision transformer for medical image analysis. *Journal of Imaging*, 9(6), 147. <https://doi.org/10.3390/jimaging9060147>
115. Zheng, S., Jayasumana, S., Romera-Paredes, B., Vineet, V., Su, Z., Du, D., ... & Torr, P. H. (2015). Conditional random fields as recurrent neural networks. In *Proceedings of the IEEE international conference on computer vision* (pp. 1529-1537).
116. Zhou, Z., Sodha, V., Rahman Siddiquee, M. M., Feng, R., Tajbakhsh, N., Gotway, M. B., & Liang, J. (2019). Models genesis: Generic autodidactic models for 3d medical image analysis. In *Medical Image Computing and Computer Assisted Intervention—MICCAI 2019: 22nd International Conference, Shenzhen, China, October 13–17, 2019, Proceedings, Part IV 22* (pp. 384-393). Springer International Publishing.
117. Zhu, H., Lin, M., Xu, Z., Yao, Z., Chen, H., Alhudhaif, A., & Alenezi, F. (2022). Deconv-transformer (DECT): A histopathological image classification model for breast cancer based on color deconvolution and transformer architecture. *Information Sciences*, 608, 1093–1112. <https://doi.org/10.1016/j.ins.2022.06.091>

3. USO DE LA IA EN LA INVESTIGACIÓN CLÍNICA ____ EN GINECOLOGÍA Y OBSTETRICIA

3. Uso de la IA en la investigación clínica en ginecología y obstetricia

Dr. Omar Alberto Hernandez Barboza

3.1. Introducción

La investigación clínica es el conjunto de estudios sistemáticos realizados en personas para generar conocimiento sobre la prevención, el diagnóstico, el tratamiento y el pronóstico de enfermedades o condiciones de salud. Su propósito principal es producir evidencia fiable que mejore la atención sanitaria, garantice la seguridad del paciente y oriente las decisiones clínicas y las políticas de salud.

La Inteligencia Artificial (IA) comprende técnicas computacionales que permiten a las máquinas realizar tareas asociadas a procesos de razonamiento, aprendizaje y toma de decisiones. En las últimas dos décadas, el acceso a grandes volúmenes de datos clínicos, el avance en hardware y el desarrollo de algoritmos más potentes han acelerado la adopción de la IA en la investigación biomédica.

Los objetivos específicos de la investigación clínica incluyen evaluar la eficacia y seguridad de intervenciones (fármacos, dispositivos, procedimientos), determinar la precisión y utilidad de pruebas diagnósticas, describir la historia natural de enfermedades y sus factores de riesgo, identificar y validar biomarcadores y fenotipos clínicos, establecer factores pronósticos y estratificar riesgos, optimizar protocolos terapéuticos y estrategias de prevención, así como evaluar la implementación y efectividad en la práctica real.

Existen diferentes tipos de estudios, entre los que destacan:

- **Ensayos Clínicos Aleatorizados (ECA):** Por ejemplo, comparar dos pautas de prevención de parto prematuro.
- **Estudios de Cohorte:** Por ejemplo, seguimiento de embarazadas con infección para evaluar desenlaces neonatales.
- **Estudios de Casos y Controles:** Por ejemplo, identificar factores asociados a preeclampsia severa.
- **Estudios Diagnósticos:** Por ejemplo, validar una prueba ecográfica automática para detectar cardiopatías fetales.
- **Estudios Pragmáticos e Implementación:** Por ejemplo, evaluar la integración de un sistema de soporte a la decisión clínica (CDS) para el manejo de hemorragia posparto en hospitales.

Los ensayos clínicos deben regirse por principios éticos y metodológicos clave para no atentar contra la salud de la humanidad y para garantizar que sean fiables y reproducibles. Por ello, deben incluir pasos ineludibles en toda investigación, como el uso de un consentimiento informado para que el paciente esté enterado de todo procedimiento que se llevará a cabo y de los riesgos asociados. Además, deben ser evaluados por comités de ética. Se requiere un diseño robusto para minimizar sesgos (aleatorización, control, cegamiento cuando sea posible) y asegurar la máxima confiabilidad del estudio. Es fundamental establecer un tamaño muestral y poder estadístico adecuados para que cada estudio tenga peso científico, y debe existir transparencia con un registro apropiado de protocolos y reportes completos según guías como CONSORT, STROBE y STARD. Todos los participantes deben contar con la seguridad de que no se violará la confidencialidad de la información, por lo que se realiza una protección de datos y respeto a la privacidad.

Finalmente, para comprender la investigación clínica, cada estudio debe tener resultados esperables y determinar su utilidad clínica.

3.2. Relación con la Inteligencia Artificial

La IA potencia la investigación clínica al acelerar el fenotipado, analizar grandes volúmenes de datos multimodales, mejorar la selección de cohortes y optimizar los diseños de ensayos. Sin embargo, su aplicación requiere rigor metodológico y validación prospectiva.

En ginecología, áreas como la imagenología prenatal y pélvica, la predicción de complicaciones obstétricas, el descubrimiento de biomarcadores en oncología ginecológica y la optimización de procesos en reproducción asistida se benefician de estas capacidades. No obstante, la promesa de la IA exige rigor metodológico, validación clínica y atención a problemas éticos, legales y de equidad.

3.3. Fundamentos y Terminología Clave

3.3.1. Tipos de Datos

- **Estructurados:** Datos demográficos, diagnósticos codificados (ICD), resultados de laboratorio, fármacos, procedimientos.
- **No Estructurados:** Notas de enfermería y médicas, cartas de alta, informes de imagen.
- **Imagenología:** Ecografías (2D/3D/4D), resonancia magnética pélvica, tomografía (poco usada en embarazo), imágenes histopatológicas digitalizadas.
- **Señales:** Cardiotocografía (CTG), registros de monitorización fetal, mediciones hemodinámicas.
- **-ómicas:** Genómica (WGS/WES), transcriptómica (RNA-seq), proteómica, metilómica.
- **Datos de Fuentes No Tradicionales:** *Wearables*, aplicaciones móviles, registros poblacionales y bases administrativas.

3.3.2. Técnicas y Paradigmas de IA

- **Aprendizaje Supervisado:** Modelos que aprenden a partir de ejemplos etiquetados (por ejemplo, clasificación de lesiones, predicción de parto prematuro). Algoritmos: regresión logística, árboles de decisión, *random forests*, *gradient boosting* (XGBoost, LightGBM), redes neuronales (MLP).
- **Aprendizaje No Supervisado:** Técnicas para descubrir estructuras latentes o subtipos sin etiquetas (*clustering*, PCA, t-SNE, UMAP, *autoencoders*).
- **Aprendizaje Semisupervisado y por Transferencia:** Aprovechan datos no etiquetados o modelos preentrenados para mejorar el rendimiento con menos datos etiquetados.
- **Aprendizaje Profundo (DL):** CNN para imágenes médicas, RNN/LSTM y *transformers* para series temporales y texto; arquitecturas híbridas para datos multimodales.
- **Modelos Generativos:** GANs y VAEs para aumento de datos sintéticos, simulación y anonimización.
- **Métodos de Interpretabilidad:** LIME, SHAP, mapas de activación (Grad-CAM), análisis de sensibilidad y extracción de reglas.

3.3.3. Métricas y Validación

- **Métricas en Clasificación:** Sensibilidad, especificidad, precisión (PPV), valor predictivo negativo (NPV), AUC-ROC, curva PR, F1-score.
- **Métricas en Regresión:** MAE, RMSE, R2, calibración, Brier score.

- **Validación:** Partición entrenamiento/validación/prueba, *cross-validation*, *bootstrap*, validación temporal, validación externa (cohorte independiente).
- **Consideraciones de Calibración y Utilidad Clínica:** *Net reclassification improvement* (NRI), *decision curve analysis* (DCA), análisis de utilidad clínica.

3.4. Diseño de Investigación con IA en Ginecología y Obstetricia

3.4.1. Definición de la Pregunta de Investigación

- Traducir la pregunta clínica a un problema computacional (por ejemplo: “predecir preeclampsia antes de la semana 20” → clasificación binaria con horizonte temporal)
- Establecer PICO adaptado: P (población), I (intervención o predictor), C (comparador), O (resultado), T (tiempo).
- Determinar si el objetivo es descubrimiento (generación de hipótesis), predicción, clasificación o causalidad (requiere enfoques y pruebas distintas).

3.4.2. Selección y Preparación de Datos

- **Inventario de Fuentes:** EHR, imágenes DICOM, bases poblacionales, biobancos con datos -ómicos, registros de ensayos clínicos.
- **Calidad de Datos:** Evaluación de integridad, duplicados, inconsistencias, patrones de datos faltantes (MCAR, MAR, MNAR).
- **Normalización y Estandarización:** Mapeo a ontologías (SNOMED CT, ICD-10, LOINC), unidades homogéneas, codificación consistente de variables categóricas.
- **Anotación y Gold Standard:** Definición de etiquetas confiables (diagnóstico por comité, consenso de expertos, hallazgos histopatológicos), procesos de etiquetado y control de calidad (*inter-rater reliability*, kappa).

3.4.3. Ética en la Obtención de Datos

- **Consentimiento y Reúso:** Clasificación entre datos con consentimiento explícito para IA, consentimiento amplio para investigación y uso secundario según la regulación local.
- **Anonimización y Riesgo de Reidentificación:** Técnicas de desidentificación, preservación de utilidad vs. privacidad.
- **Gobernanza:** Comités de datos, acuerdos de uso, auditoría y registros de acceso.

3.4.4. Tamaño Muestral y Necesidades Computacionales

- **Reglas Prácticas:** Modelos tradicionales requieren menos datos; el *deep learning* exige grandes volúmenes, especialmente para imágenes y modelos multimodales.
- **Estrategias Cuando los Datos Son Limitados:** *Augmentation* en imágenes, *transfer learning* con modelos preentrenados, etiquetas de “*weak supervision*”, generación de datos sintéticos con validación.
- **Infraestructura:** Servidores con GPU, almacenamiento seguro, sistemas de *backup*, control de versiones para datos y código.

3.4.5. Pipeline Analítico Reproducible

- **Etapas:** Extracción → preprocesamiento → división de datos → ingeniería de características/segmentación → entrenamiento → ajuste de hiperparámetros → evaluación → interpretación → documentación → despliegue experimental.
- **Herramientas Recomendadas:** Python (pandas, scikit-learn), *frameworks* DL (TensorFlow, PyTorch), bibliotecas médicas (MONAI), contenedores (Docker), *notebooks* versionados (Jupyter + git), y plataformas de CI/CD para MLops.
- **Reproducibilidad:** Fijar *seeds*, documentar versiones de librerías, conservar modelos y *checkpoints*, generar *scripts* ejecutables.

3.5. Aplicaciones Actuales por Área

3.5.1. Imagenología Prenatal y Ginecológica

Actualmente, el uso de imágenes en la especialidad ha cobrado mayor importancia en la toma de decisiones terapéuticas. Con ayuda de la IA, se puede lograr un uso dominante mediante redes neuronales convolucionales (CNNs) y arquitecturas U-Net para segmentación y detección. Por ejemplo, ya es posible realizar una medición biométrica fetal automática; existen modelos entrenados en miles de imágenes 2D que detectan planos estándar y realizan mediciones (CRL, BPD, HC, AC, FL). Implementaciones comerciales ya integradas en algunos equipos ecográficos ofrecen mediciones automáticas como herramienta de segundo lector. También se logra la detección de cardiopatías congénitas y malformaciones: CNNs aplicadas a clips y *frames*; algunos grupos utilizan *pipelines* que combinan detección de vistas (más clasificación) para reducir falsos positivos. En la calidad de imagen y *triage*, se crean modelos que etiquetan vistas aceptables vs. no aceptables para entrenamiento y auditoría de sonografistas.

3.5.2. Resonancia Magnética Pélvica y Estructural

- **Aplicaciones:** Caracterización de miomas, diagnóstico de adenomiosis, clasificación de masas anexiales, análisis radiómico para predicción pronóstica en neoplasias.
- **Ejemplo:** Radiómica + *machine learning* para diferenciar lesiones ováricas benignas de malignas usando secuencias T2 y difusión; extracción de cientos de *features* texturales y selección mediante LASSO, resultando en un AUC de 0.92 en la cohorte de derivación y 0.88 en validación externa.

Las metodologías y prácticas nos llevan a un preentrenamiento en grandes *datasets* públicos o propietarios y *fine-tuning* por centro. El uso de *data augmentation* (rotación, escalado, ruido) es fundamental para la robustez frente a la variabilidad de sondas y operadores. La validación externa en al menos una cohorte independiente es crucial para reportar la generalizabilidad.

Consideraciones Especiales: Heterogeneidad de equipos ecográficos, variabilidad del operador, necesidad de robustez frente a ruido y artefactos.

3.5.3. Monitorización Intraparto

La IA nos lleva a utilizar nuevas técnicas como RNN/LSTM, 1D-CNN, y recientemente *transformers* adaptados a series temporales. ¿Cómo se traduce esto en la vida cotidiana? A la lectura y detección de patrones de deceleración y predicción de acidosis neonatal o necesidad de intervención en los registros cardiotocográficos, donde en tiempo real se generan alertas con probabilidades y ventanas temporales de riesgo. Los resultados son prometedores en estudios retrospectivos (mejor sensibilidad que la lectura humana en algunos trabajos), pero existen preocupaciones sobre la *alarm-fatigue* (alertas excesivas) y la necesidad de validación prospectiva para demostrar una mejora en los resultados perinatales.

3.5.4. Predicción y Monitoreo de Desenlaces Obstétricos (por ejemplo, en Preeclampsia y Trastornos Hipertensivos del Embarazo)

Modelos integradores que combinan factores clínicos, demográficos, biomarcadores séricos y hallazgos ecográficos pueden mejorar la predicción temprana.

- **Ejemplo:** Modelo XGBoost entrenado con 30 variables clínicas y 10 biomarcadores que alcanzó un AUC de 0.87 para preeclampsia precoz; recalibración necesaria en poblaciones con distinta prevalencia.

3.5.6. Oncología Ginecológica

La IA está realizando la integración de radiómica y ML clásico (*autoaprendizaje automático*) como *random forest*, *gradient boosting* con DL (*Deep Learning*) en imágenes y *autoencoders* para datos -ómicos.

- **Por ejemplo:** La clasificación de masas anexiales en benignas vs. malignas mediante modelos que combinan imagen (RM/US) y variables clínicas (edad, CA-125).
- La identificación de subtipos moleculares en cáncer de ovario y endometrio mediante *clustering* sobre datos multi-ómicos.
- En el uso de la IA con la metodología, se ha utilizado para la selección de *features* radiómicos reproducibles mediante estandarización de segmentación y preprocesamiento (por ejemplo, *resampling* de vóxel). La validación en cohortes independientes y el uso de curvas ROC, análisis de decisión clínica y calibración son esenciales.

3.5.7. Reproducción Asistida (FIV/ICSI)

La utilización de modelos CNN y arquitecturas híbridas (CNN + LSTM) aplicados a *time-lapse* para clasificar embriones por probabilidad de implantación.

- Llevándolo a la práctica, estaríamos hablando de herramientas comerciales integradas a incubadoras *time-lapse* que generan *scores* de calidad embrionaria; utilizadas como soporte en la decisión de transferencia embrionaria.
- CNNs aplicadas a imágenes *time-lapse* para clasificar embriones por probabilidad de implantación y evolución hasta blastocisto.

- **Ejemplo:** Estudio multicéntrico con más de 10,000 videos *time-lapse* donde un modelo convolucional logró un AUC de 0.78 para la predicción de implantación; la implementación clínica exige controles randomizados y evaluación de impacto reproductivo.

3.5.8. Personalización de Protocolos de Estimulación

Modelos predictivos de respuesta ovárica y riesgo de hiperestimulación, incorporando edad, AMH, AFC y datos previos, permitiendo individualizar dosis y minimizar riesgos.

3.5.9. Investigación Basada en EHR y Datos Administrativos

Nos ayuda a las técnicas de modelos de *boosting* (XGBoost, LightGBM), redes neuronales para datos tabulares y LLMs/*transformers* para texto clínico.

- Como la identificación de cohortes para estudios (*fenotipado computacional*), cribado de eventos adversos y predicción de desenlaces (parto prematuro, readmisiones).
- Extracción automática de variables de interés de notas clínicas (por ejemplo, fecha de inicio de síntomas, hallazgos ecográficos) mediante procesamiento de lenguaje natural (NLP) clínico.

Para ejemplificar lo anterior, la IA está haciendo uso de *pipelines* de *phenotyping* con reglas + ML para mejorar la precisión y la revisión manual de muestras para estimar la exactitud y corregir el sesgo de etiquetado.

3.5.10. Salud Pública y Epidemiología Digital

Se está realizando la aplicación de modelos predictivos en bases poblacionales para mapear el riesgo geoespacial, prever brotes de enfermedades obstétricas o planificar recursos perinatales.

- **Herramientas:** Modelos de series temporales, modelos de supervivencia, modelos geoespaciales con ML.

3.6. Implementaciones Reales y Casos de Uso Institucionales

El uso de la IA en la investigación se está llevando a cabo en centros de referencia y hospitales universitarios con implementaciones por fases:

- **Fase 0 (Investigación):** Prototipos y análisis retrospectivos usando *datasets* locales.
- **Fase 1 (Piloto Controlado):** Integración con PACS/EHR para flujos de trabajo asistenciales con supervisión humana y recolección de métricas de proceso (tiempo de reporte, tasas de relectura).
- **Fase 2 (Evaluación Clínica):** Estudios prospectivos o estudios de impacto antes-después.
- **Fase 3 (Despliegue):** Integración con CDS y monitoreo *post-market*.

Por ejemplo, las unidades perinatales que integraron un sistema de medición biométrica automática en el ecógrafo reportaron una reducción en el tiempo de captura y menor variabilidad interoperatoria, manteniendo la concordancia diagnóstica.

3.6.1. Metodologías y Métricas Empleadas en Estudios Recientes

Existe una preferencia por AUC-ROC y sensibilidad/especificidad en estudios de diagnóstico; curvas PR en contextos con baja prevalencia. Sin embargo, es cada vez más creciente el uso de DCA (*Decision Curve Analysis*) para valorar la utilidad clínica; análisis de *net benefit* para distintos umbrales. También se está utilizando el reporte de calibración (curvas de calibración y Brier score) cada vez más frecuente.

Otra forma de aprovechar la IA es la evaluación en subgrupos: edad materna, etnia, centro clínico, equipo ecográfico — para detectar variaciones de desempeño y sesgos.

3.6.2. Validación y Generalización: Prácticas Actuales

En la investigación, la validación externa es un requisito cada vez más exigido por revisores y reguladores; los modelos que no muestran validación externa son considerados insuficientes. Por lo que se ha utilizado la IA para la recalibración: práctica común cuando se traslada un modelo a una población con distinta prevalencia. En estudios multicéntricos, es indispensable para demostrar robustez; el uso de *federated learning* como alternativa cuando compartir datos está restringido. Por otro lado, los ensayos prospectivos, aún escasos, están en aumento; muchos grupos planifican estudios controlados para demostrar impacto en resultados clínicos y flujo de trabajo.

3.6.3. Limitaciones Observadas en Implementaciones Prácticas de la IA

Dentro de las principales se encuentra la **heterogeneidad de datos**. Esto se refiere a las diferencias entre máquinas ecográficas, protocolos de adquisición, técnicas de tinción histológica y prácticas clínicas, y esto, a su vez, limita la transportabilidad.

Otra limitación es el **etiquetado de referencia imperfecto**. Los diagnósticos clínicos y códigos administrativos pueden contener errores; los *gold standards* (por ejemplo, hallazgo histopatológico) no siempre están disponibles.

El **sobreajuste a *datasets* de entrenamiento** lleva a modelos con rendimiento excelente en derivación que caen en la validación externa.

La **necesidad de integración con sistemas hospitalarios**, dependencias de infraestructura (GPU, almacenamiento) y soporte TI, ha creado problemas operativos en el desarrollo de protocolos.

Y existe una **resistencia por parte de profesionales** ante resultados de "caja negra" o cambios en el flujo de trabajo.

3.6.4. Consideraciones Regulatorias y de Gobernanza en Implementaciones Actuales

Muchas implementaciones se realizan inicialmente como herramientas de investigación o apoyo no reguladas; cuando la herramienta asume carácter diagnóstico o terapéutico, se requiere registro y aprobación (*software* como dispositivo médico). Las buenas prácticas adoptadas consisten en mantener registros de versiones, validación continua, planes de mitigación de riesgos y auditorías internas. Actualmente, los modelos comerciales tienden a incluir procesos de *post-market surveillance* y reentrenamiento controlado.

Marco Regulatorio del *Software* Médico

- Definir si la herramienta es un *software* médico con funciones diagnósticas o asistenciales. En tal caso, aplicar procesos regulatorios (por ejemplo, FDA, EMA, CE), ensayos clínicos y *post-market surveillance*.
- **Importante:** Documentación técnica, gestión de riesgos, planes de actualización y evidencia clínica que soporte las afirmaciones (*claims*).

3.6.5. Lecciones Prácticas para Diseñar Investigación Clínica con IA Hoy

- Planear la validación externa desde el diseño y, si es posible, la colaboración multicéntrica para aumentar la representatividad.
- Implementar *pipelines* de control de calidad de datos y procesos de etiquetado con múltiples expertos y métricas de concordancia.
- Evaluar no solo métricas técnicas, sino también la utilidad clínica mediante DCA, análisis de impacto en procesos y resultados clínicos.
- Anticipar los requisitos regulatorios y documentar el ciclo de vida del modelo (*dataset*, preprocesamiento, arquitectura, hiperparámetros, evaluación).
- Diseñar interfaces de usuario y flujos clínicos que incorporen la IA como asistente y faciliten la revisión humana; entrenar a los equipos clínicos en la interpretación y las limitaciones del modelo.

3.6.6. Ejemplos de Publicaciones y Consorcios Recientes de Referencia

Avanzando a pasos agigantados, actualmente podemos ver el uso de esta herramienta en diferentes ámbitos de la investigación clínica, como son:

- ***Multicenter studies on fetal ultrasound and AI:*** Consorcios europeos y asiáticos han publicado validaciones externas y protocolos estandarizados para crear *datasets* más grandes y diversos.
- ***Consortia de infertilidad y embriones:*** Agrupaciones de clínicas que comparten datos (a menudo anonimizados) para robustecer modelos de clasificación embrionaria.
- ***Proyectos de federated learning:*** Redes de hospitales que entrenan modelos conjuntos sin compartir datos, reportando un desempeño cercano al entrenamiento centralizado en algunos casos.

3.6.7. Tendencias a Corto y Mediano Plazo en Práctica Clínica e Investigación

Es importante recalcar que hay un aumento de ensayos prospectivos y estudios de impacto; exigencia regulatoria y necesidad de evidencia de beneficios clínicos reales.

La mayor adopción de *federated learning* y técnicas de privacidad diferencial para colaboración internacional y el uso creciente de LLMs clínicos para la extracción de variables y la generación de hipótesis, con validación humana necesaria.

Se trabaja en el desarrollo de marcos de interpretabilidad más amigables para clínicos (visualizaciones integradas en EHR y explicación de aportes por variable).

3.7. Recomendaciones Operativas para Centros que Desean Comenzar Implementaciones de la IA en la Investigación Clínica

Primero, iniciar con proyectos de alto valor clínico y baja complejidad técnica (por ejemplo, mediciones biométricas automáticas, *triage* de imágenes) y establecer la gobernanza de datos, comités multidisciplinarios y acuerdos de colaboración con TI y bioinformática.

Realizar pilotos controlados con métricas de proceso y de resultado bien definidas; recopilación de *feedback* de usuarios.

Destinar un presupuesto para infraestructura, mantenimiento y actualización continua del modelo; planificar educación continua para usuarios clínicos.

Formular preguntas clínicas relevantes y traducibles a problemas computacionales. Conformar un equipo multidisciplinario: clínicos, estadísticos, *data scientists*, ingenieros, expertos en ética y regulatorio; se debe involucrar a los usuarios finales desde etapas tempranas (médicos, enfermería, pacientes) para un diseño centrado en la utilidad clínica.

3.7.1. Diseño y Reporte

- Seguir guías de reporte: TRIPOD-AI para modelos predictivos, CONSORT-AI para ensayos, STARD-AI para pruebas diagnósticas; registrar protocolos y análisis planificados.
- Documentar metadatos, diccionarios y *pipelines* completos.

3.7.2. Validación y Generalización

- Planificar validación externa y prospectiva; evaluar calibración y desempeño según subgrupos.
- Evaluar impacto en resultados clínicos relevantes y costo-efectividad.

3.7.3. Reproducibilidad y Transparencia

- Compartir código y modelos cuando sea posible; usar contenedores y *pipelines* reproducibles; versionar datos y *scripts*.
- Mantener registros de cambios y justificar actualizaciones del modelo.

3.7.4. Implementación y Mantenimiento

- Pilotos controlados antes del despliegue amplio; integración con el flujo clínico y EHR.
- Planes de monitoreo posimplementación: *drift* del modelo, rendimiento en tiempo real, reevaluaciones periódicas.

3.8. Ejemplos Detallados de Estudios Representativos

Caso 1: Modelo Predictivo de Preeclampsia de Inicio Temprano

- **Diseño:** Estudio multicéntrico retrospectivo con 15,000 embarazos; variables incluyeron edad materna, índice de masa corporal, historial obstétrico, presión arterial basal, biomarcadores séricos (PIGF, PAPP-A) y hallazgos ecográficos tempranos.
- **Métodos:** XGBoost con ajuste de hiperparámetros mediante búsqueda bayesiana; validación interna con *5-fold cross-validation* y validación externa en una cohorte independiente de 3,000 embarazos.
- **Resultados:** AUC 0.88 (95% CI 0.86–0.90) en validación externa; curva de calibración aceptable tras recalibración. El *Decision Curve Analysis* mostró beneficio clínico neto para umbrales clínicos relevantes.
- **Lecciones:** Importancia de incluir biomarcadores y de la recalibración por prevalencia; necesidad de un ensayo prospectivo para evaluar la reducción de eventos adversos mediante intervenciones tempranas.

Caso 2: Selección de Embriones con CNN en *Time-Lapse*

- **Diseño:** Base de datos de 12,000 videos *time-lapse* de embriones derivados de múltiples clínicas; resultado: implantación confirmada por β -hCG y ecografía.
- **Métodos:** Modelo CNN + LSTM para capturar morfocinética temporal; entrenamiento con *stratified sampling* por clínica; validación interna y evaluación multicéntrica.
- **Resultados:** AUC 0.78 para la predicción de implantación; tasas de implantación incrementadas en cohortes retrospectivas cuando se priorizaron embriones con mayor *score* de IA.
- **Limitaciones:** Necesidad de ensayos aleatorizados para confirmar el beneficio y riesgo de sesgo por prácticas clínicas heterogéneas entre centros.

Caso 3: Detección de Malformaciones Fetales en Ecografía

- **Diseño:** Red CNN entrenada con 8,000 clips y 25,000 imágenes etiquetadas por especialistas; resultados: detección de anomalías estructurales clave (cardíacas, craneales, renales).
- **Resultados:** Sensibilidades entre 85–94% y especificidades entre 88–95% para distintas anomalías en validación externa; reducción del tiempo de revisión por parte del ecografista.
- **Consideraciones:** La IA se propone como herramienta de apoyo, no sustituto; es necesario producir guías para el manejo de falsos positivos y falsos negativos.

3.9. Recursos Prácticos: Herramientas y Repositorios que se Pueden Utilizar para Alimentar a la IA y Desarrollar Investigación Clínica Confiable

- **Lenguajes y Bibliotecas:** Python (pandas, scikit-learn), TensorFlow, Keras, PyTorch, XGBoost, LightGBM.
- **Bibliotecas Médicas:** MONAI (imágenes médicas), SimpleITK, OpenCV.
- **Plataformas y Ecosistemas:** NVIDIA Clara, TensorFlow Federated, Flower (*federated learning*), Docker, GitHub/GitLab.
- **Repositorios de Datos y Conjuntos:** PhysioNet, The Cancer Imaging Archive (TCIA), bancos locales de imágenes/biobancos del país.

- **Guías de Reporte:** TRIPOD-AI, CONSORT-AI, SPIRIT-AI, STARD-AI.

3.9.1. Limitaciones de Evidencia y Prioridades de Investigación Futura

- Necesidad de ensayos prospectivos y estudios de impacto clínico que vayan más allá de métricas técnicas.
- Evaluaciones multicéntricas y multiculturales que garanticen la generalizabilidad.
- Investigación en métodos de interpretabilidad clínicamente útiles y en la reducción de sesgos.
- Estudios sobre costo-efectividad y aceptación por parte de profesionales y pacientes.

3.9.2. Checklist Resumido para Evaluar Estudios de IA en Investigación Aplicada en Ginecología y Obstetricia

La IA es una herramienta que debes utilizar de manera confiable, pero es crucial saber cómo hacerlo. Por ello, se sugiere seguir estos pasos para establecer una investigación sólida:

- ¿Pregunta clínica claramente definida?
- ¿Dataset suficiente y representativo? ¿Anotaciones con *gold standard*?
- ¿Preprocesamiento y *pipeline* documentados?
- ¿Validación interna y externa reportadas?
- ¿Métricas técnicas y evaluación clínica (DCA, calibración) incluidas?
- ¿Evaluación de sesgos y desempeño por subgrupos?
- ¿Plan de implementación y gobernanza descrito?
- ¿Cumplimiento regulatorio/ético abordado?

Bibliografía

1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med.* 2019 Jan;25(1):44–56.
2. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nat Med.* 2019 Jan;25(1):24–29.
3. Beam AL, Kohane IS. Big data and machine learning in health care. *JAMA.* 2018 Apr 3;319(13):1317–1318.
4. Collins GS, Moons KGM. Reporting of artificial intelligence prediction models. *Lancet.* 2019 Jul 20;393(10181):1577–1579.
5. Liu X, Cruz Rivera S, Moher D, Calvert MJ, Denniston AK; CONSORT-AI Steering Group. Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension. *Nat Med.* 2020 Sep;26(9):1364–1374.
6. Liu X, Faes L, Kale AU, Wagner SK, Fu DJ, Bruynseels A, et al. A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *Lancet Digit Health.* 2019 Oct;1(6):e271–e297.
7. Kelly CJ, Karthikesalingam A, Suleyman M, Corrado G, King D. Key challenges for delivering clinical impact with artificial intelligence. *BMC Med.* 2019 Apr 11;17(1):195.
8. Moor MPJ, de Bruin K, van Ginneken B, de Jonge GA, Benders MJNL, de Vries LS. Artificial intelligence in fetal ultrasound imaging: Current status and future perspectives. *Ultrasound Obstet Gynecol.* 2021 Feb;57(2):174–184.
9. Alsolamy S, Fayadh M, Qamar S, Siddiqui T, Chen X, Huang J, et al. Machine learning and deep learning methods for fetal health assessment from cardiotocography: A systematic review. *Comput Biol Med.* 2021 Jun;133:104360.
10. Baumgartner CF, Kamnitsas K, Matthew J, Fletcher TP, Smith A, Koch LM, et al. SonoNet: real-time detection and localisation of fetal standard scan planes in freehand ultrasound. *IEEE Trans Med Imaging.* 2017 Nov;36(11):2204–2215.

11. Looney P, Hwang M, Dalal S, Lees CC, Hayat T, Thangaratinam S. Artificial intelligence (AI) for the detection of fetal heart anomalies: a systematic review. *Ultrasound Obstet Gynecol.* 2020 Jun;55(6):806–814.
12. Gandomkar Z, Brennan PC. Deep learning in medical imaging: an overview. *Med J Aust.* 2019 Jan;211(1):5–6.
13. Hashimoto DA, Rosman G, Rus D, Meireles OR. Artificial intelligence in surgery: promises and perils. *Ann Surg.* 2018 Jan;268(1):70–76.
14. Komorowski M, Celi LA, Badawi O. The artificial intelligence clinician learns optimal treatment strategies for sepsis in intensive care. *Nat Med.* 2018 Nov;24(11):1716–1720.
15. Nagelkerke N, Overvest JB, de Vries H, Louwman M, van Trigt M, Verhoef C, et al. Machine learning to identify factors associated with progression to high-grade serous ovarian cancer. *Gynecol Oncol.* 2021 Apr;161(1):141–147.
16. Khosravi P, Kazemi E, Imielinski M, Elemento O, Hajirasouliha I. Deep convolutional neural networks enable discrimination of heterogeneous digital pathology images. *EBioMedicine.* 2018 Apr;27:317–328.
17. Tran MN, Wang Y, Walle CV, McClendon J, Vinters HV, Haskell JP, et al. Radiomics and machine learning for the classification of adnexal masses on MRI: a multi-center study. *Eur Radiol.* 2022 Mar;32(3):1825–1835.
18. Khosravi P, Cao A, Tabrizi S, et al. Machine learning-assisted embryo selection in IVF: a systematic review. *Reprod Biomed Online.* 2021 Sep;43(3):588–600.
19. Meseguer M, Rubio I, Martínez F, Remohí J, Pellicer A. Embryo selection by time-lapse imaging and morphokinetic scoring: a prospective multicentre randomized controlled trial. *Hum Reprod.* 2020 Dec;35(12):2708–2716.
20. Pova C, Machado J, Sampaio P, Martins C, Rodrigues D, Nunes A. Artificial intelligence in obstetric triage: automated detection of high-risk pregnancies using administrative and clinical data. *BMC Pregnancy Childbirth.* 2022 Jan 7;22(1):31.
21. Collins FS, Varmus H. A new initiative on precision medicine. *N Engl J Med.* 2015 Feb 26;372(9):793–795.
22. Denny JC, Ritchie MD, Basford MA, Pulley JM, Bastarache L, Brown-Gentry K, et al. PheWAS: demonstrating the feasibility of a phenome-wide scan to discover gene–disease associations. *Bioinformatics.* 2010 May 1;26(9):1205–1210.
23. Rajkomar A, Dean J, Kohane I. Machine learning in medicine. *N Engl J Med.* 2019 Apr 4;380(14):1347–1358.
24. Wiens J, Saria S, Sendak M, Ghassemi M, Liu VX, Doshi-Velez F, et al. Do no harm: a roadmap for responsible machine learning for health care. *Nat Med.* 2019 Sep;25(9):1337–1340.
25. Roberts M, Driggs D, Thorpe M, Gilbey J, Yeung M, Ursprung S, et al. Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans. *Nat Mach Intell.* 2021 Mar;3(3):199–217.
26. Vayena E, Blasimme A, Cohen IG. Machine learning in medicine: addressing ethical challenges. *PLoS Med.* 2018 Nov 27;15(11):e1002689.
27. Narayanaswamy A, Peng J, Zepeda I, Stumpe MC. Regulatory considerations for AI-based medical devices: the path ahead. *Nat Med.* 2021 May;27(5):802–803.
28. Liu X, The SPIRIT-AI and CONSORT-AI Study Group. SPIRIT-AI and CONSORT-AI: new reporting guidelines for clinical trials involving artificial intelligence. *Lancet Digit Health.* 2020 Oct;2(10):e538–e539.
29. Yoon HJ, Lee JB, Lee GS, Kim JW, Park BJ, Lee N, et al. Federated learning for predicting clinical outcomes in patients with COVID-19: multicenter development and validation study. *J Med Internet Res.* 2021 Jun 1;23(6):e24207.
30. Sheller MJ, Edwards B, Reina GA, Martin J, Pati S, Kotrotsou A, et al. Federated learning in medicine: facilitating multi-institutional collaborations without sharing patient data. *Sci Rep.* 2020 Jul 28;10(1):12598.
31. Ghassemi M, Oakden-Rayner L, Beam AL. The false hope of current approaches to explainable artificial intelligence in health care. *Lancet Digit Health.* 2021 Nov;3(11):e745–e750.
32. Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. *J Big Data.* 2019 Jun 27;6:60.
33. Challen R, Denny J, Pitt M, Gompels L, Edwards T, Tsaneva-Atanasova K. Artificial intelligence, bias and clinical safety. *BMJ Qual Saf.* 2019 Mar;28(3):231–237.
34. Liu H, Peng S, Huang J, Chen Z, Huang T, Yang K, et al. Machine learning approaches for predicting postpartum hemorrhage: a systematic review and meta-analysis. *J Matern Fetal Neonatal Med.* 2023;36(6):1142–1152.
35. Rennie J, Tognini A, Carty C, McNally E, Burke G, Thomson A, et al. Artificial intelligence in gynecologic oncology: radiomics, deep learning and beyond. *Gynecol Oncol.* 2022 Nov;167(2):335–346.
36. Rajkomar A, Oren E, Chen K, Dai AM, Hajaj N, Hardt M, et al. Scalable and accurate deep learning with electronic health records. *NPJ Digit Med.* 2018 Sep 3;1:18.
37. Ranzani OT, Nascimento JM, de Almeida-Neto C, Carvalho F, Soares M. Machine learning for prognostication in critical care: a systematic review of methodology and reporting. *Crit Care.* 2020 Jan 7;24(1):5.

38. Shortliffe EH, Sepúlveda MJ. Clinical decision support in the era of artificial intelligence. *JAMA*. 2018 Jun 12;320(21):2199–2200.
39. Wiens J, Shenoy ES. Machine learning for healthcare: on the verge of a major shift in healthcare delivery? *JAMA*. 2018 Apr 3;319(13):1317–1318.
40. Hoeks S, Zeeman GG. Ethical considerations of artificial intelligence in obstetrics. *Best Pract Res Clin Obstet Gynaecol*. 2023 May;86:35–48.

4. IA EN OBSTETRICIA

4. IA en obstetricia

Dr. Rodrigo Orozco (Málaga-Quironsalud)

La obstetricia es, por su naturaleza, una de las disciplinas médicas más sensibles a la evolución tecnológica. La necesidad de tomar decisiones clínicas en tiempo real, valorar simultáneamente el estado materno y fetal, anticipar complicaciones potencialmente graves y gestionar el proceso del parto con precisión, convierte al ámbito obstétrico en un terreno fértil —y al mismo tiempo desafiante— para la incorporación de herramientas basadas en inteligencia artificial (IA).

En los últimos años, la IA ha comenzado a transformar la forma en que se aborda el seguimiento del embarazo, el diagnóstico prenatal y la planificación del parto. Mediante algoritmos de aprendizaje automático, redes neuronales profundas y sistemas de apoyo a la decisión clínica, la IA permite analizar grandes volúmenes de datos clínicos, ecográficos, genéticos y biofísicos para generar modelos predictivos, automatizar la interpretación de señales biomédicas o sugerir estrategias terapéuticas adaptadas a cada situación obstétrica.

Uno de los grandes atractivos de la IA en obstetricia es su capacidad para detectar patrones que podrían pasar desapercibidos al ojo clínico, especialmente en contextos de sobrecarga asistencial, falta de especialistas o situaciones de incertidumbre diagnóstica. Por ejemplo, en el análisis del registro cardiotocográfico, la IA puede reducir la variabilidad interobservador, identificar combinaciones de patrones complejos y emitir alertas tempranas sobre riesgo de hipoxia o sufrimiento fetal.

Asimismo, el diagnóstico prenatal se está beneficiando del uso de algoritmos que integran datos de imagen, biomarcadores y características clínicas para mejorar la detección de malformaciones congénitas, trastornos del crecimiento intrauterino o síndromes genéticos. La segmentación automática de estructuras fetales, la reconstrucción tridimensional guiada por IA o la predicción de alteraciones doppler se están consolidando como herramientas de ayuda para el ecografista y el especialista en medicina fetal.

Por otra parte, la predicción de complicaciones como la preeclampsia, el parto prematuro, el retraso de crecimiento intrauterino o la diabetes gestacional está avanzando con modelos que combinan aprendizaje supervisado, análisis longitudinal de variables y entrenamiento multicéntrico. Estos modelos no solo mejoran la capacidad de anticipación del clínico, sino que abren la puerta a estrategias de medicina personalizada y estratificación de riesgo más eficientes.

En el entorno del parto, la IA puede integrarse en sistemas inteligentes de monitorización intraparto, interpretación automática de señales, evaluación del canal del parto mediante imágenes y optimización de tiempos de intervención. Algunos estudios ya exploran el uso de simulaciones en tiempo real para valorar la progresión del parto y proponer alternativas basadas en datos históricos, biomecánicos y contextuales.

No obstante, el uso de IA en obstetricia plantea también interrogantes éticos y operativos: ¿Cómo se garantiza la explicabilidad y la validación clínica de los algoritmos? ¿Cuál es el papel del profesional frente a una recomendación automatizada? ¿Qué grado de responsabilidad clínica se mantiene? ¿Están representadas adecuadamente todas las poblaciones obstétricas en los modelos entrenados?

Este capítulo pretende ofrecer una visión actualizada, crítica y aplicada sobre las principales aplicaciones de la inteligencia artificial en obstetricia. Cada sección profundiza en un aspecto clave: diagnóstico prenatal, seguimiento del bienestar fetal, predicción de complicaciones y apoyo a la toma de decisiones en el parto. A través de estas áreas se busca mostrar tanto el potencial transformador como las limitaciones y retos que conlleva la implementación responsable de la IA en el cuidado obstétrico.

4.1 Diagnóstico prenatal asistido por IA

Dra. Alba Farras Llobet y Dra. Ma. Ángeles Sánchez (Barcelona)

El uso de inteligencia artificial (IA) en el diagnóstico prenatal, particularmente mediante aprendizaje profundo (deep learning) y redes neuronales convolucionales (CNN), ha emergido como una herramienta prometedora para apoyar a los especialistas en la identificación de problemas fetales. La IA puede analizar grandes volúmenes de datos de imágenes ecográficas para detectar patrones sutiles que pudieran indicar malformaciones o alteraciones del crecimiento, tareas que tradicionalmente dependen en gran medida de la experiencia del operador. Dado que alrededor del 3% de los embarazos presentan anomalías fetales estructurales detectables y que la eficacia de la ecografía convencional puede verse limitada por la habilidad del ecografista y la calidad de la imagen, la incorporación de sistemas de IA busca estandarizar y mejorar la precisión diagnóstica (1). A continuación, se abordan dos aplicaciones clínicas fundamentales: la detección de malformaciones congénitas y la monitorización del crecimiento fetal, seguidas de una evaluación crítica de la validación y limitaciones de estos sistemas.

4.1.1 Detección de malformaciones congénitas

La detección ecográfica de malformaciones fetales es un pilar del diagnóstico prenatal, pero supone un desafío significativo. Pese a los programas de cribado ecográfico casi universales, una proporción importante de anomalías estructurales puede pasar desapercibida en la ecografía rutinaria de las 20 semanas (en muchos entornos, las tasas de detección de anomalías frecuentes no superan el 50%) (2). Esto se debe en parte a la variabilidad interobservador y a la dependencia de la pericia del operador: distintos ecografistas pueden obtener cortes diferentes y cometer errores de medición, con variaciones reportadas de ~5–11% en parámetros biométricos clave (2). En este contexto, la IA aporta la capacidad de reconocimiento automatizado de estructuras y lesiones en las imágenes, ofreciendo un "segundo par de ojos" digital que puede señalar hallazgos anómalos al examinador. Técnicas de aprendizaje profundo, especialmente las redes neuronales convolucionales, han logrado avances notables en tareas como la clasificación de órganos fetales, segmentación de estructuras anatómicas (ej. delimitación del corazón o cerebro fetal) y la detección de anomalías en ecografías obstétricas. De hecho, ya se han desarrollado numerosos modelos de IA capaces de reconocer automáticamente defectos cardíacos, malformaciones del sistema nervioso central (SNC), anomalías renales y otras alteraciones congénitas en imágenes prenatales.

Un ejemplo concreto es el de las cardiopatías congénitas (CHD). Aún con ecografías estándar, una parte sustancial de los defectos cardíacos fetales no se diagnostica antes del nacimiento, lo que puede conllevar morbilidad severa. Modelos de *deep learning* entrenados para analizar las vistas cardíacas fetales han mostrado mejorar significativamente esta situación. En un estudio reciente, un algoritmo de *deep learning* detectó CHD con una sensibilidad del 91% y especificidad del 78%, superando ampliamente la sensibilidad del cribado clínico habitual (~53% en ese estudio) y el desempeño de expertos revisores que analizaban las mismas imágenes (3). Es notable que el modelo mantuvo un buen rendimiento incluso ante lesiones que no formaban parte de sus datos de entrenamiento, detectando correctamente 16 de 19 casos nuevos, lo que sugiere una capacidad de generalización más allá de su experiencia previa. De igual modo, en el ámbito de las malformaciones cerebrales fetales, un ensayo clínico aleatorizado evaluó un sistema de IA (denominado PAICS) para analizar neurosonogramas fetales. Este asistente logró elevar la precisión diagnóstica de los ecografistas del 73% (sin ayuda) a aproximadamente 80–82% con la ayuda de IA, incrementando el área bajo la curva (AUC) de 0.85 a ~0.90 en la detección de anomalías intracraneales (4). La mejora fue estadísticamente significativa sin un impacto significativo en el tiempo de interpretación, demostrando cómo la IA puede aumentar (no reemplazar) el rendimiento del profesional.

Figura 1. Imagen adaptada de la publicación de Athalye *et al.* (3) Imágenes etiquetadas por el modelo (en escala de grises) junto con las correspondientes representaciones Grad-CAM, que muestran mapas de calor que delimitan las regiones de la imagen con mayor relevancia en el proceso de decisión del modelo.

Otra estrategia asistencial de IA consiste en estandarizar la adquisición de imágenes. Por ejemplo, algoritmos que reconocen automáticamente los planos ecográficos estándar (vista de cuatro cámaras cardíacas, plano transventricular cerebral, etc.) pueden alertar al operador si alguna vista clave no ha sido obtenida o si la calidad de la imagen es insuficiente (5). Algunos fabricantes de ecógrafos ya han integrado herramientas de IA en sus equipos clínicos para guiar al operador durante la ecografía morfológica, identificar automáticamente estructuras fetales y realizar mediciones básicas. Estas innovaciones buscan reducir la dependencia de la habilidad individual y lograr un examen anatómico más completo y homogéneo entre diferentes operadores.

En cuanto a ejemplos prácticos, cabe mencionar proyectos en desarrollo que ilustran el potencial de la IA en la detección de malformaciones. El proyecto EmbryoScan, desarrollado en Barcelona (Hospital Universitario Vall d'Hebron y Universitat Pompeu Fabra), es una plataforma basada en IA que pretende fusionar múltiples barridos ecográficos 2D para reconstruir volúmenes 3D de alta fidelidad del embrión (6). Al generar una visión tridimensional temprana y más clara del embrión o feto, combinada con algoritmos de segmentación y medición automatizada, EmbryoScan permitiría una detección más rápida y precisa de anomalías congénitas, a la vez que disminuiría de forma notable la dependencia del operador humano. Si bien EmbryoScan se halla en fase de investigación, representa el tipo de herramienta que podría integrarse en la práctica en el futuro cercano, complementando la ecografía convencional con reconstrucciones 3D asistidas por IA para mejorar el *screening* de malformaciones.

4.1.2 Monitorización del crecimiento fetal

La monitorización del crecimiento y bienestar fetal es otra área clave del cuidado prenatal donde la IA está demostrando su utilidad. Tradicionalmente, la valoración del crecimiento fetal se basa en mediciones biométricas seriadas (diámetro biparietal, circunferencia cefálica, circunferencia abdominal, longitud femoral, estimación de peso fetal, etc.) obtenidas por ecografía en distintos trimestres. Estas mediciones sirven para trazar curvas de crecimiento y detectar condiciones como la restricción del crecimiento intrauterino (RCIU) o la macrosomía fetal. Sin embargo, el proceso manual de obtención de biometrías es lento, laborioso y sujeto a variabilidad, ya que depende de que el operador identifique el plano exacto y coloque los *cálipers* con precisión reproducible. Errores pequeños en la medición pueden traducirse en diferencias significativas en la estimación de peso o edad gestacional, afectando la toma de decisiones clínicas. Además, la calidad de las imágenes y la pericia técnica influyen directamente en la exactitud: imágenes subóptimas por mala técnica conllevan predicciones inexactas de peso al nacer (5).

La IA, a través de algoritmos de visión computacional, aborda estas limitaciones mediante la automatización de las medidas y la evaluación inteligente de las imágenes. Por ejemplo, se han desarrollado sistemas que identifican automáticamente los planos ecográficos estandarizados para biometría (como el plano trans talámico, el plano abdominal y el plano longitudinal de fémur) y colocan los *cálipers* de medida de forma autónoma. Un estudio reciente evaluó un *software* comercial avanzado, llamado CUPID, diseñado para medir automáticamente nueve parámetros biométricos fetales en el segundo trimestre. En una muestra de 642 fetos de ~22 semanas, CUPID logró colocar correctamente las marcas de medición sin necesidad de ajuste en el 90–96% de las imágenes analizadas, un rendimiento equiparable al de un ecografista experto y superior al de operadores menos experimentados (quienes lograron entre 70% y 92% de colocaciones correctas) (7). La fiabilidad de las medidas automáticas de IA mostró una correlación muy alta con las obtenidas por expertos (coeficientes de correlación intraclase >0.84 en todos los parámetros), superando claramente la concordancia

entre operadores humanos de distinto nivel. Asimismo, la eficiencia fue notable: el algoritmo tardó *on-line* del orden de 0.05 a 0.07 segundos en obtener todas las mediciones de un feto, mientras que los especialistas requirieron entre 5 y 13 segundos para realizar esas mediciones manualmente. En resumen, herramientas como CUPID han demostrado ser altamente precisas y veloces para la medición automatizada de la biometría fetal, proporcionando resultados prácticamente equivalentes a los de un experto, pero en una fracción mínima del tiempo. Estas capacidades pueden traducirse en evaluaciones de crecimiento más objetivas, reducción de la carga de trabajo y disminución de la variabilidad entre ecografistas.

Más allá de la simple medición, la IA también está revolucionando la forma en que se analizan los datos de crecimiento. Nuevos enfoques emplean *deep learning* para extraer información de la secuencia completa de imágenes o videos ecográficos, en lugar de solo fotogramas aislados. Por ejemplo, se ha propuesto un método de estimación “holística” en el que una red neuronal analiza cada fotograma de la secuencia de ultrasonido de la ecografía de rutina (p. ej., de la semana 20) y realiza miles de mediciones automáticas de diferentes estructuras en todas las vistas posibles (2). Posteriormente, estos datos masivos se integran mediante algoritmos bayesianos para obtener un valor final de cada parámetro biométrico con intervalos de confianza, descartando automáticamente valores atípicos. En un estudio retrospectivo con 1.457 ecografías completas (alrededor de 48 millones de fotogramas analizados), esta estrategia totalmente automática alcanzó un rendimiento equiparable al humano en la estimación de todas las biometrías clave, demostrando la viabilidad de un análisis exhaustivo *frame a frame* sin intervención del operador (2). La promesa de este tipo de tecnología es eliminar sesgos de selección de imágenes (cada operador tiende a escoger cortes ligeramente distintos) y aprovechar al máximo la naturaleza en tiempo real de la ecografía, aumentando la veracidad y reproducibilidad de las medidas. En última instancia, un sistema así podría detectar con mayor sensibilidad desviaciones sutiles en el patrón de crecimiento fetal a lo largo del embarazo, alertando tempranamente de un posible RCIU incipiente o confirmando la normalidad con mayor confianza.

Otra vertiente interesante es el empleo de IA para proporcionar retroalimentación en tiempo real al operador durante la ecografía. Investigadores han desarrollado modelos de IA explicables (XAI) que no solo realizan clasificaciones, sino que también señalan si la imagen obtenida cumple criterios de calidad o qué mejoras son necesarias. Por ejemplo, un estudio multicéntrico reciente implementó un sistema de XAI para asistir en ecografías de crecimiento, proporcionando comentarios sobre la calidad del plano y destacando las referencias anatómicas clave en pantalla (5). En la validación prospectiva con usuarios finales, el modelo pudo distinguir automáticamente la calidad de los cortes estándares (p. ej., si un plano estaba adecuadamente centrado y con las referencias completas) con una exactitud del 96.3%, equiparable a la evaluación humana. Además, las explicaciones generadas por la IA (marcando contornos de estructuras, indicando si faltaba rotar la sonda, etc.) concordaron con el criterio de expertos en ~83% de los casos, y fueron consideradas útiles por los médicos en aproximadamente 75% de las ocasiones. Esta clase de herramientas demuestra cómo la IA puede actuar como un *coach* durante la exploración, guiando a ecografistas menos experimentados para obtener imágenes de calidad diagnóstica y uniformizando la práctica clínica. A medida que dichas soluciones XAI se perfeccionen, podrían integrarse en los ecógrafos para mejorar la calidad de los datos de crecimiento obtenidos y asegurar que las valoraciones subsiguientes (manuales o automáticas) se basen en imágenes óptimas.

4.1.3 Validación clínica, limitaciones actuales y perspectivas futuras

Si bien los avances descritos son muy prometedores, es crucial analizar con espíritu crítico la madurez clínica de estas tecnologías, sus limitaciones actuales y los pasos necesarios para su adopción segura y efectiva. Un primer aspecto a considerar es la validación clínica rigurosa. Gran parte de los desarrollos en IA para diagnóstico prenatal provienen de estudios retrospectivos o pruebas en entornos controlados. Existe, como han señalado algunos autores, una brecha considerable entre el desarrollo técnico de los modelos de IA y su preparación para el uso clínico real (5). Hasta hace poco, escaseaban los ensayos prospectivos y multicéntricos que evaluaran en tiempo real el impacto de la IA en el desempeño de los profesionales y en los resultados

clínicos. Esto está empezando a cambiar: por ejemplo, el estudio de PAICS para malformaciones intracraneales y el de XAI para ecografías de crecimiento mencionados anteriormente, representan esfuerzos pioneros en evaluar la IA en la práctica mediante diseños controlados (incluso randomizados) con participación de usuarios finales. Dichos estudios aportan evidencia de que la IA bien diseñada puede mejorar la detección fetal sin alargar excesivamente los tiempos, pero también revelan desafíos prácticos que no se evidencian en validaciones retrospectivas. Es fundamental fomentar más investigaciones de este tipo, incluyendo ensayos clínicos y estudios de implementación que midan no solo la precisión de la IA, sino su efecto en la toma de decisiones, la satisfacción de los profesionales y los desenlaces materno-fetales.

Otra consideración importante son las limitaciones técnicas y de generalización de los sistemas de IA actuales. Un algoritmo entrenado con datos de un centro o población específica puede ver comprometido su rendimiento cuando se aplica en diferentes contextos, debido a variaciones en los ecógrafos, en las prácticas de adquisición de imágenes o en las características de la población (p. ej., distintas prevalencias de patologías, o diferencias antropométricas) (8). Por ejemplo, una red neuronal desarrollada sobre ecografías de alta calidad podría fallar al enfrentarse a imágenes de menor resolución obtenidas en entornos con menos recursos, o un modelo calibrado principalmente con fetos de cierta etnia o región podría mostrar sesgos al aplicarse en grupos demográficos no representados en su entrenamiento. Estudios recientes han subrayado la presencia de sesgos en los conjuntos de datos públicos de ecografía fetal, incluyendo falta de representatividad demográfica, escasa diversidad de condiciones patológicas incluidas y heterogeneidad en las máquinas utilizadas, factores que pueden influir significativamente en el desempeño de los modelos y potencialmente generar inequidades en la atención (8). Abordar estos sesgos requerirá ampliar y diversificar las bases de datos de entrenamiento, incorporando imágenes de múltiples poblaciones, distintas marcas de equipo y escenarios clínicos variados, para así mejorar la robustez y equidad de los algoritmos.

La explicabilidad y confianza en la IA constituyen otro reto. Muchos algoritmos de aprendizaje profundo funcionan como "cajas negras", lo cual dificulta que los médicos comprendan las razones detrás de una predicción determinada (por ejemplo, por qué la IA señala una posible anomalía en una imagen aparentemente normal). Esta falta de transparencia puede mermar la confianza del clínico en la herramienta y obstaculizar su adopción en entornos sensibles como el prenatal. Para contrarrestar esto, se está invirtiendo en técnicas de IA explicable, donde el sistema proporciona salidas interpretables –como destacando las regiones de la imagen que motivan una alerta, o dando puntuaciones de certeza– de modo que el profesional pueda validar si la recomendación de la IA es coherente con la anatomía y la fisiopatología conocidas. Los primeros estudios en esta línea (como el citado modelo XAI para crecimiento fetal) indican que proveer *feedback* visual comprensible no solo aumenta la confianza del usuario, sino que puede mejorar su propio rendimiento al servirle de guía (5). Es previsible que los futuros sistemas de IA diagnóstica incorporen cada vez más estos elementos de explicabilidad y controles de calidad integrados.

En cuanto a la integración clínica, un principio emergente es que la IA prenatal debe concebirse como un soporte a la decisión (*augmented intelligence*) y no como un reemplazo del especialista. Las herramientas más útiles serán aquellas que se acoplen de forma fluida al flujo de trabajo: por ejemplo, algoritmos que analicen automáticamente las imágenes en segundo plano mientras el ecografista realiza la exploración habitual, emitiendo sugerencias o alertas discretas (p. ej., “revisar nuevamente el corazón, posible anomalía en 3VT”) en tiempo real. Esto requiere interfaces de usuario cuidadosamente diseñadas para no distraer ni abrumar al operador con falsos positivos, sino focalizar su atención cuando realmente sea necesario. Igualmente, será importante definir protocolos de actuación: cómo proceder ante una alerta de IA, cómo documentar los hallazgos propuestos por la máquina y cómo comunicar a los padres los resultados cuando una detección sea fruto de la colaboración humano-IA.

En términos regulatorios y éticos, la incorporación de la IA en diagnóstico prenatal demanda validación externa y aprobaciones por las agencias competentes (p. ej., marcado CE en Europa, aprobación FDA en EE. UU.), lo que a su vez requiere demostrar seguridad y eficacia en poblaciones amplias. A la fecha, solo unas pocas soluciones de IA para ecografía obstétrica han obtenido tales aprobaciones, generalmente para tareas delimitadas (v.g. algoritmos de medición automática). La comunidad médica y las sociedades profesionales (como las de Medicina Materno-Fetal o Ecografía) están empezando a elaborar guías para la evaluación y

uso apropiado de la IA en este campo, enfatizando que debe cumplirse con estándares de rendimiento al menos equivalentes al estándar humano, y preferiblemente aportar un beneficio añadido.

Mirando al futuro, las necesidades incluyen:

- Estudios multicéntricos más grandes que prueben estos sistemas en entornos reales y midan el impacto clínico (reducción de diagnósticos omitidos, mejora en resultados neonatales, etc.).
- Desarrollo de bases de datos colaborativas internacionales que permitan entrenar modelos más generales y minimizar sesgos, respetando a la vez la privacidad de los pacientes.
- Mejoras continuas en la precisión y alcance de los algoritmos, posiblemente combinando datos multimodales (imágenes 2D/3D, datos clínicos maternos, marcadores bioquímicos) para obtener una visión más integral del riesgo fetal.
- Capacitación de los profesionales en el uso de estas nuevas herramientas, de modo que entiendan sus salidas y limitaciones, y sepan comunicar los hallazgos de manera adecuada a las pacientes.

En suma, la IA aplicada al diagnóstico prenatal se perfila como un complemento poderoso para el especialista, con el potencial de elevar la calidad y uniformidad de la detección de problemas fetales. Aun así, su implementación exitosa dependerá de un desarrollo responsable, avalado por evidencia científica sólida y acompañado de un marco ético y legal que garantice que estas tecnologías se utilicen en beneficio de la madre y el feto, sin generar falsas expectativas ni inequidades en la atención.

4.2. IA en el seguimiento del bienestar fetal

El seguimiento del bienestar fetal constituye uno de los pilares fundamentales de la atención obstétrica, especialmente en el tercer trimestre del embarazo y durante el trabajo de parto. Su objetivo es detectar precozmente cualquier signo de sufrimiento fetal o de alteración en el intercambio materno-fetal que pudiera comprometer la oxigenación y el desarrollo del feto. Tradicionalmente, este seguimiento se ha basado en la monitorización del registro cardiotocográfico (CTG), la evaluación del perfil biofísico fetal, la velocimetría Doppler y la valoración clínica de los movimientos fetales. Sin embargo, estas herramientas presentan una importante variabilidad interobservador, una carga interpretativa subjetiva, y no siempre permiten anticipar complicaciones con suficiente sensibilidad o especificidad.

La inteligencia artificial ofrece una oportunidad única para mejorar la precisión, reproducibilidad y capacidad predictiva del seguimiento fetal. Mediante algoritmos entrenados con grandes volúmenes de datos clínicos y fisiológicos, la IA puede identificar patrones sutiles, correlaciones multivariantes y trayectorias de riesgo que escapan al análisis convencional. Esto es especialmente relevante en contextos de vigilancia de embarazos de alto riesgo, monitorización ambulatoria o evaluación continua durante el parto.


Una de las áreas más desarrolladas es el análisis automatizado del registro cardiotocográfico (CTG), donde redes neuronales, algoritmos de aprendizaje supervisado y modelos de interpretación secuencial permiten generar interpretaciones estandarizadas, alertas inteligentes y clasificaciones de riesgo que reducen la dependencia del juicio subjetivo del profesional. Existen incluso modelos híbridos que integran datos del CTG con otros parámetros clínicos (índice de líquido amniótico, edad gestacional, antecedentes) para refinar aún más la toma de decisiones.

Otra línea emergente es la utilización de IA para predecir el riesgo de hipoxia fetal antes de que se manifiesten signos clínicos evidentes. Algunos modelos se basan en datos longitudinales del embarazo, otros en dinámicas de frecuencia cardíaca fetal y otros en la integración multimodal de variables como el Doppler, los movimientos fetales o el consumo de oxígeno estimado. Estas aproximaciones no solo tienen valor intra-parto, sino también en la planificación del parto en embarazos de riesgo (retraso de crecimiento, enfermedades hipertensivas del embarazo en todo su espectro, diabetes gestacional, etc.).

Adicionalmente, la IA puede contribuir al seguimiento fetal fuera del entorno hospitalario, mediante dispositivos portátiles conectados y soluciones de monitorización remota. Estas herramientas, aún en desarrollo, podrían mejorar el acceso al control fetal en áreas rurales o en pacientes con movilidad reducida, siempre que se implementen con garantías éticas, técnicas y de equidad.

El principal reto en este ámbito no es solo desarrollar modelos precisos, sino validarlos clínicamente, garantizar su explicabilidad y asegurar su integración fluida en la práctica asistencial, sin desplazar la responsabilidad ni el juicio clínico del obstetra o la matrona. La IA debe actuar como herramienta de apoyo y no como sustituto, permitiendo un seguimiento más personalizado, continuo y proactivo del bienestar fetal.

Figura 1. Esquema de integración de IA. En el seguimiento fetal



En los siguientes subapartados se explorarán dos aplicaciones específicas de este campo.

4.2.1 Análisis del registro cardiotocográfico (CTG)

El registro cardiotocográfico (CTG) es la herramienta más utilizada a nivel mundial para la monitorización fetal intraparto y, en ciertos contextos, también en el tercer trimestre del embarazo. Su objetivo es detectar signos de sufrimiento fetal agudo o crónico, principalmente a través de la interpretación de la frecuencia cardíaca fetal (FCF) y la actividad uterina. A pesar de su uso extendido, la interpretación del CTG se ve limitada por una gran variabilidad interobservador, una tasa elevada de falsos positivos y una baja especificidad para predecir hipoxia fetal severa, lo que puede derivar en decisiones innecesarias como cesáreas urgentes sin indicación real.

La inteligencia artificial ha irrumpido con fuerza en este campo con el objetivo de homogeneizar la interpretación, reducir el error humano y facilitar la toma de decisiones clínicas en tiempo real. Mediante el uso de algoritmos de aprendizaje automático y redes neuronales profundas, los sistemas de IA pueden ser entrenados para reconocer patrones complejos en los trazados, clasificarlos en categorías de riesgo y alertar de forma temprana sobre deterioro fetal.

4.2.1.1 Aplicaciones actuales de IA en el análisis del CTG

- **Clasificación automatizada de patrones de FCF:** Modelos basados en aprendizaje supervisado han sido entrenados para reconocer las categorías tradicionales (normal, sospechoso, patológico) siguiendo guías como las de FIGO o NICE, con niveles de concordancia superiores a los observados entre profesionales humanos.
- **Identificación de parámetros clínicos relevantes:** Algunos sistemas extraen e interpretan automáticamente características clave como la variabilidad basal, aceleraciones, desaceleraciones y la relación con las contracciones. Estas variables se integran para emitir una “puntuación de riesgo” o una recomendación asistencial.
- **Alertas inteligentes en tiempo real:** Existen plataformas que analizan el CTG de forma continua durante el trabajo de parto y generan alertas automatizadas ante desviaciones específicas (por ejemplo, desaceleraciones prolongadas, pérdida de variabilidad, taquicardia fetal sostenida).
- **Modelos híbridos e integrativos:** Algunos desarrollos integran los datos del CTG con información adicional (Doppler, edad gestacional, antecedentes de RCIU, número de contracciones, estado materno) para construir modelos multivariantes más robustos y adaptativos.
- **Monitorización remota y teleCTG:** La IA se está incorporando también en dispositivos portátiles conectados que permiten registrar y analizar la FCF a distancia, lo que puede ser útil en áreas rurales o contextos de seguimiento domiciliario. En estos casos, la IA permite filtrar artefactos, mejorar la calidad de señal y emitir alertas sin supervisión directa.

4.2.1.2 Ventajas clínicas

- Reducción de la variabilidad interobservador.
- Mayor consistencia en la aplicación de criterios clínicos.
- Potencial para disminuir la tasa de intervenciones innecesarias.
- Ayuda en situaciones de alta carga asistencial o durante las noches/guardias.
- Formación y retroalimentación para profesionales menos experimentados.

4.2.1.3 Limitaciones y desafíos

- Falta de validación clínica multicéntrica en poblaciones diversas.
- Dependencia de la calidad de la señal: artefactos o registros incompletos pueden inducir errores.
- Dificultades en la integración con el juicio clínico contextualizado.


- Necesidad de explicabilidad: muchos modelos de redes neuronales profundas funcionan como “caja negra”, sin justificación clara de su clasificación.

Desde el punto de vista ético y legal, es importante remarcar que la IA debe ser considerada como una herramienta de apoyo y no de sustitución del criterio profesional. Las decisiones clínicas deben seguir siendo asumidas por el obstetra o la matrona, incluso cuando se utilicen sistemas automatizados. Para ello es esencial que los profesionales comprendan las limitaciones del modelo, su grado de fiabilidad y su aplicabilidad al contexto específico de cada paciente.

4.2.1.4 Perspectivas futuras

La combinación de modelos explicables, entrenamiento continuo con nuevos datos clínicos y validación prospectiva puede permitir que, en un futuro cercano, el análisis del CTG con IA se convierta en una herramienta estándar, especialmente útil en centros sin experiencia especializada o con limitación de recursos. Además, el uso de modelos de predicción dinámica, capaces de anticipar el deterioro fetal con minutos de antelación, podría revolucionar la asistencia intraparto, aportando tiempo de oro para la toma de decisiones preventivas.

Figura 2. Comparativa entre interpretación humana y automatizada del CTG.



4.2.2 IA para la detección de riesgo de hipoxia fetal

La hipoxia fetal intraparto continúa siendo una de las principales causas de morbilidad y mortalidad perinatal a nivel mundial. Su detección precoz, sin embargo, representa un desafío clínico persistente, ya que los signos clásicos de sufrimiento fetal no siempre aparecen de forma temprana o son lo suficientemente específicos como para permitir una intervención oportuna. En este contexto, la inteligencia artificial ha comenzado a desempeñar un papel clave al ofrecer herramientas predictivas que superan los métodos convencionales basados en umbrales fijos o criterios clínicos subjetivos.

A diferencia del análisis del registro cardiotocográfico (CTG), que se centra en la monitorización de eventos actuales, los sistemas de IA aplicados a la detección de hipoxia buscan identificar trayectorias de riesgo antes de que se produzca un compromiso evidente del feto. Para ello, utilizan múltiples fuentes de datos —

clínicos, biofísicos, ecográficos y dinámicos— combinadas mediante algoritmos de aprendizaje automático que permiten generar modelos predictivos individualizados.


Entre los enfoques más destacados se encuentran:

- **Modelos multivariantes** entrenados con cohortes obstétricas históricas, que integran factores de riesgo maternos (edad, índice de masa corporal, hipertensión, diabetes), datos del seguimiento fetal (crecimiento intrauterino, Doppler anormal, líquido amniótico), así como hallazgos del CTG en fases precoces del parto. Estos modelos pueden calcular una probabilidad acumulada de hipoxia fetal clínicamente significativa y sugerir estrategias preventivas o decisiones de finalización del parto.
- **Algoritmos de detección de patrones dinámicos** en la frecuencia cardíaca fetal, más allá de la clasificación categórica tradicional. Algunos sistemas analizan la complejidad del patrón, la entropía, la aceleración instantánea o las variaciones cíclicas no percibidas por el observador humano, que pueden anticipar el deterioro antes de que se produzcan desaceleraciones significativas.
- **Sistemas de IA basados en aprendizaje profundo**, que utilizan trazados completos del CTG y los correlacionan con marcadores bioquímicos (pH, lactato en sangre del cuero cabelludo fetal) o resultados neonatales adversos para identificar señales tempranas de hipoxia. Algunos modelos alcanzan una sensibilidad superior al 85% para predecir acidosis al nacer, con tasas aceptables de falsos positivos.
- **Análisis longitudinal del bienestar fetal durante el embarazo**, mediante series de tiempo que recogen datos desde el segundo trimestre hasta el parto. Esto incluye la evolución del crecimiento fetal, los cambios Doppler, las alteraciones en el patrón de movimientos fetales y las adaptaciones hemodinámicas materno-fetales. Los algoritmos pueden anticipar el momento óptimo para la finalización del embarazo en situaciones de restricción del crecimiento o riesgo de insuficiencia placentaria crónica.
- **Modelos híbridos que combinan IA y reglas clínicas**: en estos casos, se integra la predicción algorítmica con guías clínicas estructuradas para ayudar al profesional a interpretar el riesgo de forma comprensible y fundamentada. La clave de estos sistemas es su explicabilidad, que permite a obstetras y matronas entender la lógica detrás de cada alerta y actuar en consecuencia.

A pesar de su promesa, estos modelos aún deben superar importantes retos antes de su implementación clínica rutinaria. Entre ellos destacan la necesidad de validación multicéntrica en distintas poblaciones, la integración segura con los sistemas de información hospitalarios, la interpretación ética de alertas automatizadas y la formación adecuada de los profesionales para interpretar los resultados sin generar dependencia excesiva.

El uso de IA para la predicción de hipoxia fetal no solo representa un avance tecnológico, sino un cambio conceptual: se pasa de una vigilancia reactiva a una monitorización anticipativa, que puede transformar radicalmente la seguridad del parto y el bienestar neonatal.

Figura 3. Variables clave en modelos predictivos de hipoxia fetal mediante IA.



4.3. IA en la Diabetes Mellitus Gestacional: De la Predicción a la Aplicación Clínica

*Dr. Leonardo Mancillas Adame. Coordinador del Servicio de Endocrinología
Dr. Luis Abel Guzmán Ochoa. Profesor de Medicina Materno Fetal y Cirugía Fetal*

4.3.1 Introducción

La diabetes *mellitus* gestacional (DMG) es una alteración metabólica caracterizada por intolerancia a la glucosa diagnosticada por primera vez durante el embarazo, generalmente en el segundo o tercer trimestre, sin cumplir criterios de diabetes preexistente (1). Esta condición se asocia a un mayor riesgo de complicaciones maternas —como preeclampsia, hipertensión gestacional y parto por cesárea— y neonatales inmediatas —como macrosomía, hipoglucemia e inmadurez respiratoria—, además de un incremento sustancial en el riesgo a largo plazo de desarrollar diabetes tipo 2 y enfermedad cardiovascular en la madre, así como obesidad, intolerancia a la glucosa y síndrome metabólico en la descendencia (2-5).

En México, la prevalencia de DMG varía según la región, los criterios diagnósticos y las características de las poblaciones estudiadas. Estudios recientes estiman que entre el 10% y el 14% de los embarazos podrían verse afectados por DMG (6). En mujeres con obesidad pregestacional, la prevalencia reportada alcanza aproximadamente el 13.7% (7), mientras que ciertos estudios arrojan cifras más bajas (alrededor del 6%) en poblaciones generales con distintos perfiles de riesgo (8).

El diagnóstico convencional depende de la prueba de tolerancia oral a la glucosa realizada entre las semanas 24 y 28 de gestación. Esto implica que muchas mujeres solo son identificadas cuando la disrupción metabólica ya está presente. La detección temprana —en el primer trimestre— podría abrir la puerta a intervenciones preventivas oportunas que mejoren la evolución perinatal y reduzcan la morbilidad materna y neonatal.

La inteligencia artificial (IA) y el aprendizaje automático (*machine learning*, ML) permiten analizar grandes volúmenes de información y modelar interacciones complejas entre variables clínicas, bioquímicas y de imagen, ofreciendo predicciones más robustas que los métodos tradicionales. Una revisión sistemática reciente concluyó que “la inteligencia artificial en la atención de la DMG ofrece herramientas prometedoras, aunque la evidencia aún se encuentra fragmentada y basada en conjuntos de datos heterogéneos, con falta de validación externa y limitada implementación en la práctica clínica” (9). Esto subraya que, aunque los algoritmos muestran gran potencial para transformar la atención obstétrica y perinatal, todavía se requiere un esfuerzo importante para estandarizar los métodos, mejorar la calidad de los datos y garantizar que los modelos desarrollados en distintos contextos sean aplicables en poblaciones diversas, incluyendo la mexicana.

De este modo, el uso de IA en la DMG podría mejorar la predicción de riesgo, apoyar la toma de decisiones clínicas y personalizar estrategias de manejo, siempre que se atiendan los retos de validación externa, interpretabilidad y equidad en su implementación.

4.3.2 Panorama actual de la predicción en DMG

Tradicionalmente, la identificación de mujeres en riesgo de desarrollar diabetes *mellitus* gestacional (DMG) se ha basado en factores clínicos simples: edad materna avanzada, índice de masa corporal elevado, antecedentes familiares de diabetes tipo 2, antecedentes obstétricos adversos y pertenencia a ciertos grupos étnicos. Sin embargo, el poder predictivo de estos factores es limitado, pues explican solo una fracción de la variabilidad en la aparición de la enfermedad (10).

En las últimas dos décadas se han explorado biomarcadores bioquímicos y moleculares para mejorar la predicción temprana. Entre ellos se incluyen glucosa en ayuno, hemoglobina glucosilada (HbA1c), triglicéridos, adipocinas (como leptina y adiponectina), así como perfiles metabolómicos y proteómicos. Una revisión sistemática reciente encontró que, aunque algunos marcadores muestran asociaciones consistentes con el riesgo de DMG, la reproducibilidad entre estudios es baja y la utilidad clínica todavía es limitada (11). Por ejemplo, la HbA1c en el primer trimestre puede tener cierta capacidad discriminativa, pero su sensibilidad y especificidad son insuficientes para recomendarla como prueba diagnóstica aislada (12).

La heterogeneidad en los criterios diagnósticos constituye otro reto. Distintos organismos —como la Asociación Internacional de Grupos para el Estudio de la Diabetes y el Embarazo (IADPSG), la *American Diabetes Association* (ADA) y la Organización Mundial de la Salud (OMS)— han propuesto umbrales diferentes de glucosa, lo cual repercute directamente en las tasas reportadas de prevalencia y dificulta la comparación entre estudios. Esta falta de consenso ha sido señalada en la literatura como un obstáculo para implementar estrategias uniformes de tamizaje y predicción (13).

En este escenario, la inteligencia artificial (IA) y los modelos de aprendizaje automático (*machine learning*, ML) han surgido como una alternativa innovadora. Estos modelos permiten integrar datos clínicos, demográficos y bioquímicos, generando predicciones con mayor sensibilidad que las herramientas tradicionales. Un ejemplo es el modelo MIDO GDM, desarrollado en población mexicana, que alcanzó una sensibilidad del 83.3% para identificar riesgo de DMG utilizando variables clínicas rutinarias (14). Este tipo de aproximaciones, si bien todavía requieren validación externa, representan un paso hacia la predicción temprana y personalizada.

El panorama actual de la predicción en DMG refleja un tránsito desde modelos basados en factores clínicos simples, hacia el uso de biomarcadores complejos y algoritmos de IA, con la expectativa de lograr detección más temprana, reducción de la morbilidad y personalización de la atención.

4.3.3 Metodologías de IA aplicadas a diabetes gestacional

Los modelos de predicción de diabetes *mellitus* gestacional (DMG) han evolucionado desde el uso de regresiones logísticas hacia enfoques de aprendizaje automático (*machine learning*, ML) y, más recientemente, de aprendizaje profundo (*deep learning*, DL). Estas metodologías permiten procesar grandes volúmenes de información clínica, demográfica, bioquímica e incluso imágenes médicas, identificando patrones no lineales y complejas interacciones entre variables que los métodos estadísticos tradicionales difícilmente capturan. Esto se traduce en mejoras en la capacidad predictiva y en la sensibilidad para la detección temprana de la enfermedad, particularmente cuando se integran múltiples fuentes de datos heterogéneos en un mismo modelo (15-17).

Un estudio comparativo demostró que algoritmos como *random forest*, *support vector machines* y *gradient boosting* superaron a la regresión logística en la predicción de DMG, aunque con menor transparencia en su interpretación (17). Esta tensión entre la precisión predictiva e interpretabilidad y uso clínico constituye uno de los dilemas centrales para su adopción en la práctica cotidiana. Para enfrentarlo, se han desarrollado herramientas de explicabilidad como SHAP (*SHapley Additive exPlanations*), que asigna valores de contribución a cada característica del modelo y permite comprender tanto predicciones individuales como patrones globales (18). En DMG, la aplicación de estos enfoques ha permitido identificar factores clave como la edad gestacional, el control glucémico y el momento del diagnóstico como predictores relevantes, haciendo los modelos más transparentes para la práctica clínica (19). De manera complementaria, las guías metodológicas como TRIPOD+AI recomiendan reportar con detalle el tipo de algoritmo, los procedimientos de validación y los aspectos de interpretabilidad para garantizar la transportabilidad y el uso responsable en la clínica (20).

Un aspecto metodológico clave es la gestión de datos faltantes en expedientes clínicos. La ausencia de información puede generar sesgos y limitar la validez externa de los modelos. Se ha demostrado que la imputación múltiple por ecuaciones encadenadas (MICE) y otros enfoques como *k-nearest neighbors* mejoran la estabilidad y la precisión de los modelos, siempre que se especifiquen los mecanismos de ausencia de datos (MCAR, MAR, MNAR) y se incorporen variables auxiliares adecuadas (21). Herramientas de evaluación de riesgo de sesgo como PROBAST subrayan que el manejo de datos faltantes debe explicarse de forma explícita y acompañarse de análisis de calibración y desempeño discriminativo después de la imputación para garantizar su validez (22, 23).

Más allá de los datos numéricos, la IA también se ha aplicado a la imagenología obstétrica. Las redes neuronales convolucionales (CNN) se han usado para analizar la ecotextura hepática fetal, prediciendo desequilibrios insulínicos neonatales con un AUC de 0.83 y sensibilidad del 86.5% en estudios recientes (24). Asimismo, arquitecturas como SonoNet han mostrado capacidad para identificar planos estándar en ultrasonido fetal en tiempo real (25), y modelos de DL han alcanzado desempeño a nivel experto en la detección prenatal de cardiopatías congénitas a partir de ecocardiografía fetal (26). Estos avances ilustran el potencial de la IA para ampliar la predicción más allá de variables clínicas hacia biomarcadores visuales y modelos multimodales, aunque su implementación exige validaciones externas robustas y estandarización de protocolos.

4.3.4 Predicción de riesgos maternos y fetales

La diabetes *mellitus* gestacional (DMG) no es solo hiperglucemia durante el embarazo, sino que también se asocia con un conjunto de complicaciones maternas y neonatales que pueden anticiparse mediante modelos de inteligencia artificial (IA). Entre los riesgos maternos destacan preeclampsia, parto pretérmino, hipertensión gestacional y cesárea intraparto, mientras que en el recién nacido son relevantes la macrosomía, hipoglucemia, inmadurez respiratoria y admisión a la UCI neonatal (5, 27).

Modelos de aprendizaje automático (ML) han sido entrenados con información clínica, bioquímica y antropométrica para estimar la probabilidad de desenlaces adversos. En un estudio con 1,670 pacientes con

DMG, un modelo de tipo *stacking* alcanzó una exactitud del 85.6% y un AUC de 0.82 para predecir complicaciones obstétricas; además, mediante explicabilidad basada en SHAP, se identificaron como factores clave la edad gestacional al diagnóstico, el grado de control glucémico y la ganancia ponderal materna (19). Estos hallazgos sugieren que la IA puede no solo mejorar la capacidad de predicción, sino también señalar predictores clínicamente relevantes.

Por otra parte, la IA aplicada a imagenología perinatal ha abierto un nuevo campo en la predicción de riesgos fetales. De forma complementaria, la metabolómica integrada con ML ha permitido identificar alteraciones en aminoácidos específicos (glutamina, histidina, asparagina), correlacionados de manera inversa con la glucemia materna y asociados con macrosomía, lo que los posiciona como biomarcadores potenciales para la predicción temprana (28).

En cuanto a los riesgos obstétricos inmediatos, un modelo predictivo basado en cohortes de mujeres con DMG desarrolló un puntaje de riesgo de cesárea intraparto, alcanzando un AUC de 0.81 tras validación interna. Entre los factores determinantes se encontraron IMC materno $>30 \text{ kg/m}^2$, nuliparidad, inducción del trabajo de parto y presencia de preeclampsia (29). Estos resultados refuerzan la utilidad de los modelos de IA como herramientas de apoyo clínico en la planificación del parto.

En conjunto, la evidencia sugiere que la IA es capaz de predecir riesgos maternos y fetales de manera temprana y precisa, integrando información clínica, bioquímica y de imagen. Sin embargo, la mayoría de los estudios son de validación interna; se requiere investigación multicéntrica y validación externa en distintas poblaciones para consolidar la transportabilidad de estos modelos.

4.3.5 Fuentes de datos y desafíos

El desarrollo de modelos de inteligencia artificial para la predicción de DMG depende en gran medida de la calidad y disponibilidad de los datos empleados. Las fuentes más comunes incluyen:

1. **Registros clínicos electrónicos (EHR/EMR):** Permiten integrar información demográfica, antecedentes obstétricos, laboratorio y evolución clínica. Sin embargo, la falta de estandarización, los datos faltantes y la presencia de errores de codificación constituyen limitaciones frecuentes (9).
2. **Biomarcadores bioquímicos y moleculares:** Como glucosa en ayuno, HbA1c, perfiles lipídicos, adipocinas y, más recientemente, metabolómica y proteómica. Su inclusión mejora la discriminación de los modelos, pero eleva la complejidad y los costos de implementación (11).
3. **Imágenes médicas:** Especialmente ultrasonido, que abren la posibilidad de desarrollar modelos de visión computacional para identificar patrones sutiles relacionados con riesgos metabólicos y de crecimiento fetal (24).
4. **Datos poblacionales y de cohorte:** Como registros de nacimientos o encuestas nacionales, que facilitan el entrenamiento de modelos en muestras grandes y heterogéneas, aunque pueden carecer de granularidad clínica (30).

Los principales desafíos metodológicos y prácticos incluyen:

- **Calidad de los datos:** La presencia de información incompleta o inexacta puede sesgar los modelos. La imputación múltiple y otras estrategias son recomendadas, pero requieren transparencia en su reporte (21).
- **Heterogeneidad de criterios diagnósticos:** La coexistencia de múltiples definiciones de DMG (ADA, IADPSG, OMS) genera dificultades para la comparación de estudios y afecta la generalización de los modelos.

- **Validación externa:** Muchos modelos se han evaluado únicamente en las cohortes donde fueron desarrollados, lo que limita su transportabilidad. La literatura insiste en la necesidad de validación multicéntrica y en poblaciones diversas (20).
- **Aspectos éticos y regulatorios:** El uso de datos sensibles en embarazo plantea dilemas relacionados con privacidad, consentimiento informado y equidad en la aplicación de algoritmos (31).

4.3.6 Implementación y apoyo a decisiones clínicas

La transición de los modelos de inteligencia artificial en diabetes *mellitus* gestacional desde el laboratorio hasta la práctica clínica constituye uno de los mayores retos actuales. Aunque múltiples estudios han demostrado que los algoritmos de aprendizaje automático superan en desempeño a los métodos estadísticos tradicionales, su impacto real en la toma de decisiones clínicas aún es limitado por la falta de integración en los flujos de trabajo hospitalarios (9).

Un ejemplo de aplicación clínica es el desarrollo de modelos para predecir la vía del parto en mujeres con DMG. Un estudio retrospectivo con más de 11,000 gestantes generó un nomograma para estimar la probabilidad de cesárea intraparto, identificando como predictores clave el índice de masa corporal, la nuliparidad, la ganancia ponderal excesiva y la presencia de preeclampsia. El modelo alcanzó un área bajo la curva (AUC) de 0.81 tras validación interna, ofreciendo una herramienta potencial para la planificación obstétrica personalizada (29).

Asimismo, revisiones recientes han documentado más de 30 estudios sobre modelos de IA para morbilidad y mortalidad materna, destacando su utilidad para anticipar complicaciones como preeclampsia, hemorragia posparto y eventos cardiovasculares. Sin embargo, la mayoría se limita a validaciones retrospectivas y ninguno se ha integrado aún como herramienta clínica en tiempo real (32). Esto refleja la amplia brecha traslacional entre el desarrollo metodológico y la adopción en la práctica cotidiana.

La implementación de sistemas de apoyo a la decisión clínica basados en IA en DMG requiere superar barreras técnicas y humanas. Entre ellas se incluyen la necesidad de:

- Interfaz amigable y comprensible para los profesionales de la salud y pacientes.
- Explicabilidad de las predicciones, mediante marcos como SHAP o LIME, que permitan entender los factores que influyen en el riesgo asignado a cada paciente.
- Validación multicéntrica en poblaciones diversas para garantizar la generalización.
- Cumplimiento regulatorio y ético, con protección de datos sensibles y reducción del riesgo de sesgos.

Aunque la IA ha demostrado un gran potencial para apoyar la toma de decisiones en el manejo de la DMG, su implementación clínica efectiva dependerá de la capacidad de integrar estos modelos en plataformas interoperables, validadas en entornos reales y aceptadas por los equipos médicos como herramientas complementarias para mejorar la atención materno-fetal.

4.3.7 Perspectivas futuras

El futuro de la IA en la diabetes *mellitus* gestacional apunta hacia modelos más integrativos, multimodales y personalizados. Una de las principales tendencias es la combinación de datos clínicos, bioquímicos, de imagen y de sensores portátiles en sistemas de predicción que permitan un tamizaje más temprano y preciso. El uso de monitoreo continuo de glucosa y su integración con algoritmos de aprendizaje profundo abre la posibilidad de identificar patrones glucémicos asociados con riesgo materno y neonatal antes de que se manifiesten clínicamente (33).

Asimismo, la incorporación de plataformas de telemedicina y aplicaciones móviles permitirá trasladar estos modelos predictivos al entorno cotidiano de la paciente, favoreciendo la adherencia a intervenciones

de estilo de vida y el seguimiento remoto. En países como México, donde existen desigualdades en el acceso a servicios especializados, estas herramientas podrían contribuir a cerrar brechas y ofrecer una atención más equitativa.

Otra línea de investigación emergente es la IA explicable (XAI), que busca generar algoritmos interpretables y confiables para los profesionales de la salud. Esto será esencial para garantizar su aceptación clínica y evitar que los modelos se perciban como “cajas negras” (31). En paralelo, guías metodológicas como TRI-POD+AI promueven estándares de reporte y validación que incrementan la transparencia y reproducibilidad de los modelos.

Finalmente, será necesario abordar los desafíos éticos y regulatorios asociados al uso de IA en obstetricia, incluyendo la protección de datos sensibles, la reducción de sesgos algorítmicos y la validación en poblaciones diversas. Para que estas tecnologías se conviertan en herramientas de apoyo clínico de rutina, deberán superar no solo las barreras técnicas, sino también las relacionadas con la confianza de médicos, pacientes e instituciones de salud.

Las perspectivas futuras de la IA en DMG son prometedoras: avanzar hacia un tamizaje temprano, individualizado y accesible, integrando herramientas digitales y garantizando seguridad, equidad y rigor científico.

Tabla 1. Modelos de IA para predicción de riesgos maternos y fetales en DMG

Riesgo predicho	Tipo de modelo IA	Población / Datos	Desempeño reportado	Referencia
Complicaciones maternas y perinatales (preeclampsia, parto pretérmino, cesárea, hipoglucemia neonatal)	<i>Stacking model</i> (combinación de LR, RF, SVM, XGBoost) con explicabilidad SHAP	1,670 gestantes con DMG (cohorte retrospectiva)	Exactitud 85.6%, AUC 0.82 (validación interna)	Li J et al., 2025
Desequilibrio insulínico neonatal (niveles elevados de péptido C en cordón umbilical)	Redes neuronales convolucionales (CNN, EfficientNet-B0)	1,733 imágenes de ultrasonido hepático fetal	Sensibilidad 86.5%, AUC 0.83	Da Correggio KS et al., 2025
Macrosomía fetal	ML con integración de perfiles metabólicos (aminoácidos)	94 pares madre-hijo (53 con DMG, 41 controles)	Identificación de glutamina, histidina y asparagina como biomarcadores; correlación inversa con glucemia materna	Frankevich NA et al., 2025
Riesgo de cesárea intraparto en mujeres con DMG	Regresión logística y ML con desarrollo de nomograma	>11,000 mujeres con DMG, parto único	AUC 0.81 (validación interna)	Gilboa I et al., 2025

4.4. Predicción de complicaciones obstétricas

4.4.1. Previsión de la preeclampsia

A pesar de los numerosos estudios realizados, aún no se ha logrado predecir, tratar o prevenir la preeclampsia con una eficacia del 100%. Actualmente, se comprende que no es una única enfermedad, sino un conjunto de trastornos que pueden manifestarse de diversas formas y tener diferentes causas biológicas. Esto sugiere la existencia de varios tipos distintos de preeclampsia. Además, sus efectos no se limitan al embarazo, sino que pueden cronificarse, como el aumento del riesgo cardiovascular materno o la hipertensión persistente posparto.

La variabilidad en su presentación ha dificultado la detección temprana en el embarazo y el tratamiento exitoso con medicamentos como la aspirina. Uno de los grandes desafíos para la identificación y prevención continua es la calidad y el registro de los datos de los pacientes, ya que cada dato puede tener diferentes formas de ser registrado. La inteligencia artificial (IA) depende completamente de la calidad de los datos que se ingresen o, en su defecto, de los que se obtengan de las bases de datos existentes.

Este capítulo enumerará diferentes artículos, destacando sus resultados positivos y analizando las limitaciones que pudieron influir negativamente en ellos. Esto ayudará a implementar estas nuevas tecnologías de acuerdo con la realidad de nuestro entorno, considerando que la IA evolucionará de tal forma que las posibles limitaciones serán cada vez menores.

El aprendizaje de los modelos utilizados puede ser supervisado o no supervisado (existen formas mixtas). Ambos modelos se nutren de maneras distintas: en el primero, los datos están vinculados a una respuesta o resultado; en el no supervisado, los modelos interpretan los datos sin una tutorización explícita. El tipo de modelo más adecuado dependerá de los datos disponibles, y los datos relacionados con la preeclampsia pueden interpretarse con ambos.

Dentro del aprendizaje automático, existe un modelo de aprendizaje supervisado llamado *Random Forest* (Bosque Aleatorio). Éste combina los resultados de múltiples árboles de decisión para llegar a una única conclusión. Este modelo suele ser fácil de usar, interpretar y aprender rápidamente. Es adaptable a diferentes tipos de datos, ofreciendo resultados efectivos y confiables, incluso con datos incompletos.

Diversos autores han comparado la forma tradicional de analizar el riesgo de preeclampsia (regresión logística) con los nuevos modelos de aprendizaje, como las Redes Neuronales Profundas (*Deep Neural Network*), Máquinas de Vectores de Soporte (*Support Vector Machine*), Árboles de Decisión (*Decision Tree*), Bosque Aleatorio (*Random Forest*) y el Método de Aumento de Gradientes (*Gradient Boosting Method*). Tras analizar datos clínicos, ecográficos y analíticos de los pacientes, la conclusión entre los diferentes autores se inclina preferentemente hacia dos métodos como los mejores: el Bosque Aleatorio (BA) y el Método de Aumento de Gradientes (MAG).

El MAG permite predecir el comportamiento de los valores según diferentes cálculos de gradiente (vectores, interceptos y errores) en distintas situaciones, lo que posibilita analizar el comportamiento de los valores desde múltiples perspectivas y obtener diversas conclusiones.

Existen algunos detractores de estos modelos que consideran que la Red Neuronal Profunda es la mejor, argumentando que todo depende del tipo y la cantidad de datos ofrecidos al sistema para su entrenamiento. Este modelo, similar al comportamiento del cerebro humano, consta de diferentes capas de nodos o "neuronas" que interpretan los datos de diversas formas y envían o no información a la siguiente capa. Conforme el modelo aprende, lo hace de manera más eficiente, rápida y precisa.

Los datos novedosos, como los de nuevos biomarcadores, tendrán un gran recorrido bajo estas nuevas tecnologías. La capacidad de analizarlos permitirá identificar mejor las combinaciones de biomarcadores que predicen la aparición de preeclampsia, e incluso determinar cuáles son los más adecuados para su uso.

Actualmente, uno de los avances más significativos en el cribado precoz de la preeclampsia ha sido el desarrollo del modelo de riesgos competitivos propuesto por la *Fetal Medicine Foundation* (FMF). Este modelo ha mejorado sustancialmente la precisión del cribado en el primer trimestre. La estrategia se basa en un modelo de supervivencia que estima el tiempo hasta la aparición de preeclampsia, utilizando el teorema de

Bayes para combinar información previa derivada de las características maternas con los valores de biomarcadores ajustados por múltiplos de la mediana (MoM). Mediante este algoritmo, es posible identificar aproximadamente el 90 % de las mujeres que desarrollarán preeclampsia antes de las 34 semanas y el 75 % de aquellas que lo harán antes de las 37 semanas, todo ello con una tasa de falsos positivos del 10 %. La calculadora de riesgo se encuentra disponible de forma gratuita en la página web de la FMF (<https://fetalmedicine.org/research/assess/preeclampsia/first-trimester>). Es importante destacar que este modelo estadístico complejo supera con creces el enfoque basado exclusivamente en factores de riesgo clínicos, el cual, a pesar de sus limitaciones, continúa siendo el más utilizado a nivel mundial. La identificación temprana y precisa de pacientes en riesgo es fundamental, ya que la profilaxis con ácido acetilsalicílico solo resulta eficaz si se inicia antes de la semana 16 de gestación. En este contexto, el estudio ASPRE demostró que cuando el cribado entre las 12-14 semanas se realiza según el algoritmo de la FMF y se administra aspirina a las mujeres con riesgo elevado, la incidencia de preeclampsia se reduce en un 62 % en comparación con el grupo placebo. Aunque la aplicación del modelo de riesgos competitivos en etapas más avanzadas del embarazo también ha mostrado resultados prometedores, por el momento su uso generalizado no se ha alcanzado.

La integración en herramientas ya validadas también será un camino a seguir. El estudio de Van den Heuvel et al. (2020), *Pregnancy Hypertension*, demostró que una plataforma operada de forma autónoma mediante diferentes algoritmos puede mejorar la asistencia a pacientes con alto riesgo de preeclampsia. Este estudio, llamado SAFE@HOME, realizado en Holanda, es un estudio de caso-control en el que se facilita una plataforma digital para el tele-monitoreo de la presión arterial y síntomas relacionados con la preeclampsia, en combinación con un programa reducido de visitas. Se compararon 103 mujeres con factores de riesgo para desarrollar preeclampsia a quienes se les dio acceso a esta plataforma desde la semana 16, con 133 mujeres de las mismas características que se sometieron a los controles estándar. Los resultados significativos fueron una reducción del consumo de atención médica, menos hospitalizaciones y una mayor satisfacción del usuario, manteniendo iguales resultados en la morbilidad materno-fetal. Con este tipo de resultados basados en cálculos de datos, se puede inferir hacia dónde deben orientarse los esfuerzos. Esta misma plataforma, asistida por inteligencia artificial, podría reproducirse a lo largo del mundo sin un gran despliegue de recursos, generando una repercusión positiva, sobre todo en lugares donde los recursos de personal son limitados, e incluso en países desarrollados donde el personal sanitario no siempre está disponible, especialmente en zonas remotas.

Intentando resumir las áreas donde la IA puede influir en el abordaje de la preeclampsia, se podrían enumerar las siguientes:


- Mejorar la identificación de pacientes con alto riesgo de preeclampsia.
- Lograr un diagnóstico más rápido de la preeclampsia.
- Clasificar el grado de preeclampsia, estratificando mejor los riesgos.
- Identificar mejor y más rápido los biomarcadores.
- Aplicar de forma más efectiva las combinaciones de biomarcadores.
- Mejorar el rendimiento de herramientas de asistencia o monitoreo para pacientes en riesgo.

Khalil et al. (2024), como parte de un sub-análisis del estudio SMART, realizaron un estudio de detección temprana de la preeclampsia con datos clínicos y biomarcadores (*Total Cell Free DNA* y *Fetal Fraction*), utilizando un modelo de inteligencia artificial que analizó datos de 17 520 pacientes. El tipo de modelo utilizado fue una Red Neuronal (*Neural Network*). Los resultados fueron comparables para todos los tipos de preeclampsia (<34, <37 y >37 semanas) al compararlos con la regresión logística. Por lo tanto, se puede concluir que el uso habitual de las características de los pacientes y la fracción de ADN libre en sangre, en combinación con la IA, puede utilizarse en la práctica clínica para el cribado de preeclampsia, al ser comparable con los despistajes actuales. Esto, desde un punto de vista integrativo, permite que, en el momento en que se logren integrar los sistemas operativos al 100 % en la práctica clínica, la IA pueda evaluar los datos automáticamente, sin necesidad de ejecutar los algoritmos manualmente, lo que resultaría en menos errores y aceleraría los tratamientos preventivos asociados a esta práctica.

Bülez et al. (2024) publicaron un estudio sobre el entrenamiento de una IA con 10 307 pacientes (se perdieron 2/3 del volumen total de pacientes por falta de datos, que podrían haber sido 37 823) para su reconocimiento precoz de la preeclampsia. Obtuvieron un 73 % de sensibilidad, 92 % de especificidad, 90 % de precisión y un área bajo la curva (AUC) de 0.83. Concluyen que la IA es un método efectivo para la detección temprana de la preeclampsia. Este estudio destaca el potencial de la IA para transformar la atención prenatal en entornos con estímulo de innovación, como este hospital del sureste de Turquía, que apuesta por la implementación de registros médicos electrónicos, telemedicina e IA.

Hackelöer et al. (2023) publicaron "Nuevos avances en la predicción y vigilancia de la preeclampsia: rol del aprendizaje por máquinas y la monitorización remota". El estudio recopila ensayos y destaca que los algoritmos basados en aprendizaje automático han demostrado ser eficaces en la identificación temprana de mujeres en riesgo de preeclampsia. Estos modelos pueden analizar grandes volúmenes de datos clínicos, incluyendo factores maternos, biomarcadores y parámetros ecográficos, que pueden predecir la aparición de la enfermedad y sus complicaciones. Se resalta la importancia de las tecnologías remotas y el cambio de paradigma.

Figura 3.1.



Li et al. (2022) publicaron "Improving preeclampsia risk prediction by modeling pregnancy trajectories from routinely collected electronic medical record data", donde evalúan si la información habitualmente registrada en historias clínicas electrónicas (HCE) puede mejorar la predicción del riesgo de preeclampsia en comparación con los métodos clínicos tradicionales. Se desarrolló un algoritmo de fenotipado digital para reconstruir la trayectoria de 108 557 embarazos a partir de las HCE y se entrenaron modelos de aprendizaje automático con 60 879 casos, abarcando anteparto, intraparto y posparto. Las curvas ROC (*Receiver Operating Characteristic*) mostraron una alta precisión con un AUC (*Area Under the Curve*) de 0.92 a las 37 semanas, 0.82 en intraparto y 0.89 en el posparto. También se validó externamente. Con estos resultados, se interpreta que el uso de esta tecnología permite una predicción más precisa y dinámica del riesgo de preeclampsia en distintas etapas del embarazo. El modelo supera la precisión de las herramientas actuales en la práctica clínica, abriendo la puerta a estrategias terapéuticas más personalizadas y precisas. Con estos datos, se puede afirmar que el enfoque de "fenotipo digital" usando datos longitudinales reales y aprendizaje automático ofrece una herramienta prometedora para la identificación temprana y dinámica de mujeres en riesgo de preeclampsia, lo cual podría mejorar la prevención y el manejo obstétrico.

Existen proyectos con poca pero buena información (*dataset*), como el artículo de Marín et al. (2019), donde, con datos de 105 pacientes monitorizados de forma ambulatoria con un brazalete, mediante aprendizaje automático, obtuvieron un AUC de 0.79 en la predicción de preeclampsia. Este artículo resalta la fusión de sistemas (telemedicina y aprendizaje automático).

El estudio de Schmidt et al. (2022, AJOG) sugiere un punto de inflexión, donde nos tendríamos que cuestionar si es ético no dirigirnos a un entorno de inteligencia artificial. En este estudio se desarrolla y valida un algoritmo automatizado por el modelo de aprendizaje automático que predice efectos adversos en madres con sospecha de preeclampsia. Se analizaron 1647 mujeres entre 2010 y 2019, obteniendo 114 características

que incluyen historia clínica, signos físicos, biomarcadores angiogénicos (sFlt-1, PlGF) y parámetros Doppler fetales. Se entrenaron dos modelos: árboles potenciados (*gradient boosted trees*) y Bosque Aleatorio (*Random Forest*) con optimización de hiperparámetros mediante *Grid Search*. Se obtuvieron: 88 % VPP, 89 % VPN, 66 % sensibilidad, 97 % especificidad, Precisión global 89 %, AUC-ROC de 0.82. Se puede concluir que los modelos de aprendizaje automático mejoran significativamente la capacidad de predecir resultados adversos en mujeres con sospecha de preeclampsia, en comparación con los enfoques clínicos actuales. El sistema es automatizado, lo que facilita su integración en sistemas de decisión clínica, permitiendo tomar decisiones en tiempo real, combinando biomarcadores y evaluaciones Doppler, lo que posibilita una mayor precisión para identificar a las pacientes que requerirán un manejo más temprano y especializado.

Después de revisar tantos ejemplos, se puede afirmar que existen muchos avances en lo que la inteligencia artificial puede hacer con respecto a la preeclampsia:

- Mejorar la predicción previa a los síntomas clínicos.
- Diferenciar la severidad de la enfermedad.
- Monitorizar de forma remota y en tiempo real la enfermedad.
- Detectar mejor los riesgos materno-fetales.

También es importante comentar las limitaciones de los modelos de aprendizaje y la generalización de los mismos en diferentes poblaciones:

- **Datos distintos:** Mismos datos con significados diferentes, o datos similares con significado distinto.
- **Características específicas de ciertas poblaciones:** Raciales, genéticas, ambientales, socioeconómicas.
- **Parámetros distintos de los datos:** Uso de máquinas con especificaciones o validaciones distintas.
- **Datos obtenidos de hospitales complejos:** Generan resultados distintos a los vistos en hospitales de menor complejidad, lo que podría generar posibles sobre-tratamientos o sobre-diagnósticos.
- **Falta de sistemas informáticos similares** en ámbitos asistenciales distintos.
- **Falta de predictibilidad:** Al no poder predecir el rendimiento o entender el razonamiento detrás de cada decisión, se puede limitar su uso por causas legales o falta de autorización por parte de los pacientes.
- **Datos sesgados** por su limitación en cantidad (cortes pequeñas).

4.4.2. Diagnóstico del parto prematuro

El parto prematuro (PPT), definido como aquel que ocurre antes de las 37 semanas de gestación, continúa siendo una de las principales causas de morbilidad y mortalidad perinatal en todo el mundo. La Organización Mundial de la Salud informa que, cada día, aproximadamente uno de cada diez bebés nace prematuramente, lo que representa entre 37.000 y 40.000 prematuros diarios en el mundo. Las complicaciones asociadas a la prematuridad son las principales responsables de la mortalidad, y se estima que el 75 % son prevenibles. A pesar de los avances en obstetricia, sigue siendo difícil predecir qué mujeres desarrollarán esta complicación, sobre todo en ausencia de síntomas clínicos tempranos. La fisiopatología del parto prematuro es multifactorial: inflamación, infecciones subclínicas, disfunción placentaria, estrés uterino o insuficiencia cervical, entre otros, convergen para desencadenar un proceso que, en muchos casos, se inicia de forma silenciosa. También se han estudiado e identificado múltiples factores de riesgo: edad materna avanzada o baja (adolescencia), tabaquismo, abuso de drogas, nivel socioeconómico bajo, antecedentes médicos y quirúrgicos, malos antecedentes obstétricos, periodo intergenésico corto, entre otros. Este carácter heterogéneo y asintomático ha complicado el desarrollo de métodos diagnósticos robustos y universalmente aplicables. En este escenario, los modelos estadísticos han sido hasta ahora la herramienta más usada, pero la inteligencia artificial (IA) o los Modelos basados en aprendizaje automático (MAM o *MLM machine learning models* en inglés) emergen

como la técnica más prometedora para integrar múltiples fuentes de datos y mejorar la predicción y el manejo del parto prematuro.

También es importante recalcar que la definición de parto prematuro incluye arbitrariamente a muchos recién nacidos que cursarán con un desarrollo totalmente asintomático. Seong et al. (2024), en una revisión de abordajes computacionales para el PPT y resultados neonatales, propone y resalta que la inteligencia artificial, con el tiempo, también permitirá mejorar la predicción de qué prematuros necesitarán mayores cuidados, además de predecir cuáles tendrán un PPT. Subrayan tres grandes fuentes de información:

- **Registros electrónicos de salud:** Permitirán modelar con precisión las posibles complicaciones asociadas al PPT.
- **Datos biológicos tipo “ómicos” (*multi-omics*):** Ayudarán a descubrir nuevos mecanismos biológicos subyacentes al PPT, ampliando la comprensión de su fisiopatología.
- **Determinantes sociales de la salud:** Factores que influyen en los riesgos maternos e infantiles.

Resaltan la importancia de la interpretabilidad de los resultados, diseñando modelos comprensibles que permitan evitar posibles sesgos que puedan comprometer su adopción.

La predicción tradicional del parto prematuro se ha basado principalmente en la historia clínica (antecedentes de parto pretérmino), la longitud cervical por ecografía transvaginal y, en algunos casos, biomarcadores como la fibronectina fetal. Sin embargo, estos enfoques tienen sensibilidad y especificidad limitadas. Es aquí donde la IA puede marcar la diferencia. Modelos de aprendizaje supervisado y no supervisado permiten identificar patrones complejos en datos heterogéneos —clínicos, bioquímicos, ecográficos, genéticos y de dispositivos portátiles— que serían indetectables mediante análisis convencionales.

Uno de los modelos más utilizados en este contexto ha sido el *Random Forest*, que ya ha demostrado su capacidad para manejar datos incompletos, evitar el sobreajuste y ofrecer resultados fácilmente interpretables. También se han aplicado modelos como *Support Vector Machines* (SVM), Redes Neuronales Profundas (DNN) y el *Gradient Boosting Method* (GBM), cada uno con diferentes grados de éxito dependiendo del tipo y volumen de datos disponibles. Por ejemplo, el modelo GBM se ha utilizado con éxito en cohortes hospitalarias para predecir partos pretérminos espontáneos combinando datos de longitud cervical, marcadores inflamatorios en suero y características sociodemográficas.

La revisión de Lee et al. (2020) sobre la aplicación de la IA al diagnóstico precoz del PPT ofrece recomendaciones sobre qué MAM debería usarse según el tipo de dato analizado:

- **Datos numéricos clínicos:** Redes neuronales artificiales, regresión logística, bosques aleatorios.
- **Datos electrohisterográficos:** Máquinas de soporte vectorial.
- **Datos de texto clínicos:** Redes neuronales recurrentes.
- **Imágenes médicas:** Redes neuronales convolucionales.


La exactitud de los modelos varía entre 0.79 y 0.94, la sensibilidad entre 0.22 y 0.97, la especificidad entre 0.86 y 1, y el AUC entre 0.54 y 0.83. La conclusión del estudio es que existen diferentes técnicas de IA eficaces para la detección temprana, pero estas deben adaptarse al tipo de dato disponible para mejorar su rendimiento.

Algunos sectores son reticentes a utilizar MAM porque consideran que los resultados son poco predecibles, en el sentido de que el profesional que los tiene que interpretar no puede dar una explicación detallada de los algoritmos utilizados por el sistema. Por ello, también existen asistentes para la interpretación y explicación de resultados, como el *Shapley Additive Explanations* (SHAP) o el *Local Interpretable Model-agnostic Explanations* (LIME), que permiten que la obtención de resultados de los MAM genere información más confiable.

Khan et al. (2023) realizaron un estudio donde utilizaron seis tipos de MAM para predecir PPT, añadiendo SHAP y LIME. Evaluaron de forma prospectiva una cohorte de 3509 mujeres con embarazos únicos y tuvieron en cuenta 35 factores de riesgo identificados previamente por otros estudios. Se identificó XGBoost como

el MAM con mejor rendimiento. Las ROC fueron de 0.735 para las mujeres multíparas y 0.723 para las nulíparas. La incidencia global de PPT fue 11.23 %. Los principales factores de riesgo en multíparas fueron: el antecedente de PPT, cesárea previa, preeclampsia y edad materna. Los principales para nulíparas fueron: el IMC al momento del parto, la edad materna y la presencia de infección amniótica. Con estos resultados, se puede afirmar que los MAM han tenido una capacidad discriminativa aceptable para distinguir entre embarazadas que tendrán un parto prematuro y las que no. Los sistemas añadidos permitieron identificar e interpretar mejor los resultados, determinando cuáles fueron los factores de riesgo más influyentes.

Gráfica 1.



Varios estudios han demostrado la eficacia de modelos de IA para predecir el PPT. Gao et al. (2019) desarrollaron un modelo de *deep learning* expuesto a bases de datos (*dataset*) modificadas para balancear la proporción de casos y controles. Además, utilizaron técnicas de procesamiento de lenguaje como *Word Embedding* y *Bag of Words* para codificar conceptos médicos dentro de los registros. Este modelo (red neuronal recurrente) logró predecir partos extremadamente prematuros (menores de 28 semanas) con una sensibilidad (0.96 vs. 0.68) y especificidad superiores a los métodos convencionales (regresión logística, máquinas de soporte vectorial, método de aumento de gradiente). Obtuvieron un área bajo la curva (AUC) de 0.811 frente a 0.76-0.78 de los métodos convencionales. Utilizando una red neuronal profunda alimentada con más de 25 000 registros de pacientes, este modelo identificó combinaciones de factores de riesgo que pasaban desapercibidas en los enfoques tradicionales. Al utilizar datos temporales, demostró un avance de hasta 8 semanas en el diagnóstico del PPT. Identificar embarazos en riesgo de un parto extremadamente prematuro y derivarlos a un centro que cuente con una unidad de cuidados intensivos neonatales adecuada puede mejorar los resultados a corto y largo plazo para estos recién nacidos. Los hospitales con falta del nivel apropiado de UCI-Neo adolecen de personal entrenado y ventiladores apropiados para su correcto tratamiento. Esta novedosa evaluación tiene una utilidad muy alta en la elección del hospital, dadas las necesidades especiales de los prematuros extremos.


Gráfica 2.

Model	AUC	SN	SP	PPV
SVM_BOW	0.769 (0.754–0.783)	0.749 (0.734–0.764)	0.724 (0.711–0.737)	0.754 (0.723–0.775)
LR_MEAN	0.765 (0.755–0.774)	0.715 (0.694–0.736)	0.753 (0.733–0.774)	0.753 (0.740–0.766)
LR_BOW_MEAN	0.780 (0.765–0.794)	0.771 (0.744–0.798)	0.778 (0.759–0.797)	0.779 (0.763–0.795)
LSTM_WORD2VEC	0.811 (0.799–0.823)	0.797 (0.774–0.821)	0.777 (0.757–0.797)	0.788 (0.776–0.800)

El estudio de Andrade Junior et al. (2023) evidencia la necesidad de un cambio en el cribado utilizado en muchos hospitales. Muchos centros usan la medición de la longitud cervical (LC) para valorar el riesgo de PPT por debajo de las 35 semanas. En este estudio se compara el rendimiento de la medición de LC transvaginal menor de 25 mm frente a un modelo de regresión logística (RL) multivariable no ajustada, y frente al mejor algoritmo de IA detectado durante el estudio (el SBELM, modelo de ensamble basado en *stacking*). Se analizaron 524 embarazos únicos entre las 18 y 24 semanas. Fijando una tasa de falsos positivos del 10 %, se obtuvieron los siguientes resultados:


- **Utilizando LC:** AUC: 0.318, Sensibilidad 33.3 %, Especificidad 91.8 %, VPP 23.1 %, VPN 94.9 %.
- **Utilizando IA:** AUC: 0.808, Sensibilidad 47 %, Especificidad 92.8 %, VPP 32.7 %, VPN 96 %.

Gráfica 3.



El modelo de IA mejoró significativamente respecto al método tradicional de la medición de LC menor de 25 mm, con una diferencia estadísticamente significativa. Bajo el análisis SHAP, la variable LC es el principal contribuyente al riesgo de PPT, sobre todo al ser menor de 20 mm. Las siguientes variables influyentes son: no haber tomado antibióticos, un parto previo prematuro, peso materno menor de 58 kilos, angulación cervical alterada, presencia de *funneling*, legrados previos y no fumar (en orden de importancia). La incorporación de la IA permite un cribado más eficaz, mejorando notablemente su rendimiento global, por lo que su implementación podría mejorar la detección temprana del PPT, siendo altamente recomendada.

Gráfica 4.



En una revisión sistemática reciente, Shahiri et al. (2022) evaluaron múltiples modelos de *machine learning* aplicados al diagnóstico de PPT y concluyeron que los algoritmos basados en árboles de decisión y redes neuronales ofrecían una alta capacidad discriminativa, con valores de AUC (área bajo la curva ROC) superiores al 0.85 en varios casos.

Kong et al. (2024) emplearon plataformas *autoML* para desarrollar modelos predictivos utilizando datos de altas hospitalarias, identificando como predictores relevantes la historia de PPT, edad materna y ciertos biomarcadores inflamatorios. De forma similar, Sun et al. (2022) diseñaron un modelo retrospectivo basado en datos de más de 50 000 gestaciones que incorporaba variables clínicas y ecográficas para predecir la probabilidad de parto prematuro antes de las 34 semanas.

Un aspecto especialmente prometedor es la integración de datos longitudinales, como se mostró en el trabajo de Huang et al. (2024), quienes construyeron un modelo que aprovechaba datos recopilados en múltiples visitas prenatales. Este enfoque permitió mejorar significativamente la sensibilidad en la predicción temprana, al capturar cambios dinámicos en los parámetros clínicos de la madre y el feto.

Belaghi et al. (2024) expuso diferentes MAM a 145 846 embarazos de una base canadiense (*BORN- Ontario Better Outcomes Registry and Network*), que incluye información de madres múltiples desde las 20 hasta las 42 semanas de embarazo, con una tasa de PPT del 5.57 %. Encontraron que:

- **En 1.^{er} trimestre:** La red neuronal artificial tuvo un AUC del 68.8 %.
- **En 2.º trimestre:** Logró un AUC del 72.1 %, y al añadir la información de complicaciones durante el embarazo, subió a 80.5 %.
- **Valor predictivo negativo:** Para el PPT global y espontáneo, el modelo alcanzó un VPN del 97 %, superando a marcadores como la fibronectina.

Con este estudio, se observa que se alcanza un valor alto de AUC asociado a un valor muy alto de VPN, lo que permite indicar la alta capacidad de este modelo para identificar embarazos no pretérmino, lo que ayudará a reducir las intervenciones innecesarias.

La IA también ha demostrado su utilidad en la estratificación del riesgo: no se trata solo de predecir si ocurrirá un parto pretérmino, sino de diferenciar entre casos de bajo, moderado o alto riesgo. Esto permite adaptar la intervención, desde vigilancia más estrecha, administración de corticosteroides, cerclaje, progestona vaginal o derivación a centros con unidades neonatales especializadas.

Algunos centros hospitalarios han comenzado a incorporar estos modelos como herramientas de apoyo a la toma de decisiones clínicas. Por ejemplo, Zhang et al. (2024), en el *Peking University Third Hospital*, compararon varios algoritmos de ML (*machine learning*) en entornos clínicos reales y encontraron que los

modelos integrados con los sistemas de HCE (historias clínicas electrónicas) podían alertar a los profesionales sobre pacientes con riesgo elevado de PPT con varias semanas de antelación. En este estudio se utilizaron 30 965 nacimientos como *dataset*, con una tasa de prematuros del 12.7 % (3164).

Además, se están explorando aplicaciones móviles que recopilan datos biométricos y autoinformados por las pacientes, que alimentan algoritmos en la nube para predecir riesgo de PPT en tiempo real. Estas tecnologías podrían ser especialmente útiles en contextos de baja disponibilidad de recursos médicos.

No obstante, también hay que reconocer las limitaciones actuales. Los modelos predictivos desarrollados en cohortes homogéneas pueden no ser generalizables a otras poblaciones. Las diferencias raciales, socio-económicas, genéticas y culturales influyen en los factores de riesgo y la presentación clínica del PPT. Además, la calidad de los datos sigue siendo una barrera. El entrenamiento de modelos precisos requiere bases de datos amplias, completas y estandarizadas, lo cual no siempre es factible. La interpretación de las decisiones del modelo también es un desafío; muchas veces los resultados carecen de una explicación clara, lo que puede generar desconfianza tanto en clínicos como en pacientes.

En resumen, las principales áreas donde la inteligencia artificial está demostrando utilidad en el abordaje del parto prematuro incluyen:

- Identificación precoz del riesgo de parto pretérmino antes de los síntomas clínicos.
- Integración de múltiples fuentes de datos (biomarcadores, ecografía, historia clínica).
- Estratificación dinámica del riesgo y personalización del tratamiento.
- Monitorización remota y continua mediante *wearables* (dispositivos) conectados a algoritmos de IA.
- Reducción de intervenciones innecesarias y optimización de recursos.
- Aumento de la cobertura en zonas con acceso limitado a servicios obstétricos especializados.

Como ocurrió con la preeclampsia, el potencial de la IA en el diagnóstico y manejo del parto prematuro es enorme, pero su éxito dependerá en gran medida de la calidad, interoperabilidad y accesibilidad de los datos, así como de la aceptación ética y legal de estas herramientas. La creación de consorcios internacionales, el desarrollo de estándares para el intercambio de datos y la validación externa de los modelos son pasos necesarios para lograr una implementación segura y eficaz.

4.5. Sistemas de Apoyo para la Toma de Decisiones en el Parto

Miquel Martra Celma

4.5.1. Introducción

En la última década, las publicaciones sobre inteligencia artificial (IA) en medicina han experimentado un crecimiento exponencial. Según PubMed, se han registrado más de 300.000 referencias, con un incremento significativo desde las 126.000 de 2020. En el ámbito de la obstetricia y la ginecología, la IA ha comenzado a consolidarse en áreas como la interpretación de registros cardiotocográficos, el análisis de mamografías y ecografías mamarias, las ecografías obstétricas y las técnicas de reproducción asistida. No obstante, el enorme potencial de esta tecnología sugiere una expansión progresiva hacia otros ámbitos del manejo clínico en los próximos años.

Este capítulo se centra en el uso actual de herramientas basadas en inteligencia artificial aplicadas a la toma de decisiones durante el trabajo de parto, así como en las perspectivas futuras de su integración en la práctica obstétrica.

La obstetricia ha sido, durante décadas, una de las especialidades médicas con mayor índice de litigios, en parte debido a la elevada sensibilidad de las intervenciones realizadas durante el nacimiento. Las reclamaciones legales no siempre derivan de daños neurológicos evidentes; en muchos casos, están relacionadas con la percepción de una atención inadecuada, ya sea por fallos en la comunicación, ausencia de consentimiento

informado, deficiente aplicación de protocolos o realización de intervenciones innecesarias o desproporcionadas —como inducciones no indicadas, cesáreas evitables, maniobras de Kristeller o episiotomías rutinarias—. En otras palabras, muchas de estas reclamaciones tienen su origen en el incumplimiento de las expectativas del parto por parte de la paciente.

Las consecuencias socioeconómicas de estos eventos son cada vez más relevantes. Algunas indemnizaciones ya superan los millones de euros, lo que representa un impacto considerable tanto para los sistemas públicos como para las aseguradoras del ámbito privado.

Entre las principales causas de litigio grave destaca la encefalopatía hipóxico-isquémica (EHI), una patología neonatal severa asociada a la asfixia intraparto. Su incidencia se estima entre 2,5 y 5 por cada 1.000 nacidos vivos^{1 2}, y en muchos casos se relaciona con una interpretación incorrecta del registro fetal o con una respuesta médica inadecuada, frecuentemente por retraso en la toma de decisiones. Se calcula que hasta el 50 % de estos casos podrían ser prevenibles³.

Atrás han quedado los tiempos en los que el obstetra decidía de forma unilateral la conducción del parto, priorizando la vía vaginal como objetivo principal. Durante años, se consideró un éxito cualquier parto eutócico, sin tener en cuenta ni los deseos de la mujer ni las consecuencias funcionales y emocionales a largo plazo. Este modelo desatendía complicaciones frecuentes como la incontinencia urinaria o fecal, la dispareunia, los prolapsos o el impacto psicológico de partos vividos como traumáticos.

En la obstetricia actual, se reconoce que el éxito de un parto no depende exclusivamente de su vía, sino de una experiencia global segura, respetuosa y coherente con las expectativas y valores de la madre. Un parto vaginal no puede considerarse plenamente satisfactorio si ha implicado maniobras forzadas, separación innecesaria del recién nacido o sufrimiento evitable.

Este cambio de paradigma ha ido acompañado de una proliferación de nuevas modalidades de parto —parto respetado, parto en el agua, parto domiciliario, parto sin intervenciones— que, si bien responden a la legítima demanda de humanizar y desmedicalizar el nacimiento, también plantean retos importantes. Existe el riesgo de idealizar procesos fisiológicos sin valorar adecuadamente los riesgos clínicos, generando expectativas poco realistas y comprometiendo la seguridad materno-fetal. La obstetricia moderna debe buscar un equilibrio entre la autonomía materna y la seguridad clínica, evitando tanto la sobreintervención como el dogmatismo del “parto natural”.

Pero... ¿y si contáramos con una herramienta objetiva, fiable y dinámica para apoyar la toma de decisiones en tiempo real? En un futuro cada vez más cercano, la inteligencia artificial permitirá predecir con precisión las probabilidades de un parto vaginal exitoso, la necesidad de cesárea y el riesgo de complicaciones como hemorragia, desgarros, episiotomía, ingreso neonatal o separación madre-hijo. Y no lo hará como una simple fotografía inicial, sino como un sistema adaptativo capaz de actualizar sus predicciones conforme progresa el trabajo de parto.

Imaginemos un escenario en el que una mujer pueda, desde el inicio del proceso, acceder a información personalizada, comprensible y basada en evidencia sobre los riesgos y beneficios de cada opción. Un entorno donde sus decisiones se basen no en intuiciones o experiencias previas sesgadas, sino en datos objetivos, contextualizados y en constante evolución. Un parto en el que se reduzcan la incertidumbre, los arrepentimientos y las sensaciones de pérdida de control. Un futuro en el que, gracias a la inteligencia artificial, el acompañamiento clínico sea más preciso, más respetuoso y verdaderamente centrado en la mujer.

Ese es el reto —y la promesa— de la obstetricia basada en inteligencia artificial. Y es precisamente de eso de lo que trata este capítulo.

4.5.2. Asistencia en Cesáreas y Partos Vaginales: Uso de Inteligencia Artificial en la Predicción de la Vía del Parto

La predicción de la vía del parto —específicamente, la identificación de mujeres con alta probabilidad de requerir una cesárea— constituye una de las aplicaciones más prometedoras de la inteligencia artificial (IA)

en obstetricia. Esta predicción temprana y precisa permitiría personalizar el plan de parto, reducir intervenciones innecesarias, optimizar la asignación de recursos y, en última instancia, mejorar la seguridad materno-fetal.

Los modelos tradicionales de predicción se basan en regresiones logísticas o *scores* clínicos que incorporan variables como la edad materna, el IMC, la paridad, la edad gestacional, el peso fetal estimado y la altura uterina o la dilatación en el momento de la evaluación. Sin embargo, estos modelos presentan limitaciones para capturar relaciones no lineales o interacciones complejas entre variables. La IA, y en particular el aprendizaje automático (*machine learning*), ha demostrado ser capaz de superar estas limitaciones y ofrecer una mayor precisión predictiva.

Entre los trabajos revisados, destacan varios estudios que han empleado modelos de *machine learning*, redes neuronales o sistemas híbridos para anticipar la vía del parto. A continuación, se resumen los más representativos:

El “Adana System” de Beksac et al. (2018)⁵

Este fue uno de los primeros intentos publicados de aplicar redes neuronales artificiales al apoyo en la decisión sobre la vía del parto. El modelo fue entrenado con datos retrospectivos recogidos en el momento del ingreso de la gestante al paritorio para predecir si el parto finalizaría vía vaginal o cesárea.

El modelo se construyó a partir de tres cohortes históricas de partos atendidos en la Hacettepe University (Turquía), correspondientes a los años 1976 (n = 2.127), 1986 (n = 3.548) y 1996 (n = 1.723). Se excluyeron del análisis las cesáreas electivas, las indicaciones sociales, los mortinatos y los casos con decisiones clínicas erróneas, tanto en cesáreas como en partos vaginales.

Las variables de entrada incluyeron edad materna, gestaciones previas, paridad, edad gestacional, tipo de inducción (si la había), presentación fetal y comorbilidades maternas o factores de riesgo. La predicción se realizaba antes de que avanzara el trabajo de parto, y el modelo proporcionaba una salida binaria: parto vaginal o cesárea.

Los resultados mostraron una especificidad muy alta (97,5 %), lo que sugiere una gran capacidad para identificar correctamente a las mujeres que podrán culminar un parto vaginal. Sin embargo, la sensibilidad fue más modesta (60,9 %), lo que implica que el modelo no identificó correctamente a todas las pacientes que acabarían en cesárea. El valor predictivo positivo fue del 81,8 %, y el negativo del 93,1 %. La tasa global de error se situó en un 8,2 %.

El estudio demostró que es posible entrenar un sistema de IA a partir de decisiones clínicas históricas para ayudar a reducir la variabilidad médica. Por otro lado, sus limitaciones son relevantes: el modelo fue desarrollado en un único centro, sin validación externa y sin integrar datos dinámicos del curso del parto, lo que limita su aplicabilidad en escenarios complejos o cambiantes.

En conjunto, el Adana System constituyó un ejemplo pionero de IA aplicada a la predicción de la vía del parto, y puede considerarse una contribución valiosa al desarrollo de herramientas de soporte clínico que, adecuadamente entrenadas y validadas, podrían facilitar una toma de decisiones más objetiva.

Caso Destacado: Fernández et al. (2022) – Sistema de Soporte Clínico en Hospital Español⁶

Este estudio, realizado en colaboración entre la Universidad de Alicante y el Hospital Clínico Universitario Virgen de la Arrixaca de Murcia, tenía como objetivo desarrollar un sistema de soporte a la decisión clínica (CDSS) que ayudara al ginecólogo a anticipar si un parto terminaría por vía vaginal (eutócica o instrumental) o cesárea, utilizando técnicas de *machine learning* aplicadas a una amplia base de datos clínicos.

Utilizando datos de más de 25.000 partos, se entrenaron modelos Random Forest, SVM y redes neuronales (MLP) para predecir la vía del parto con una precisión del 91 % en la clasificación cesárea vs. vaginal, y 86 % en eutócico vs. instrumental.

Se incluyeron partos espontáneos y partos inducidos por indicación médica. Se extrajeron un total de 48 variables clínicas periparto, como la edad materna, paridad, antecedentes obstétricos, estado de las membranas, uso de analgesia, fiebre intraparto, entre otras.

El sistema se estructuró en dos clasificadores secuenciales:

- El primero diferenciaba entre parto vaginal y cesárea.
- El segundo, entre parto vaginal eutócico y parto instrumental, si la predicción previa era parto vaginal.

Para el entrenamiento y validación se aplicaron tres algoritmos ampliamente utilizados en *machine learning*:

- Random Forest
- Support Vector Machines (SVM)
- Multilayer Perceptron (MLP, una red neuronal artificial)

Todos los modelos se sometieron a preprocesamiento estadístico (normalización, selección de variables, balanceo de clases) y validación cruzada.

Los resultados fueron muy consistentes. En el primer clasificador (cesárea vs. vaginal), la precisión fue del 91 % en los modelos Random Forest y SVM, y del 90 % en MLP. El F1-score, que equilibra sensibilidad y especificidad, osciló entre 0.89 y 0.91. Para el segundo clasificador (eutócico vs. instrumental), la precisión fue del 86–87 % en los tres modelos.

Pese a su solidez, el modelo aún no ha sido implementado ni validado externamente en otros centros. Tampoco se diseñó para operar en tiempo real durante el trabajo de parto. Además, como en otros estudios retrospectivos, se asumió como válida la decisión clínica final de cada parto, lo que podría introducir sesgos en el entrenamiento del sistema.

Caso Destacado: Owusu-Adjei et al. (2025) – *Machine Learning Accesible en Ghana*⁷

Un estudio especialmente interesante por su aplicabilidad clínica y uso de algoritmos accesibles es el desarrollado por Owusu-Adjei et al. (2025), realizado en el Kwahu Government Hospital, en Ghana. Este trabajo no propone un sistema de inteligencia artificial como tal, pero sí aplica técnicas de *machine learning* supervisado —específicamente, *random forest* y *gradient boosting*— para predecir la vía del parto (vaginal vs. cesárea) a partir de variables clínicamente disponibles.

El estudio incluyó 842 gestantes atendidas entre enero y septiembre de 2020. Se recogieron variables del partograma y del historial clínico, incluyendo: edad gestacional, dilatación cervical, presión arterial, frecuencia cardíaca fetal, número de gestaciones, abortos previos y muertes fetales. Tras aplicar un test chi-cuadrado para seleccionar las variables predictivas más significativas, se entrenaron y compararon tres algoritmos: regresión logística (estadística clásica), *random forest* y *gradient boosting* (*machine learning*).

De todas las variables, solo dos mostraron correlación estadísticamente significativa con la vía del parto: la edad gestacional y la dilatación cervical al ingreso. El mejor rendimiento predictivo lo obtuvo la regresión logística (AUC = 0.93), seguida de *random forest* (AUC = 0.91) y *gradient boosting* (AUC = 0.91). En términos de *balanced accuracy*, los valores fueron 84,6 %, 83 % y 82,7 %, respectivamente.

Aunque la regresión logística —una técnica estadística convencional— fue la más precisa, la inclusión de algoritmos de *machine learning* como *random forest* y *gradient boosting* sitúa este estudio en una zona intermedia entre la estadística tradicional y la inteligencia artificial. No se trata de un sistema adaptativo ni dinámico, y no se presenta como una herramienta de soporte clínico automatizada, pero demuestra la viabilidad de aplicar técnicas de IA incluso en entornos con recursos limitados.

Entre sus limitaciones destacan el tamaño muestral relativamente reducido, la ausencia de validación externa y la falta de integración de variables antropométricas o psicosociales que podrían haber enriquecido el modelo. No obstante, su valor reside en mostrar que con datos clínicos básicos y algoritmos accesibles, se puede mejorar la capacidad predictiva sobre la vía del parto, sentando las bases para futuros desarrollos más complejos.

En resumen, se trata de un ejemplo de transición entre estadística y *machine learning*, que subraya el potencial de la inteligencia artificial en obstetricia incluso en contextos donde la implementación tecnológica aún es incipiente.

Caso Destacado: Guedalia et al. (2021) – Transportabilidad de Modelos entre Hospitales⁸

La mayor parte de los modelos de IA en obstetricia han sido desarrollados en un único centro y carecen de validación externa, lo que limita su aplicabilidad en contextos clínicos distintos.

Este estudio se diseñó, específicamente, para evaluar la aplicabilidad de modelos de predicción de cesárea urgente en diferentes centros. Utilizando datos de más de 100.000 partos, mostraron que los modelos podían trasladarse entre hospitales si se ajustaban las variables clave.

Los autores diseñaron y entrenaron dos modelos de *machine learning* a partir de una base de datos de aproximadamente 100.000 partos en el Hospital A, empleando más de 11 millones de puntos de datos extraídos de historias clínicas electrónicas y a continuación aplicaron el modelo en el Hospital B.

Se desarrollaron dos tipos de modelos:

- **Modelo de ingreso:** basado en datos disponibles al llegar a la sala de partos.
- **Modelo de progresión del trabajo de parto:** que incorpora variables adicionales conforme avanza el parto.

Ambos modelos mostraron un rendimiento elevado para la predicción de cesárea urgente en el hospital original, con áreas bajo la curva (AUC) de 0.82 para el modelo de ingreso y 0.86 para el modelo de progresión.

El aspecto más innovador del estudio fue la evaluación de estos modelos cuando se transportaban a otro centro, el Hospital B, con una población de aproximadamente 60.000 partos. Al aplicar el modelo entrenado en Hospital A sobre los datos del Hospital B, el rendimiento se mantuvo estable. Sin embargo, al invertir el proceso —transportar el modelo del Hospital B hacia el Hospital A—, el modelo de progresión perdió precisión (AUC bajó de 0.84 a 0.77).

Según los autores, la causa principal en la pérdida de precisión fueron las diferencias en la forma de registrar variables clínicas clave como la estática fetal o la dilatación cervical.

Para mitigar este efecto, los autores propusieron una recalibración de los datos, alineando las distribuciones de las variables críticas entre centros, lo que permitió recuperar parcialmente el rendimiento del modelo transportado (AUC corregido: 0.82).

Por otro lado, se evaluó también la aplicabilidad del modelo de Hospital A en entornos con menos recursos. Simulando hospitales con bases de datos progresivamente más pequeñas (5.000, 15.000 y 25.000 partos), se comprobó que el modelo externo, aun sin ser entrenado localmente, ofrecía mejor rendimiento que los modelos desarrollados *in situ* con datos reducidos. Este hallazgo pone en valor la posibilidad de aprovechar modelos desarrollados en grandes centros para mejorar la atención en hospitales más pequeños o con limitaciones tecnológicas.

Este estudio no se centra en la creación de un nuevo modelo, sino en un aspecto esencial para el futuro de la IA clínica: su validación externa y capacidad de generalización. Los autores concluyen que el éxito de la inteligencia artificial en obstetricia no dependerá solo del rendimiento interno de los modelos, sino de su adaptabilidad a diferentes poblaciones, protocolos y sistemas de registro. La IA, en este contexto, no debe considerarse una herramienta estática, sino un sistema que requiere ajuste, contextualización y validación continua para ser verdaderamente útil y segura en la práctica clínica.

El estudio de Hu et al. (2022)⁹ se centró en prever si una inducción con oxitocina en gestaciones a término culminaría en parto vaginal en ≤ 72 h. Aunque el modelo más eficaz fue la regresión logística, su rendimiento (AUC 0,89 en multíparas) superó ampliamente al de herramientas clásicas como la escala de Bishop. Introdujo, además, variables poco exploradas, como medidas ecográficas fetales y diferenciación entre primíparas y multíparas.

Lipschuetz et al. (2020) – Predicción Personalizada del Éxito del Parto Vaginal Tras Cesárea (VBAC) Mediante Inteligencia Artificial¹⁰

El parto vaginal tras una cesárea previa (VBAC) continúa siendo uno de los principales dilemas clínicos en obstetricia moderna, ya que debe equilibrar la reducción de cesáreas innecesarias con el riesgo potencial de

complicaciones, como la rotura uterina. En este contexto, el estudio de Lipschuetz et al. (2020), publicado en el *American Journal of Obstetrics and Gynecology*, representa un ejemplo avanzado de aplicación de técnicas de inteligencia artificial para la predicción individualizada del éxito del VBAC.

El trabajo se llevó a cabo en el Hadassah Medical Center (Jerusalén, Israel), utilizando una cohorte retrospectiva de 9.888 gestantes con antecedentes de una única cesárea, gestación única a término y sin anomalías fetales. De estas, el 75,6 % intentaron un TOLAC (trabajo de parto tras cesárea), con un índice de éxito del 88 %, cifra significativamente superior a la reportada en otras series.

Los investigadores desarrollaron dos modelos predictivos empleando el algoritmo de *gradient boosting*:

- **Un modelo basado en variables del primer trimestre**, que permite estimar el pronóstico desde el inicio del seguimiento prenatal.
- **Un modelo preparto**, actualizado con datos disponibles al ingreso en la unidad de partos, como la dilatación cervical, la estación fetal o si el parto fue inducido.

Ambos modelos fueron entrenados y validados utilizando métodos de validación cruzada y validación externa temporal (sobre cohortes de años distintos), con un desempeño robusto:

- El modelo preparto permitió una estratificación de riesgo altamente precisa. Entre las pacientes clasificadas como de bajo riesgo, el 97,3 % culminaron el parto por vía vaginal. En contraste, en el grupo de alto riesgo (32 % de las gestantes), el éxito descendía al 73,3 %. Además, al aplicar retrospectivamente el modelo a mujeres que optaron por cesárea electiva, se identificó que el 31 % de ellas podrían haber tenido una alta probabilidad de éxito en un VBAC, lo que sugiere un margen de mejora en la toma de decisiones clínicas compartidas.

Este estudio aporta múltiples elementos diferenciales respecto a trabajos previos:

- Utiliza algoritmos de aprendizaje avanzado (*gradient boosting*) frente a las tradicionales regresiones logísticas.
- Ofrece predicciones individualizadas y longitudinales, desde el primer trimestre hasta el ingreso hospitalario.
- Aplica una validación externa rigurosa, mejorando su aplicabilidad práctica.
- Incluye variables obstétricas detalladas, como resultados de partos previos, que rara vez se integran en modelos automatizados.

Entre sus limitaciones, cabe destacar que se trata de un estudio unicéntrico y retrospectivo, y que no se incluyeron predictores de complicaciones graves (como rotura uterina o desenlaces neonatales adversos). Sin embargo, su capacidad para identificar a las pacientes con mayor probabilidad de éxito y su aplicabilidad potencial en la toma de decisiones compartida lo convierten en uno de los estudios más completos publicados hasta la fecha sobre predicción del VBAC mediante IA.

Caso Destacado: Macones et al. (2001) – Comparación entre Modelos de Regresión y Redes Neuronales para Predecir el Éxito del VBAC¹¹

El estudio de Macones et al., publicado en *American Journal of Obstetrics and Gynecology* en 2001, es uno de los primeros intentos documentados de aplicar redes neuronales artificiales para predecir el resultado de un intento de parto vaginal tras cesárea (VBAC). Su objetivo era comparar la precisión de un modelo multivariante clásico frente a una red neuronal entrenada con los mismos datos.

El trabajo se basó en un diseño caso-control, en el que se seleccionaron 100 mujeres con fallo del TOLAC (*Trial of Labor After Cesarean*) y 300 controles con parto vaginal exitoso tras cesárea previa. Se analizaron

más de 70 variables clínicas, incluyendo antecedentes obstétricos, características de la gestación actual y datos recogidos al ingreso.

Mediante un análisis bivariado inicial, se identificaron los predictores más relevantes, que posteriormente se incluyeron en un modelo de regresión logística paso a paso. Las variables finalmente seleccionadas fueron:

- Abuso de sustancias durante el embarazo (OR ajustada: 0,27)
- VBAC previo exitoso (OR ajustada: 0,13)
- Dilatación cervical al ingreso (OR ajustada: 0,53)
- Necesidad de oxitocina para inducción o aumento del parto (OR ajustada: 2,15)

Con este modelo multivariante se obtuvo una sensibilidad del 77 %, especificidad del 65 % y precisión global del 69 %.

En paralelo, se entrenó una red neuronal mediante algoritmo de retropropagación utilizando estas mismas variables (y otras combinaciones). Sin embargo, los resultados fueron inferiores: la red alcanzó una sensibilidad máxima del 63 % y una especificidad del 42 %, lo que refleja una capacidad predictiva más baja que el modelo estadístico tradicional.

Las limitaciones de este estudio eran varias: presentaba un tamaño muestral limitado (n=400), se basaba en un diseño retrospectivo caso-control, carecía de validación externa y los modelos fueron entrenados con un *software* primitivo. A pesar de estas, su hallazgo principal —que en ese momento las redes neuronales no superaban a la regresión logística— sirvió como punto de partida para futuros trabajos con mejores herramientas y mayor potencia computacional.

Caso Destacado: Meyer et al. (2020) – Comparación entre Modelos de *Machine Learning* y la Calculadora Clásica MFMU-C para Predecir el Éxito del VBAC¹²

El estudio de Meyer et al., publicado en *The Journal of Maternal-Fetal & Neonatal Medicine* en 2020, ofrece una comparación directa entre distintos algoritmos de *machine learning* y uno de los modelos clínicos más extendidos en la práctica obstétrica: la calculadora clásica elaborada por Maternal-Fetal Medicine Units Network (MFMU-C).

El objetivo fue predecir el éxito del parto vaginal tras cesárea (VBAC) en mujeres candidatas a un intento de parto tras cesárea previa (TOLAC), y evaluar si los modelos basados en inteligencia artificial ofrecían ventajas significativas frente a herramientas tradicionales.

La cohorte incluyó 989 gestantes con una o dos cesáreas previas, embarazo único ≥ 34 semanas, atendidas en un centro terciario israelí entre 2017 y 2018. La tasa global de éxito del VBAC fue del 85,6 %.

Los modelos comparados fueron:

- Random Forest
- XGBoost (*Extreme Gradient Boosting*)
- Generalized Linear Model (GLM)
- Modelo clínico tradicional MFMU-C

Este último, el modelo MFMU-C, ampliamente utilizado en la práctica clínica, es un modelo de regresión logística que estima la probabilidad de éxito del VBAC a partir de variables disponibles en la primera visita prenatal: edad materna, IMC, grupo étnico, historia obstétrica previa y tipo de cesárea anterior. Su simplicidad y accesibilidad han favorecido su difusión internacional, aunque su capacidad predictiva es limitada (AUC ~0,70–0,75), especialmente en contextos clínicos con mayor complejidad o variabilidad^{13, 14, 15}.

Las conclusiones del estudio afirman que los algoritmos de IA no solo son comparables al modelo clásico, sino que pueden ofrecer mayor precisión y simplicidad, utilizando menos variables.

El modelo XGBoost, en particular, identificó solo ocho variables clave con alto poder discriminativo, entre ellas: parto vaginal previo, altura materna, dilatación y borramiento cervical, estación fetal, tipo de inducción

y el motivo de la cesárea anterior (si fue por detención del descenso, tenía más impacto negativo que si fue por detención de la dilatación).

Con estas variables, el modelo fue capaz de clasificar correctamente al 80 % de las pacientes en un grupo de alta probabilidad de éxito, con una tasa de VBAC cercana al 90 %.

Aunque el estudio fue unicéntrico y no contó con validación externa, constituye una demostración clara del potencial de la inteligencia artificial para refinar decisiones clínicas complejas, incluso en escenarios donde ya existen herramientas consolidadas como el modelo MFMU-C. La ventaja añadida es que los modelos basados en *machine learning* permiten actualizarse con nuevas bases de datos, adaptarse a diferentes poblaciones y reconocer interacciones no lineales entre variables clínicas, lo que amplía sus posibilidades frente a los enfoques tradicionales.

Caso Destacado: Yang et al. (2022) – Predicción del Éxito del VBAC Mediante Tres Algoritmos de Machine Learning¹⁶

El estudio de Yang et al., publicado en *Scientific Reports* (2022), representa un ejemplo claro de cómo las técnicas de inteligencia artificial pueden aplicarse también en entornos clínicos con recursos moderados, para mejorar la predicción del éxito del parto vaginal tras cesárea (VBAC). El objetivo fue construir y comparar modelos predictivos basados en algoritmos de *machine learning* aplicados a variables clínicas accesibles durante el seguimiento prenatal y al ingreso hospitalario.

El estudio incluyó 410 mujeres con antecedentes de una única cesárea y sin contraindicaciones para el parto vaginal. Se recopilaron 19 variables clínicas, entre ellas: edad materna, paridad, duración del trabajo de parto previo, puntuación de Bishop, altura uterina, circunferencia abdominal fetal, índice de masa corporal y el intervalo entre partos, una variable poco incorporada en estudios previos.

Se construyeron y compararon tres modelos:

- Random Forest (RF)
- Support Vector Machine (SVM)
- XGBoost (*Extreme Gradient Boosting*)

Los resultados mostraron que el modelo XGBoost obtuvo el mejor rendimiento.

Entre las variables más predictivas destacaron la altura uterina, el índice de Bishop, el intervalo entre partos, la paridad previa y la circunferencia abdominal fetal.

Este estudio destaca por demostrar que la aplicación de IA no requiere grandes cohortes ni sistemas sanitarios hiperdesarrollados. Su enfoque es realista, clínicamente viable, y utiliza algoritmos conocidos y fácilmente implementables. Además, introduce variables como la altura uterina o el intervalo entre partos, que podrían considerarse en futuros modelos con mayor potencia estadística.

Un enfoque totalmente distinto al uso de la inteligencia artificial como herramienta útil en el manejo de pacientes sometidas a cesárea es el realizado por Chen et al.¹⁷ A diferencia de los trabajos anteriores centrados en la predicción de la vía del parto, este estudio utiliza algoritmos de *machine learning* para predecir la necesidad de transfusión intraoperatoria de concentrados de hemáties durante cesáreas electivas. Usando una base de datos de más de 14.000 procedimientos y seleccionando 10.147 casos válidos, el modelo alcanzó una AUC de 0,89 y una precisión del 96,85 % en la predicción de transfusión (aunque solo un 45 % de coincidencia exacta en volumen transfundido). Las variables más relevantes fueron el nivel preoperatorio de hemáties, el tipo de técnica quirúrgica, la localización quirúrgica y parámetros de coagulación. Su principal aportación es abrir la vía hacia un modelo de gestión perioperatoria de riesgo hemorrágico personalizado, con especial valor en contextos donde la disponibilidad de sangre es crítica o donde se requiere optimizar recursos. Aunque no incide directamente en la decisión sobre la vía del parto, su integración como herramienta preoperatoria puede ayudar a planificar recursos, prevenir eventos adversos y mejorar la seguridad materna.

Como señalan Bizzego et al. (2023)¹⁸ en su revisión crítica, el verdadero valor de la inteligencia artificial en obstetricia no reside exclusivamente en su capacidad predictiva, sino en su potencial para reducir la incertidumbre clínica, estandarizar decisiones complejas y facilitar una atención personalizada.

Los estudios revisados demuestran que los modelos de IA —especialmente aquellos basados en algoritmos de *ensemble* como XGBoost o Random Forest— ofrecen un rendimiento superior al de las regresiones clásicas. Además, permiten integrar múltiples variables clínicas, adaptar los modelos a distintas etapas del proceso obstétrico y optimizar la toma de decisiones en tiempo real.

Pese a ello, persisten desafíos: validación externa, interpretación clínica, interoperabilidad con sistemas hospitalarios y cuestiones éticas ligadas a la transparencia y explicabilidad de los modelos. La IA debe entenderse como una herramienta de apoyo —no de sustitución— del juicio clínico, especialmente valiosa en contextos de alta presión asistencial o incertidumbre diagnóstica.

En conjunto, estos avances configuran una nueva etapa en la obstetricia basada en datos, en la que el uso inteligente de la información permitirá una atención más segura, eficiente y centrada en la mujer.

4.5.3. IA para la Evaluación del Canal del Parto

La valoración de la progresión del parto es un aspecto central de la asistencia obstétrica. Tradicionalmente, la exploración vaginal digital ha sido considerada el “estándar de oro” para evaluar la dilatación cervical, el descenso y la posición de la cabeza fetal¹⁹. Sin embargo, se trata de un procedimiento invasivo, asociado a dolor, incomodidad materna, riesgo de infección y posible corioamnionitis, además de una importante variabilidad interobservador. Se ha descrito que dos clínicos pueden diferir en más de 2 cm en la estimación de la dilatación en aproximadamente un 11 % de los casos, y que la precisión disminuye conforme avanza el parto y se acerca la segunda etapa¹⁹. Asimismo, la capacidad diagnóstica de la exploración digital para determinar la posición cefálica es limitada, con una precisión de apenas un 70 % en el expulsivo, frente al 92 % reportado para la ecografía^{20, 21}.

Ante estas limitaciones, los organismos internacionales han revisado críticamente el papel del tacto vaginal en el control del parto. La Organización Mundial de la Salud (OMS) recomienda que los tactos se limiten a los estrictamente necesarios y, de ser posible, restringirse al mínimo indispensable²². El National Institute for Health and Care Excellence (NICE) aconseja realizarlos cada 4 horas durante la primera etapa del parto²³, mientras que el Royal College of Midwives sugiere que los lleve a cabo la misma matrona para reducir la variabilidad diagnóstica²⁴. Estas recomendaciones reflejan el interés global por desmedicalizar el parto de bajo riesgo y apoyar su evolución fisiológica.

Sin embargo, una vez alcanzada la segunda etapa del trabajo de parto, conocer con precisión la orientación de la cabeza fetal resulta determinante. Esta información influye en la dirección de los pujos, facilita maniobras de rotación manual, orienta las posturas maternas y condiciona la indicación y seguridad de un parto instrumental. La dificultad diagnóstica se incrementa en presencia de *caput succedaneum* o moldeado craneal, que enmascaran los reparos óseos, y también porque la valoración suele ser realizada por un profesional que no siempre ha acompañado toda la evolución del parto.

La ecografía intraparto se ha consolidado como una herramienta más objetiva y reproducible que el tacto digital. La ecografía transabdominal es actualmente la referencia más precisa para determinar la posición cefálica, mientras que la ecografía transperineal añade ventajas notables: permite valorar simultáneamente estación y rotación de la cabeza, ofrece una medición objetiva con menor variabilidad interobservador, se puede repetir sin riesgos añadidos y mejora la comunicación entre profesionales al aportar imágenes claras y reproducibles^{25, 26}.

El desarrollo reciente de herramientas basadas en inteligencia artificial (IA) promete revolucionar este campo. En primer lugar, un estudio multicéntrico internacional (ISLANDS) demostró que un modelo de *deep learning* basado en redes neuronales convolucionales puede identificar la posición cefálica en ecografía transperineal con una precisión global del 94,5 %, alcanzando un 98,3 % al diferenciar entre posición occipitoanterior y no anterior²⁷. Este tipo de algoritmos ofrece soporte objetivo en tiempo real, especialmente útil para profesionales con menor experiencia en ecografía intraparto.

Por otra parte, el Artificial Intelligence Dystocia Algorithm (AIDA) integra parámetros ecográficos bien establecidos —ángulo de progresión, distancia cabeza-sínfisis, ángulo de la línea media y grado de asinclitismo— con técnicas de *machine learning*. Este sistema clasifica la progresión del parto en cinco categorías de riesgo, mostrando una alta capacidad para predecir resultados y detectar precozmente distocia, lo que lo convierte en una herramienta de gran valor en la estratificación clínica y la planificación de intervenciones²⁸.

En conjunto, la integración de la ecografía intraparto con algoritmos de IA constituye un cambio de paradigma en la evaluación del canal del parto. Esta combinación no solo supera las limitaciones del tacto vaginal, sino que ofrece una valoración más objetiva, reproducible y dinámica, con el potencial de optimizar la seguridad materno-fetal, reducir intervenciones innecesarias y homogeneizar la práctica clínica en distintos contextos.

El uso de inteligencia artificial en ecografía en el contexto del parto también se ha explorado desde otra vertiente: la predicción de una inducción exitosa.

Hay que tener en cuenta que el proceso inducción-parto es sumamente complejo, siendo múltiples los condicionantes que pueden tener lugar a lo largo del mismo y que modifiquen su curso. Como se ha expuesto previamente, la predicción del resultado de la inducción basada en variables individuales es baja, y empleando modelos multivariable, si bien la predicción mejora, sigue siendo moderada y lejana aún de una tasa de detección razonable para emplear estos modelos en la práctica asistencial.

Si a esto le sumamos que la inducción al parto es una de las intervenciones más frecuentes en obstetricia, alcanzando tasas de hasta del 25-30 % en países desarrollados^{28, 29}, y que tradicionalmente se ha vinculado a un mayor riesgo de complicaciones como parto instrumentado, hiperestimulación uterina, sufrimiento fetal, hemorragia posparto o incluso rotura uterina²⁹, no es de extrañar que disponer de una herramienta que nos prediga la probabilidad de éxito de antemano sería de gran ayuda. En este ámbito, la inteligencia artificial (IA) emerge como una herramienta decisiva, capaz de integrar múltiples variables clínicas, ecográficas y de monitorización intraparto, superando las limitaciones de los métodos tradicionales como el Bishop score.

El test de Bishop, aunque es uno de los factores más importantes para predecir una inducción exitosa (conjuntamente con altura materna, IMC y peso fetal), su sensibilidad por sí mismo es muy limitada (23–64 %) con una elevada variabilidad interobservador³¹.

En la aplicación en práctica clínica de cualquier modelo de predicción se debe tener en cuenta la repercusión de los falsos positivos y falsos negativos del modelo. La tasa de falsos positivos de un modelo de predicción se incrementa a medida que aumenta la tasa de detección. Basándonos en la cesárea tras inducción de parto como variable resultado, los falsos positivos implican una incorrecta clasificación de un cierto número de embarazadas, a las que se les ofrecerá una cesárea programada en lugar de una inducción de parto, cuando con esta segunda opción habrían conseguido un parto vaginal. Dados los riesgos que conlleva la cesárea respecto al parto vaginal (mayor morbilidad materna y neonatal, mayor tiempo de ingreso, mayor coste económico), la repercusión de la tasa de falsos positivos sería muy negativa, y aunque no está claro cuál sería el punto de corte máximo para poder implementar el modelo, parece razonable que sea menor de un 5 %. En cuanto a los falsos negativos, suponen proponer una inducción de parto a un cierto número de mujeres cuando finalmente su inducción fracasará y se les acabará realizando una cesárea. Estos falsos negativos tampoco son deseables, pues incrementan el tiempo de ingreso y el uso de recursos, aunque quizás su repercusión es menor que la de los falsos positivos. Otro factor a considerar previamente a la implementación de un modelo de predicción es su validación. Mediante el proceso de validación interna se prueba la fiabilidad del modelo en un subgrupo de pacientes de la muestra sobre la que fue diseñado, para así comprobar que no sea un posible sobredimensionamiento la justificación de las buenas tasas. Con la validación externa, se prueba el algoritmo en una muestra de pacientes distinta, lo que permitiría la generalización de sus resultados. No en todos los modelos publicados en la bibliografía se ha llevado a cabo este protocolo de validación.

4.5.4. Conclusión

La integración de la inteligencia artificial en la predicción y manejo de la vía del parto representa un avance transformador para la obstetricia contemporánea. La evidencia revisada demuestra que los modelos de IA superan de manera consistente a las herramientas estadísticas tradicionales en precisión y capacidad de adaptación, alcanzando áreas bajo la curva superiores a 0,90 en distintos contextos clínicos. Estos modelos no solo permiten anticipar con fiabilidad la necesidad de cesárea, el éxito de una inducción o la probabilidad de un parto vaginal tras cesárea, sino que también facilitan una gestión más eficiente de recursos y una reducción de intervenciones innecesarias.

Entre los ejemplos más relevantes destacan el Adana System, pionero en Turquía; los modelos desarrollados en España con más de 25.000 partos que validan la utilidad de algoritmos como Random Forest y SVM; o el trabajo de Lipschuetz et al., que aplicando técnicas de *gradient boosting* logró estratificaciones precisas en mujeres candidatas a un VBAC. De forma complementaria, proyectos como el ERIFI en nuestro entorno o el algoritmo AIDA aplicado a la ecografía intraparto han puesto de manifiesto el valor añadido de integrar parámetros clínicos, ecográficos y dinámicos en tiempo real.

La IA en obstetricia no está exenta de retos. La heterogeneidad de las cohortes utilizadas, la escasez de validaciones multicéntricas y la ausencia de estándares de interoperabilidad limitan aún su aplicación universal. Además, cuestiones éticas como la transparencia de los algoritmos, la explicabilidad de las predicciones y el manejo seguro de datos sensibles siguen siendo barreras críticas. La aceptación por parte de profesionales y pacientes dependerá en gran medida de que estas herramientas se perciban como un complemento al juicio clínico, y no como un sustituto.

En conclusión, la IA tiene el potencial de convertirse en un pilar esencial de la obstetricia moderna, favoreciendo una atención más personalizada, segura y basada en la evidencia. Para ello, será imprescindible promover estudios prospectivos y multicéntricos, establecer marcos regulatorios claros y garantizar la formación de los equipos clínicos. Solo así podremos trasladar el enorme potencial teórico de la IA a una práctica obstétrica real que transforme la experiencia del parto y contribuya a mejorar los resultados maternos y perinatales.

Bibliografía

1. Yousefpour Shahrivar R, Karami F, Karami E. Enhancing Fetal Anomaly Detection in Ultrasonography Images: A Review of Machine Learning-Based Approaches. *Biomimetics*. 2023 Nov 2;8(7):519.
2. Venturini L, Budd S, Farruggia A, Wright R, Matthew J, Day TG, et al. Whole examination AI estimation of fetal biometrics from 20-week ultrasound scans. *npj Digit Med*. 2025 Jan 11;8(1):22.
3. Athalye C, Van Nisselrooij A, Rizvi S, Haak MC, Moon-Grady AJ, Arnaout R. Deep-learning model for prenatal congenital heart disease screening generalizes to community setting and outperforms clinical detection. *Ultrasound Obstet Gynecol*. 2024 Jan;63(1):44-52.
4. Lin M, Zhou Q, Lei T, Shang N, Zheng Q, He X, et al. Deep learning system improved detection efficacy of fetal intracranial malformations in a randomized controlled trial. *npj Digit Med*. 2023 Oct 13;6(1):191.
5. Bashir Z, Lin M, Feragen A, Mikolaj K, Taksøe-Vester C, Christensen AN, et al. Clinical validation of explainable AI for fetal growth scans through multi-level, cross-institutional prospective end-user evaluation. *Sci Rep*. 2025 Jan 15;15(1):2074.
6. EmbryoScan project. EmbryoScan: AI-based 3D Ultrasound for Early Prenatal Screening (Vall d'Hebron & Universitat Pompeu Fabra, Barcelona) [Internet]. [citado 2024 Abr 24]. Disponible en: embryoscanner.com
7. Han X, Yu J, Yang X, Chen C, Zhou H, Qiu C, et al. Artificial intelligence assistance for fetal development: evaluation of an automated software for biometry measurements in the mid-trimester. *BMC Pregnancy Childbirth*. 2024 Feb 23;24(1):158.
8. Fiorentino MC, Moccia S, Cosmo MD, Frontoni E, Giovanola B, Tiribelli S. Uncovering ethical biases in publicly available fetal ultrasound datasets. *npj Digit Med*. 2025 Jun 13;8(1):355.
9. Georgieva A, Payne SJ, Redman CWG. Artificial intelligence for intrapartum fetal monitoring: Progress and challenges. *Semin Fetal Neonatal Med*. 2017;22(2):91-9.

10. Fergus P, Cheung P, Hussain A, Al-Jumeily D, Dobbins C, Iram S. Prediction of preterm deliveries from cardiogram data using machine learning models. *Comput Biol Med.* 2020;121:103805.
11. Warrick PA, Hamilton EF, Precup D, Kearney RE. Classification of normal and hypoxic fetuses using temporal differences of fetal heart rate features. *Med Biol Eng Comput.* 2010;48(9):873–83.
12. Spilka J, Chudáček V, Burša M, Janků P, Lhotská L. Using nonlinear features for fetal heart rate classification. *Bio-med Signal Process Control.* 2012;7(4):350–7.
13. Jezewski J, Horoba K, Wrobel J, Matonia A, Kupka T. Hybrid system for the prediction of fetal hypoxia risk. *Comput Biol Med.* 2018;100:77–86.
14. Romano M, Costamagna M, Giansanti A. Wearable monitoring systems for fetal well-being: A review of the state-of-the-art. *Sensors (Basel).* 2021;21(2):485.
15. American Diabetes Association Professional Practice C. 2. Diagnosis and Classification of Diabetes: Standards of Care in Diabetes-2025. *Diabetes Care.* 2025;48(1 Suppl 1):S27–S49.
16. Liu J, Yang C, Liu B, Kim R, Philis-Tsimikas A, Isasi C, et al. Factors Associated with Progression to Type 2 Diabetes among Women with Gestational Diabetes. *J Urban Health.* 2025.
17. Gomez Fernandez C, Mitsigiorgi R, Fochini M, Leung A, Fernandez Perez C, Nicolaides KH. Continuous glucose monitoring: criteria for the diagnosis of type 2 diabetes mellitus with clinical obesity after gestational diabetes. *Am J Obstet Gynecol.* 2025.
18. Bellamy L, Casas JP, Hingorani AD, Williams D. Type 2 diabetes mellitus after gestational diabetes: a systematic review and meta-analysis. *Lancet.* 2009;373(9677):1773–9.
19. Lowe WL Jr, Scholtens DM, Lowe LP, Kuang A, Nodzenski M, Talbot O, et al. Association of Gestational Diabetes With Maternal Disorders of Glucose Metabolism and Childhood Adiposity. *JAMA.* 2018;320(10):1005–16.
20. Martinez-Juarez LA, Gallardo-Rincon H, Saucedo-Martinez R, Mujica-Rosales R, Reyes-Munoz E, Alvarez-Hernandez DA, et al. A strategic framework for managing gestational diabetes in Mexico. *Glob Health Res Policy.* 2025;10(1):12.
21. Suarez-Cruz MG, Rivas-Ruiz R, Sarmiento-Galvan DK, Martinez-Valle PG, Mondragon-Sandoval EX, Lopez-Farias MA, et al. [Effect of weight gain on the development of gestational diabetes]. *Rev Med Inst Mex Seguro Soc.* 2023;61(Suppl 3):S460–S7.
22. Font-López KC, G-CM. Diagnóstico de diabetes gestacional en población mexicana. *Ginecol Obstet Mex.* 2017;85(2):116–24.
23. AlSaad R, Elhenidy A, Tabassum A, Odeh N, AboArqoub E, Odeh A, et al. Artificial Intelligence in Gestational Diabetes Care: A Systematic Review. *J Diabetes Sci Technol.* 2025;19322968251355967.
24. Farrar D. Hyperglycemia in pregnancy: prevalence, impact, and management challenges. *Int J Womens Health.* 2016;8:519–27.
25. Huang QF, Hu YC, Wang CK, Huang J, Shen MD, Ren LH. Clinical First-Trimester Prediction Models for Gestational Diabetes Mellitus: A Systematic Review and Meta-Analysis. *Biol Res Nurs.* 2023;25(2):185–97.
26. Khalafallah A, Phuah E, Al-Barazan AM, Nikakis I, Radford A, Clarkson W, et al. Glycosylated haemoglobin for screening and diagnosis of gestational diabetes mellitus. *BMJ Open.* 2016;6(4):e011059.
27. Zera CA, Seely EW. Controversies in Gestational Diabetes. *touchREV Endocrinol.* 2021;17(2):102–7.
28. Gallardo-Rincon H, Rios-Blancas MJ, Ortega-Montiel J, Montoya A, Martinez-Juarez LA, Lomelin-Gascon J, et al. MIDO GDM: an innovative artificial intelligence-based prediction model for the development of gestational diabetes in Mexican women. *Sci Rep.* 2023;13(1):6992.
29. Hu X, Hu X, Yu Y, Wang J. Prediction model for gestational diabetes mellitus using the XG Boost machine learning algorithm. *Front Endocrinol (Lausanne).* 2023;14:1105062.
30. Kokori E, Olatunji G, Aderinto N, Muogbo I, Ogieuhi IJ, Isarinade D, et al. The role of machine learning algorithms in detection of gestational diabetes; a narrative review of current evidence. *Clin Diabetes Endocrinol.* 2024;10(1):18.
31. Ye Y, Xiong Y, Zhou Q, Wu J, Li X, Xiao X. Comparison of Machine Learning Methods and Conventional Logistic Regressions for Predicting Gestational Diabetes Using Routine Clinical Data: A Retrospective Cohort Study. *J Diabetes Res.* 2020;2020:4168340.
32. Lundberg SM, LS-I. A Unified Approach to Interpreting Model Predictions. *Adv Neural Inf Process Syst.* 2017;30:4765–74.
33. Li J, Liu X, He S, Ren Y. Interpretable Machine Learning for Predicting Adverse Pregnancy Outcomes in Gestational Diabetes: Retrospective Cohort Study. *JMIR Med Inform.* 2025;13:e71539.
34. Collins GS, Moons KGM, Dhiman P, Riley RD, Beam AL, Van Calster B, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ.* 2024;385:e078378.

35. Sterne JA, White IR, Carlin JB, Spratt M, Royston P, Kenward MG, et al. Multiple imputation for missing data in epidemiological and clinical research: potential and pitfalls. *BMJ*. 2009;338:b2393.
36. Wolff RF, Moons KGM, Riley RD, Whiting PF, Westwood M, Collins GS, et al. PROBAST: A Tool to Assess the Risk of Bias and Applicability of Prediction Model Studies. *Ann Intern Med*. 2019;170(1):51–8.
37. Moons KGM, Wolff RF, Riley RD, Whiting PF, Westwood M, Collins GS, et al. PROBAST: A Tool to Assess Risk of Bias and Applicability of Prediction Model Studies: Explanation and Elaboration. *Ann Intern Med*. 2019;170(1):W1–W33.
38. Da Correggio KS, Santos LO, Muylaert Barroso FS, Galluzzo RN, Chaves TZL, Wangenheim AV, et al. AI-Driven Fetal Liver Echotexture Analysis: A New Frontier in Predicting Neonatal Insulin Imbalance. *J Ultrasound Med*. 2025.
39. Baumgartner CF, Kamnitsas K, Matthew J, Fletcher TP, Smith S, Koch LM, et al. SonoNet: Real-Time Detection and Localisation of Fetal Standard Scan Planes in Freehand Ultrasound. *IEEE Trans Med Imaging*. 2017;36(11):2204–15.
40. Arnaout R, Curran L, Zhao Y, Levine JC, Chinn E, Moon-Grady AJ. An ensemble of neural networks provides expert-level prenatal detection of complex congenital heart disease. *Nat Med*. 2021;27(5):882–91.
41. Weinert LS. International Association of Diabetes and Pregnancy Study Groups recommendations on the diagnosis and classification of hyperglycemia in pregnancy: comment to the International Association of Diabetes and Pregnancy Study Groups Consensus Panel. *Diabetes Care*. 2010;33(7):e97; author reply e98.
42. Frankevich NA, Tokareva AO, Yuriev SY, Chagovets VV, Kutsenko AA, Novoselova AV, et al. Amino Acid Profile Alterations in the Mother-Fetus System in Gestational Diabetes Mellitus and Macrosomia. *Int J Mol Sci*. 2025;26(17).
43. Gilboa I, Gabbai D, Attali E, Hiersch L, Lavie A, Yogev Y. Prediction model for intrapartum cesarean delivery among women with gestational diabetes mellitus. *Arch Gynecol Obstet*. 2025.
44. Watanabe M, Eguchi A, Sakurai K, Yamamoto M, Mori C, Japan Environment Children's Study G. Prediction of gestational diabetes mellitus using machine learning from birth cohort data of the Japan Environment and Children's Study. *Sci Rep*. 2023;13(1):17419.
45. Amann J, Blasimme A, Vayena E, Frey D, Madai VI, Precise Qc. Explainability for artificial intelligence in healthcare: a multidisciplinary perspective. *BMC Med Inform Decis Mak*. 2020;20(1):310.
46. Vasudevan L, Kibria MG, Kucirka LM, Shieh K, Wei M, Masoumi S, et al. Machine Learning Models to Predict Risk of Maternal Morbidity and Mortality From Electronic Medical Record Data: Scoping Review. *J Med Internet Res*. 2025;27:e68225.
47. Ku CW, Zheng RT, Tan HY, Lim JYQ, Chen LW, Cheung YB, et al. Early continuous glucose monitoring-derived glycemic patterns are associated with subsequent insulin resistance and gestational diabetes mellitus development during pregnancy. *Diabetol Metab Syndr*. 2024;16(1):271.
48. Andrade Júnior VL, França MS, Santos RAF, Hatanaka AR, Cruz JJ, Hamamoto TEK, et al. A new model based on artificial intelligence to screening preterm birth. *J Matern Fetal Neonatal Med*. 2023;36(2):2241100.
49. Belaghi RA. Prediction of preterm birth in multiparous women using logistic regression and machine learning approaches. *Sci Rep*. 2024;14(1):21967.
50. Bulez A, Hansu K, Çağan ES, Şahin AR, Dokumacı HÖ. Artificial Intelligence in Early Diagnosis of Preeclampsia. *Niger J Clin Pract*. 2024;27:383–8.
51. Gao C, Osmundson S, Velez Edwards DR, Jackson GP, Malin BA, Chen Y. Deep learning predicts extreme preterm birth from electronic health records. *J Biomed Inform*. 2019;100:103334.
52. Hackelöer M, Schmidt L, Verlohren S. New advances in prediction and surveillance of preeclampsia: role of machine learning approaches and remote monitoring. *Arch Gynecol Obstet*. 2023;308(6):1663–77.
53. Huang C, Long X, van der Ven M, et al. Predicting preterm birth using electronic medical records from multiple prenatal visits. *BMC Pregnancy Childbirth*. 2024;24:843.
54. Khan W, Zaki N, Ghenimi N, Ahmad A, Bian J, Masud MM, et al. Predicting preterm birth using explainable machine learning in a prospective cohort of nulliparous and multiparous pregnant women. *PLoS One*. 2023;18(12):e0293925.
55. Khalil A, Bellesia G, Norton ME, et al. The role of cell-free DNA biomarkers and patient data in the early prediction of preeclampsia: an artificial intelligence model. *Am J Obstet Gynecol*. 2024;231:554.e1–18.
56. Kong D, Tao Y, Xiao H, Xiao W, Wei W, Cai M. Predicting preterm birth using auto-ML frameworks: a large observational study using electronic inpatient discharge data. *Front Pediatr*. 2024;12:1330420.
57. Layton AT. Artificial Intelligence and Machine Learning in Preeclampsia. *Arterioscler Thromb Vasc Biol*. 2025;45(2):165–71.
58. Lee KS, Ahn KH. Application of Artificial Intelligence in Early Diagnosis of Spontaneous Preterm Labor and Birth. *Diagnostics (Basel)*. 2020;10(9):733.
59. Li S, Wang Z, Vieira LA, Zheutlin AB, Ru B, Schadt E, et al. Improving preeclampsia risk prediction by modeling pregnancy trajectories from routinely collected electronic medical record data. *npj Digit Med*. 2022;5(1):68.

60. Liu M, Yang X, Chen G, Ding Y, Shi M, Sun L, Huang Z, Liu J, Liu T, Yan R, et al. Development of a prediction model on preeclampsia using machine learning-based method: a retrospective cohort study in China. *Front Physiol.* 2022;13:896969.
61. Marín I, Pavaloioiu B, Marian C-V, Racovita V, Goga N. Early detection of preeclampsia based on a machine learning approach. *E-Health Bioeng Conf 2019*; 2019:1–4.
62. O’Gorman N, Wright D, Syngelaki A, Akolekar R, Wright A, Poon LC, et al. Competing risks model in screening for preeclampsia by maternal factors and biomarkers at 11–13 weeks gestation. *Am J Obstet Gynecol.* 2016;214(1):103.e1-103.e12.
63. Rolnik DL, Wright D, Poon LC, O’Gorman N, Syngelaki A, de Paco M C, et al. Aspirin versus placebo in pregnancies at high risk for preterm preeclampsia. *N Engl J Med.* 2017;377(7):613–22.
64. Schmidt LJ, Rieger O, Neznansky M, Hackelöer M, Dröge LA, Henrich W, et al. A machine-learning-based algorithm improves prediction of preeclampsia-associated adverse outcomes. *Am J Obstet Gynecol.* 2022;227(1):77.e1-77.e30.
65. Seong D, Espinosa C, Aghaeepour N. Computational Approaches for Predicting Preterm Birth and Newborn Outcomes. *Clin Perinatol.* 2024;51(2):461-73.
66. Shahiri SH, et al. Machine Learning Approach for Preterm Birth Prediction Using Health Records: systematic review. *JMIR Med Inform.* 2022;10(4):e33875.
67. Sun H, et al. Machine Learning-Based Prediction Model of Preterm Birth Using Electronic Health Record. *J Healthc Eng.* 2022;2022:9635526.
68. Torchin H, Ancel PY. Epidemiology and risk factors of preterm birth. *J Gynecol Obstet Biol Reprod.* 2016;45:1213–20.
69. Van den Heuvel JFM, Lely AT, Huisman JJ, Trappenburg JCA, Franx A, Bekker MN. SAFE@HOME: digital health platform facilitating a new care path for women at increased risk of preeclampsia – a case-control study. *Pregnancy Hypertens.* 2020;22:30–6.
70. Wright D, Wright A, Nicolaides KH. The competing risk approach for prediction of preeclampsia. *Am J Obstet Gynecol.* 2020;223(1):12-23.e7.
71. Zhang F, Tong L, Shi C, Zuo R, Wang L, Wang Y. Deep Learning in Predicting Preterm Birth: A Comparative Study of Machine Learning Algorithms. *Matern Fetal Med.* 2024;6(3):141–6.
72. Graham EM, Ruis KA, Hartman AL, Northington FJ, Burd I. A systematic review of the role of intrapartum hypoxia-ischemia in the causation of neonatal encephalopathy. *Am J Obstet Gynecol.* 2020;199(6):587–95.
73. Warrick PA, Hamilton EF, Precup D, Kearney RE. Classification of normal and hypoxic fetuses from systems modeling of intrapartum cardiotocography. *IEEE Trans Biomed Eng.* 2010;57(4):771–9.
74. Gale C, et al. Neonatal brain injuries in England: Population-based incidence derived from routinely recorded clinical data. *Arch Dis Child Fetal Neonatal Ed.* 2018;103(4):F301–F306.
75. NHS Resolution. Annual Report and Accounts 2017/18 [Internet]. 2018 [citado 2019 Jul 5]. Disponible en: <https://resolution.nhs.uk/wp-content/uploads/2018/08/NHS-Resolution-Annual-Report-2017-2018.pdf>
76. Beksac MS, Tanacan A, Bacak HO, Leblebicioglu K. Computerized prediction system for the route of delivery (vaginal birth versus cesarean section). *J Perinat Med.* 2018 Oct 25;46(8):881-4.
77. De Ramón Fernández A, Ruiz Fernández D, Prieto Sánchez MT. Prediction of the mode of delivery using artificial intelligence algorithms. *Comput Methods Programs Biomed.* 2022;219:106740.
78. Owusu-Adjei M, Ben Hayfron-Acquah J, Frimpong T, Gaddafi AS. An AI-based approach to predict delivery outcome based on measurable factors of pregnant mothers. *PLOS Digit Health.* 2025 Feb 5;4(2):e0000543.
79. Guedalia J, Lipschuetz M, Cohen SM, Sompolinsky Y, Walfisch A, Sheiner E, et al. Transporting an Artificial Intelligence Model to Predict Emergency Cesarean Delivery: Overcoming Challenges Posed by Interfacility Variation. *J Med Internet Res.* 2021;23(12):e28120.
80. Hu T, Du S, Li X, et al. Establishment of a model for predicting the outcome of induced labor in full-term pregnancy based on machine learning algorithm. *Sci Rep.* 2022;12:19063.
81. Lipschuetz M, Guedalia J, Rottenstreich A, et al. Prediction of vaginal birth after cesarean deliveries using machine learning. *Am J Obstet Gynecol.* 2020;222:613.e1-613.e12.
82. Macones GA, Hausman N, Edelstein R, Stamilio DM, Marder SJ. Predicting outcomes of trials of labor in women attempting vaginal birth after cesarean delivery: a comparison of multivariate methods with neural networks. *Am J Obstet Gynecol.* 2001;184:409-13.
83. Meyer R, Hendin N, Zamir M, Mor N, Levin G, Sivan E, et al. Implementation of machine learning models for the prediction of vaginal birth after cesarean delivery. *J Matern Fetal Neonatal Med.* 2020;35(19):3677–83.
84. Landon MB, Hauth JC, Leveno KJ, et al. Maternal and perinatal outcomes associated with a trial of labor after prior cesarean delivery. *N Engl J Med.* 2004;351:2581-9.

85. Grobman WA, Sandoval G, Rice MM, Bailit JL, Chauhan SP, Costantine MM, et al. Prediction of vaginal birth after cesarean in term gestations: A calculator without race and ethnicity. *Am J Obstet Gynecol*. 2021;225:664.e1-664.e7.
86. Grobman WA, Sandoval GJ, Rice MM, Chauhan SP, Clifton RG, Costantine MM, Gibson KS, Metz TD, et al. Prediction of vaginal birth after cesarean using information at admission for delivery: A calculator without race and ethnicity. *Am J Obstet Gynecol*. [Publicado en línea el 13 de julio de 2023].
87. Yang CC, Wang CF, Lin WM, Chen SW, Hu HW. Evaluating the performance of an AI-powered VBAC prediction system within a decision-aid birth choice platform for shared decision-making. *Digital Health*. 2024;10.
88. Chen H, Cao B, Yang J, Ren H, Xia X, Zhang X, et al. Construction and effect evaluation of prediction model for red blood cell transfusion requirement in cesarean section based on artificial intelligence. *BMC Med Inform Decis Mak*. 2023 Oct 12;23(1):213.
89. Bizzego A, Gabrielli L, Esposito G. Contributions of Artificial Intelligence to Obstetrics: A Review of Current State, Challenges, and Future Directions. *Healthcare (Basel)*. 2023;11(6):881.
90. Sherer DM, Miodovnik M, Bradley KS, Langer O. Intrapartum fetal head position II: comparison between transvaginal digital examination and transabdominal ultrasound during the second stage of labor. *Ultrasound Obstet Gynecol*. 2002;19(3):264-8.
91. Akmal S, Tsoi E, Howard R, Osei E, Nicolaides KH. Investigation of occiput posterior delivery by intrapartum sonography. *Ultrasound Obstet Gynecol*. 2004;24(4):425-8.
92. Malvasi A, Stark M, Ghi T, et al. Intrapartum sonography for fetal head asynclitism and transverse position: sonographic signs and comparison of diagnostic performance between transvaginal and digital examination. *J Matern Fetal Neonatal Med*. 2012;25(5):508-12.
93. World Health Organization. WHO recommendations: intrapartum care for a positive childbirth experience. Geneva: WHO; 2018.
94. National Institute for Health and Care Excellence. Intrapartum care for healthy women and babies. NICE Clinical Guideline CG190. London: NICE; 2014.
95. Royal College of Midwives. Position statement: Vaginal examination in labour. London: RCM; 2012.
96. Ramirez Zegarra R, Conversano F, Dall'Asta A, et al. A deep learning approach to identify the fetal head position using transperineal ultrasound during labor. *Eur J Obstet Gynecol Reprod Biol*. 2024;301:147-53.
97. Malvasi A, Malgieri LE, Stark M, Tinelli A. Dystocia, delivery, and artificial intelligence in labor management: perspectives and future directions. *J Clin Med*. 2024;13(21):6410.
98. Krsman A, Grujić Z, Čapko D, et al. Ultrasound assessment of cervical status compared to the Bishop score – predicting the success of labor induction using a machine learning-based model. *Eur Rev Med Pharmacol Sci*. 2023;27:6332-42.
99. Leduc D, Biringer A, Lee L, Dy J; Clinical Practice Obstetrics Committee. Induction of labour. *J Obstet Gynaecol Can*. 2013;35(9):840-57.
100. Grobman WA, Rice MM, Reddy UM, et al; Eunice Kennedy Shriver National Institute of Child Health and Human Development Maternal-Fetal Medicine Units Network. Labor induction versus expectant management in low-risk nulliparous women. *N Engl J Med*. 2018;379(6):513-23.
101. Hong J, Atkinson J, Mitchell AR, et al. Comparison of maternal labor-related complications and neonatal outcomes following elective induction of labor at 39 weeks of gestation vs expectant management: a systematic review and meta-analysis. *JAMA Netw Open*. 2023;6(5):e2313162.
102. Ferreira I, Simões J, Pereira B, Correia J, Areia AL. Ensemble learning for fetal ultrasound and maternal-fetal data to predict mode of delivery after labor induction. *Sci Rep*. 2024;14:15275.
103. Del Campo Real A. Aportación de la ecografía en la predicción del resultado de la inducción de parto [tesis doctoral]. Universidad del País Vasco (UPV/EHU); 2021.
104. Michalitsi K, Metallinou D, Diamanti A, et al. Artificial intelligence in predicting the mode of delivery: a systematic review. *Cureus*. 2024;16(9):e69115.

5. IA EN GINECOLOGÍA

5. IA en ginecología

5.1 Diagnóstico precoz de cáncer ginecológico

Manuel Albi

5.1.1. IA en el diagnóstico precoz del carcinoma de cérvix

5.1.1.1. Introducción


El cáncer de cérvix es una enfermedad con una alta morbilidad y mortalidad, registrando 6000 casos diagnosticados y 3000 muertes anuales. La mayoría de los casos se diagnostican en países subdesarrollados o en vías de desarrollo. La Organización Mundial de la Salud (OMS) se ha propuesto la erradicación del cáncer de cérvix, basándose en tres pilares fundamentales: la vacunación, el cribado (screening) y el tratamiento de los casos diagnosticados [1].

El diagnóstico de cáncer de cérvix tradicionalmente incluye la realización e interpretación de la exploración física, citología, colposcopia y biopsias. Este proceso implica la necesidad de personal altamente capacitado, así como un considerable tiempo y costes económicos elevados.

La inteligencia artificial (IA), desde su conceptualización como "máquina pensante" en 1956, ha experimentado un desarrollo vertiginoso que ha transformado múltiples disciplinas, incluida la medicina. Una de las áreas donde su impacto ha sido especialmente prometedor es en el diagnóstico del cáncer de cérvix. Esta patología, prevenible mediante cribado y detección precoz de lesiones premalignas, puede beneficiarse significativamente de las capacidades analíticas, predictivas y de automatización que ofrece la IA.

5.1.1.2. Conceptos Básicos

- **Inteligencia Artificial (IA):** Incluye cualquier técnica que permite a las máquinas utilizar algoritmos para realizar tareas propias de la inteligencia humana, tales como razonar, aprender, planificar, percibir o procesar el lenguaje.
- **Machine Learning (Aprendizaje Automático):** Subcampo de la IA que permite a los algoritmos aprender automáticamente a partir de datos, mejorando su desempeño con la experiencia sin requerir una nueva programación directa.
- **Deep Learning (Aprendizaje Profundo):** Subcategoría del aprendizaje automático que emplea redes neuronales profundas para extraer y procesar grandes volúmenes de datos no estructurados.



De Jiang I. Seminars in Cancer Biology 2023.

5.1.1.3. Aplicaciones de la IA en el Diagnóstico del Cáncer de Cérvix

1. Diagnóstico Citológico

El cribado mediante citología ha sido históricamente específico, pero con baja sensibilidad y reproducibilidad, lo que resulta en una exactitud diagnóstica limitada. A pesar de que requiere personal adecuadamente entrenado en la interpretación de imágenes citológicas, los errores de lectura en la citología convencional suponen hasta un 10 % de subestimación de las lesiones. La alta tasa de falsos negativos se ha mantenido incluso con la citología en medio líquido, aunque su sensibilidad es mayor que la de la citología convencional. Esta falta de precisión incrementa el riesgo de diagnósticos erróneos u omitidos, retrasando el tratamiento y empeorando el pronóstico de la enfermedad.

Además, el cribado tradicional depende de citopatólogos experimentados. Cada frotis contiene entre 20.000 y 50.000 células para ser adecuado, lo que hace que el proceso de evaluación sea lento y altamente dependiente de la experiencia y habilidades individuales del profesional. En regiones con recursos limitados, especialmente en países en desarrollo, existe una escasez de personal capacitado y equipos para realizar un cribado citológico cervical eficaz. Esta desigualdad en recursos provoca una baja cobertura de cribado en entornos con medios técnicos y humanos limitados [1].


Un sistema típico de análisis automático de frotis comprende las siguientes cinco etapas: adquisición de imágenes, preprocesamiento, segmentación, extracción de características y clasificación. La tecnología de inteligencia artificial se aplica en las etapas de segmentación, clasificación y extracción de áreas de interés [2].

Los sistemas de lectura totalmente automatizados constan de un escáner central que analiza las láminas citológicas y una o más estaciones de revisión. El *software* identifica los campos de interés para que el citólogo solo revise esas zonas señaladas por la estación. Algunos sistemas, además, clasifican las láminas según el riesgo de contener lesiones relevantes en grupos de "con" o "sin revisión adicional". Todos estos sistemas pueden aplicarse a citología en base líquida, aunque solo algunos son compatibles también con frotis convencionales [3].

La IA asiste a los citopatólogos en el análisis de frotis, aliviando su carga de trabajo mediante el procesamiento eficiente de grandes volúmenes de datos y permitiéndoles enfocarse en los casos más complejos. Además, la IA contribuye a reducir las disparidades regionales, proporcionando servicios de cribado de alta calidad mediante diagnóstico remoto y análisis inteligente, acortando así la brecha en la atención sanitaria entre áreas con diferentes recursos económicos [1].

Usando algoritmos de aprendizaje automático y redes neuronales profundas, se ha logrado reducir los falsos positivos y negativos, aumentar la precisión diagnóstica en un 99 %, alcanzar una sensibilidad del 100 % y mejorar la eficiencia del cribado hasta en cuatro veces [4]. La lectura de citologías mediante IA ha demostrado una discriminación del 80-100 % entre citologías normales y de alto grado, en un tiempo 380 veces menor por muestra analizada [5].

Un metaanálisis sobre interpretación citológica mediante IA, publicado recientemente, ha mostrado sensibilidad y especificidad diagnósticas en torno al 90 % tanto para citología convencional como para citología en medio líquido [1].



Wu T. Cancer Biol Med 2024.

2. Modelos Basados en Aprendizaje Profundo

En 2020 se publicó en China un estudio sobre la interpretación de estudios citológicos mediante IA, basado en la introducción de casi 200.000 imágenes de citologías en un sistema de *Deep Learning*. Se estudiaron 2100 muestras y se compararon con los resultados de la observación de esas mismas muestras por patólogos y citólogos. Las tasas de detección de lesiones de alto grado fueron superiores al 90 %, con sensibilidad y especificidad similares a las obtenidas por patólogos y mejores que las obtenidas por citólogos [6].

Otro modelo reciente de red convolucional guiada por mecanismos de atención simuló la forma de lectura de los patólogos, enfocándose en ciertas características y suprimiendo otras, y alcanzó un rendimiento equivalente al de patólogos con 10 años de experiencia [7].

Además, la IA aplicada a láminas histológicas teñidas con hematoxilina y eosina ha demostrado la capacidad de predecir biomarcadores, detectar variantes genéticas comunes e inferir subtipos tumorales y perfiles

moleculares en diversos tipos de cáncer. Al añadir a este modelo una tinción p16/ki67, se redujo un tercio el número de pacientes remitidas a colposcopia respecto a la citología cervical con tinción manual [8].

3. Implementación en Poblaciones Reales

La reducción de costes de estas técnicas permite su implementación en cribados poblacionales. Además, disminuir la necesidad de personal especializado aumenta la accesibilidad del sistema. En China se han realizado varios programas de cribado apoyados por IA. En 2023, un programa logró evaluar a más de 1.5 millones de mujeres con un 97 % de muestras válidas y un coste de apenas 6.31 dólares por mujer [9]. Otro estudio logró cribar a 1.7 millones de mujeres rurales en un año, con una participación del 99 % [10].

4. Estratificación de Riesgo y Detección de HPV

La integración del VPH en el genoma celular es un paso clave en la transformación maligna. Un modelo basado en *Deep Learning* ha sido validado para señalar los puntos de integración del VPH en el genoma de la célula cervical [11].

Otros algoritmos analizan el estado de integración viral, mutaciones somáticas y variaciones de número de copias para estratificar el riesgo de lesiones CIN 2+ [2]. Estos modelos han demostrado una gran precisión en la predicción de progresión en pacientes VPH positivas [12]. A diferencia de los algoritmos habitualmente utilizados donde se realiza la introducción manual de los datos, estos utilizan *Deep Learning* y *Machine Learning* en la extracción de datos no siempre estructurados de las historias clínicas y los combinan con imágenes para aportar un resultado con alto valor predictivo.

5. Videocolposcopia

La colposcopia requiere un elevado tiempo de realización y una larga curva de aprendizaje para los profesionales. La escasez de colposcopistas, especialmente en países en vías de desarrollo, conduce a una alta discrepancia entre la imagen colposcópica y el resultado histológico, alta subjetividad, baja concordancia intra e interobservador y altas tasas de biopsias innecesarias. Los criterios y el control de calidad rigurosos son difíciles de mantener de forma constante, especialmente para los colposcopistas con habilidades diagnósticas limitadas. Los programas estructurados de formación en colposcopia son esenciales para mejorar la capacidad diagnóstica de los colposcopistas. Sin embargo, la implementación práctica de estos programas para mejorar el rendimiento diagnóstico en un corto período de tiempo resulta difícil, especialmente en países con rentas medias-bajas.

Numerosos estudios han demostrado que la inteligencia artificial (IA) tiene el potencial de mitigar estos desafíos [1].

La IA ha sido empleada en colposcopia para segmentar lesiones acetoblancas y analizar su relación con la zona de transformación [12].

Estos avances mejoran la precisión diagnóstica y pueden apoyar o incluso reemplazar la colposcopia convencional, especialmente en contextos de bajos recursos. Además, se ha mostrado una herramienta eficaz en el asesoramiento de colposcopistas no expertos [5].

Varios estudios han mostrado los resultados del uso de la IA en la gradación de las imágenes colposcópicas y la guía del área de biopsia. Estos métodos han conseguido una exactitud en el diagnóstico de cáncer invasivo, CIN y tejido normal similares a las de un colposcopista experto [8].

En 2023 se publicó un estudio que evaluó la precisión y viabilidad de la IA para el análisis de las imágenes colposcópicas. La IA evaluó más de 6000 exámenes colposcópicos de mujeres con imágenes correspondientes a control normal, lesiones intraepiteliales de bajo grado (LSIL) y alto grado (HSIL). Para cada paciente se recopilaron tres tipos de imágenes: original, prueba de Schiller y tinción con ácido acético. Se desarrolló un modelo con una red principal para la extracción de características y una unidad para fusionar la información de las tres modalidades de imagen. La capacidad diagnóstica para diferenciar HSIL de LSIL y normalidad fue superior al 91 % [13].

En 2024, un estudio argentino mostró un 15 % de mejoría en la precisión diagnóstica del estudio colposcópico apoyado en IA respecto al convencional [14].

Sistemas como CAIADS (Sistema de Diagnóstico Auxiliar por Inteligencia Artificial para Colposcopia), diseñado para mejorar la interpretación de colposcopias y guiar la toma de biopsias, tuvo una mayor concordancia con los hallazgos histológicos que los colposcopistas humanos (82.2 % frente a 65.9 %), con una mejoría de la sensibilidad en el diagnóstico de lesiones CIN 2+ [15]. Otro *software*, CerviCARE AI, alcanzó una sensibilidad del 98 % y una especificidad del 95.5 % para HSIL [16].

Un reciente metaanálisis también muestra una precisión diagnóstica en exámenes colposcópicos mayor para la IA en comparación con los colposcopistas humanos (OR 1.75); tanto en entornos de países subdesarrollados como desarrollados [1].

La automatización del proceso colposcópico podría establecer un nuevo modelo de cribado del cáncer de cuello uterino. El uso de la IA tiene la capacidad de mejorar la accesibilidad a los recursos, reducir la incidencia de falsos negativos y falsos positivos, y mejorar la precisión de los diagnósticos basados en colposcopia y biopsias cervicales.

6. Diagnóstico Histológico

El diagnóstico definitivo del cáncer de cérvix se obtiene mediante el estudio histológico de biopsias cervicales. Estas biopsias, realizadas habitualmente mediante guía colposcópica, requieren procesamiento y tinción para ser evaluadas por patólogos.


La precisión diagnóstica de la biopsia cervical para detectar neoplasia intraepitelial cervical (CIN) es relativamente baja, oscilando entre el 30 % y el 70 %, especialmente en los países con recursos limitados [1].

La tomografía de coherencia óptica (OCT) es una técnica emergente de imagen biomédica que utiliza luz para obtener imágenes seccionales del tejido biológico con resolución micrométrica, capaz de captar imágenes celulares de hasta 2 mm de profundidad en el tejido. Este método ha sido considerado una “biopsia óptica”.

La microscopía de coherencia óptica (OCM) combina la tecnología anterior con la microscopía confocal. La OCM de ultra-alta resolución ha demostrado recientemente su capacidad para revelar detalles del tejido cervical *ex vivo* similares a los de la histología, a nivel celular. Sin embargo, las imágenes de OCM son ajenas para ginecólogos y patólogos debido al uso limitado de esta tecnología en la práctica clínica. Los clínicos necesitarían una formación rigurosa, que probablemente incluiría la visualización de miles de imágenes OCM con distintas patologías, para familiarizarse y reconocer características diagnósticas. Esta formación puede ser muy exigente en cuanto a tiempo requerido y no siempre viable dado el ritmo de trabajo clínico. Además, como las imágenes OCM difieren de las de colposcopia tradicional y las de la histología, esto puede dificultar su aceptación y adopción en la práctica clínica para el cribado y diagnóstico de enfermedades cervicales [17].

Las tecnologías de aprendizaje profundo, especialmente las redes neuronales profundas, han mostrado avances notables en la valoración y análisis de imágenes médicas gracias a su capacidad para aprender características a partir de grandes volúmenes de imágenes y vídeos. En particular, las redes neuronales convolucionales (CNNs), una clase de redes de aprendizaje profundo, se han utilizado ampliamente en clasificación de imágenes. Estudios recientes indican que las CNNs profundas pueden alcanzar una precisión al menos comparable a la de expertos humanos en tareas como la detección de patologías basadas en imágenes.

La IA (red neuronal convolucional) ha sido aplicada a imágenes de microscopía de coherencia óptica (OCM) en 3D para diagnosticar lesiones benignas (normal y ectopia), de bajo grado y de alto grado/cáncer, logrando una alta precisión, sensibilidad y especificidad; especialmente en clasificación binaria como bajo y alto grado (S 87 % y E 93 %). La herramienta diagnóstica utiliza las imágenes OCM, el resultado del test de detección de VPH y la edad de la paciente para emitir un diagnóstico [17].



Ma Y. IEEE Trans Biomed Eng. 2019.

Con la asistencia de estas herramientas diagnósticas de inteligencia artificial, las imágenes OCM de alta resolución son una tecnología prometedora para el diagnóstico no invasivo y en tiempo real de las lesiones cervicales [17].

7. Diagnóstico por Imagen


Se han implementado modelos basados en inteligencia artificial para mejorar la precisión diagnóstica y estratificar subtipos tumorales directamente a partir de imágenes histopatológicas y radiológicas. Las imágenes de RM/TC analizadas mediante inteligencia artificial se han utilizado para evaluar características clinicopatológicas, incluyendo el estado de los ganglios linfáticos, la invasión parametrial, los subtipos histológicos, el grado tumoral y el estadio FIGO del carcinoma de cérvix [8].

En el subgrupo de pacientes con recurrencia local y metástasis a distancia, se han probado con éxito modelos basados en un algoritmo de inteligencia artificial que evalúa de forma segmentaria los hallazgos de la RM (tamaño lesional, restricción a la difusión). Este algoritmo clasificó adecuadamente a los pacientes con respuesta completa, respuesta incompleta y progresión de la enfermedad [12].

8. Consejo Preoperatorio y Planificación del Tratamiento

Algunos modelos de *Machine Learning* han sido utilizados para predecir la respuesta a quimioterapia y la morbilidad asociada en pacientes con cáncer cervical como herramienta de apoyo en la selección de pacientes y regímenes de tratamiento [8].

La planificación del tratamiento de braquiterapia mediante *Deep Learning* permite la automatización del proceso, disminuyendo el tiempo dedicado a ello por los profesionales y mejorando la exactitud (eliminando modificaciones por el llenado vesical o el peristaltismo intestinal) y la tolerabilidad de la misma [18].



De Jiang I. Seminars in Cancer Biology 2023.

5.1.1.4. Conclusiones

La incorporación de la inteligencia artificial en el diagnóstico del cáncer de cérvix ha revolucionado el abordaje clínico de esta patología. Desde el cribado inicial mediante citología hasta la planificación personalizada del tratamiento, los algoritmos de IA han demostrado mejoras significativas en precisión, eficiencia y cobertura poblacional. La capacidad de estos sistemas para procesar grandes volúmenes de datos, detectar patrones complejos y ofrecer diagnósticos automatizados, ofrece una valiosa herramienta para reducir la carga global de esta enfermedad, especialmente en entornos con recursos limitados.

El ámbito más estudiado ha sido la exactitud diagnóstica de los diagnósticos citológicos y colposcópicos. La aplicación de la IA ha mostrado disminuir el tiempo diagnóstico, los costes y la limitación de la falta de personal entrenado, especialmente en ámbitos con bajos recursos. Sin embargo, no existen aún guías clínicas establecidas para la aplicación del cribado citológico cervical y el diagnóstico colposcópico asistidos por inteligencia artificial.

Se espera que, con el desarrollo continuo de modelos más robustos y su integración en sistemas de salud, la IA contribuya decisivamente a mejorar la detección precoz, la estratificación del riesgo y los resultados clínicos en el cáncer de cuello uterino.

Los resultados de los estudios realizados hasta la fecha muestran el alto valor potencial de la aplicación de la IA en la prevención y diagnóstico precoz del cáncer de cérvix.

Sin embargo, aún existen algunas barreras para su aplicación de forma generalizada. Son necesarios más estudios prospectivos y multicéntricos con grandes muestras homogéneas que permitan extrapolar los resultados. Los algoritmos de IA requieren millones de observaciones; por ello, la investigación debe enfocarse en la estandarización, autenticidad y precisión en la recopilación de datos. Además, dada la diversidad de los algoritmos utilizados en los diferentes estudios, es importante mejorar la compatibilidad entre los diferentes *softwares* de IA.

En el caso del cáncer de cérvix, existen diferencias muy importantes en las prevalencias de patología en diferentes áreas geográficas. Por ello, es importante contextualizar también los resultados de la IA en áreas de baja prevalencia, donde la rentabilidad de todas las pruebas diagnósticas puede estar disminuida.

Aunque aún existen desafíos relacionados con la estandarización, validación clínica, accesibilidad y aceptación por parte del personal médico, los resultados actuales apoyan la expansión del uso de IA en oncología ginecológica.

5.1.2. IA en el diagnóstico precoz del carcinoma de ovario

5.1.2.1. Introducción


El cáncer de ovario es uno de los tumores ginecológicos más letales a nivel mundial, y es la principal causa de muerte por cáncer ginecológico en países desarrollados. Cada año, se diagnostican más de 300.000 nuevos casos a nivel global, con una mortalidad que supera el 60%, fundamentalmente debido al diagnóstico tardío. A diferencia de otros tumores ginecológicos como el de cérvix o el de endometrio, el cáncer de ovario suele desarrollarse sin presentar una sintomatología específica en sus estadios iniciales, es por eso por lo que se le conoce como el “asesino silencioso”, esto conlleva que aproximadamente el 70-75% de los casos sean detectados en estadios avanzados (FIGO III o IV). La supervivencia a 5 años en estos estadios avanzados es del 25–30%, mientras que en los estadios iniciales (I–II), esta supervivencia puede alcanzar cifras cercanas al 90%. Esta diferencia tan marcada en el pronóstico según el estadio al momento del diagnóstico ha motivado múltiples esfuerzos por establecer métodos efectivos de detección precoz. Desgraciadamente, en la actualidad no existe un método de diagnóstico precoz que haya demostrado utilidad en el cáncer de ovario. El uso combinado del marcador tumoral Ca-125 combinado con la ecografía ginecológica transvaginal, que ha sido ampliamente investigado, presenta limitaciones importantes; esto es debido a varias razones como que el Ca-125 puede estar elevado en condiciones benignas (peritonitis, pericarditis, pleuritis, fumadoras...etc.), y

no siempre se encuentra alterado en estadios iniciales de la enfermedad, mientras que la ecografía depende en gran medida de la experiencia del ecografista, y puede no detectar lesiones pequeñas o no típicas. En este contexto, la incorporación de la IA en este campo, y en general en medicina, ha abierto nuevas posibilidades. La IA permite procesar un número muy elevado de volúmenes de datos clínicos, moleculares, así como pruebas de imagen, identificar patrones sutiles y generar modelos predictivos que podrían superar la capacidad humana “tradicional”. Su aplicación al diagnóstico precoz del cáncer de ovario ha comenzado a demostrar un impacto significativo, al combinar precisión, reproducibilidad y capacidad de personalización diagnóstica. Entre las aplicaciones emergentes destacan la interpretación automatizada de imágenes ecográficas mediante algoritmos de “deep learning”, el análisis de biomarcadores tumorales en sangre con modelos de “machine learning”, y la integración de datos multi-ómicos (genéticos, epigenéticos, proteómicos) en redes neuronales avanzadas para predecir la presencia de enfermedad incluso antes de la aparición de signos clínicos o hallazgos radiológicos. De esta forma, la IA es probable que se presente como un elemento transformador en el abordaje del cáncer de ovario, con el potencial de reducir su mortalidad mediante la posible detección más temprana, precisa y accesible. En el presente capítulo trataremos de revisar los principales avances tecnológicos y científicos en esta área, analizando tanto las aplicaciones actuales y futuras de la IA en el diagnóstico precoz de esta patología.

5.1.2.2. Biopsia líquida y multiómica con IA

La biopsia líquida es una técnica de análisis molecular no invasiva que permite detectar biomarcadores tumorales en fluidos corporales, principalmente en sangre periférica. Esta técnica representa una alternativa de interés frente a las biopsias histopatológicas que se utilizan a día de hoy, ya que posibilita la monitorización dinámica del tumor, la detección precoz de recurrencias y, en algunos casos, la identificación precoz del cáncer antes de la aparición de signos clínicos específicos. Entre los principales componentes evaluados en la biopsia líquida se encuentran el ADN libre circulante (cfDNA, del inglés cell-free DNA) y los microARN (miRNA). El cfDNA es un fragmento de ADN liberado en el torrente sanguíneo por células tumorales a través de diferentes mecanismos como la apoptosis o la necrosis. Su análisis permite identificar mutaciones somáticas, alteraciones epigenéticas (como la metilación del ADN), y patrones de fragmentación característicos del cáncer. Por otra parte, los miRNA son pequeñas secuencias de ARN no codificante que regulan la expresión génica y que muestran perfiles de expresión alterados en múltiples tipos de cáncer, incluyendo el cáncer de ovario. La integración de estos biomarcadores en modelos de inteligencia artificial ha demostrado ser eficaz. En concreto, algoritmos entrenados con patrones de metilación del cfDNA han llegado a presentar sensibilidad > 90% para la detección de cáncer de ovario en estadios iniciales (I - II). Asimismo, el análisis conjunto de datos de fragmentómica (longitud y distribución del cfDNA) y proteómica (marcadores plasmáticos como Ca 125, HE4, o proteínas relacionadas con la inflamación) en enfoques multi-ómicos, ha permitido una mejora significativa en cuanto a la especificidad del diagnóstico. Los modelos multi-ómicos integrados emplean técnicas avanzadas de IA para combinar múltiples secciones de información biológica (genómica, transcriptómica, epigenómica, proteómica y metabolómica) con el fin de realizar perfiles tumorales precisos y personalizados. Estas estrategias no sólo aumentan la precisión diagnóstica, sino que también ofrecen una vía para el estudio y la investigación de nuevas dianas terapéuticas, así como biomarcadores pronósticos. A pesar de su potencial, estas tecnologías aún enfrentan limitaciones importantes, como la necesidad de estandarización de protocolos de análisis, las validaciones externas y la accesibilidad económica para su uso en clínica diaria.

Figura 1. Comparación de sensibilidad y especificidad de métodos IA aplicados al diagnóstico precoz del cáncer de ovario. Leyenda: Comparación de la sensibilidad y especificidad de distintos enfoques de IA en el diagnóstico precoz del cáncer de ovario. TVUS = ultrasonido transvaginal; cfDNA = ADN libre circulante; DL = deep learning; ML = machine learning.



5.1.2.3. Técnicas de imagen asistida por inteligencia artificial

1. Ecografía transvaginal (TVUS)

Un metaanálisis reciente que incluyó 14 estudios y más de 15.000 imágenes ecográficas analizadas mediante diferentes modelos de inteligencia artificial demostró que la sensibilidad media alcanzada fue del 81%, mientras que la especificidad media fue del 92%. Estos resultados reflejan un rendimiento comparable, e incluso superior al de ecografistas expertos, especialmente en contextos donde el acceso a profesionales con alta experiencia es limitado. Además, existe un ensayo clínico multicéntrico evaluó la eficacia de modelos basados en arquitectura de “Transformers” para interpretar ecografías de más de 3.600 pacientes. Los Transformers son modelos de “Deep learning” introducidos en 2017 por Vaswani et al. en el artículo “Attention is All You Need”. Se basan en un mecanismo llamado atención, que permite al modelo enfocarse dinámicamente en las partes más relevantes de los datos de entrada. Esto los hace especialmente potentes para tareas donde la secuencia o la relación entre elementos es importante. En este estudio, estos modelos no sólo mantuvieron elevados niveles de precisión diagnóstica, sino que además redujeron las derivaciones innecesarias a cirugía en un 63%. Los transformers son un tipo avanzado de arquitectura de redes neuronales profundas originalmente diseñados para procesamiento del lenguaje natural, pero cuya estructura de autoatención les permite captar relaciones contextuales complejas en datos secuenciales. Su aplicación a imagen médica ha resultado prometedora, ya que pueden analizar no solo características estáticas, sino también patrones espaciales y temporales complejos en series de imágenes, lo que los hace especialmente útiles en el análisis dinámico de estudios ecográficos.

2. Segmentación y clasificación automatizadas

La segmentación y clasificación automatizada de imágenes médicas mediante inteligencia artificial constituye una de las aplicaciones más desarrolladas en el campo de la imagen computacional. En el

contexto del cáncer de ovario, esta tecnología tiene un valor fundamental al permitir la detección precisa de lesiones ováricas, la delimitación de estructuras anatómicas relevantes y la clasificación morfológica de masas anexiales sin necesidad de intervención humana directa. La segmentación automática consiste en delimitar regiones específicas de una imagen, por ejemplo, una zona tumoral en una ecografía ginecológica. Modelos como U-Net y variantes más recientes como V-Net, Attention U-Net o nnU-Net han sido entrenados con bases de datos de imágenes ecográficas, consiguiendo resultados similares a los obtenidos por ecografistas expertos. El coeficiente de Dice ha sido la forma de medir los resultados de estos modelos en múltiples estudios, superando el 90% de concordancia entre el área segmentada por el algoritmo y la realizada por radiólogos. Una de las principales ventajas de la segmentación automatizada es su capacidad para reproducir resultados de forma constante, eliminando la variabilidad inter e intraobservador, especialmente relevante en contexto clínico donde los ecografistas tienen diferentes niveles de experiencia. Además, al permitir una cuantificación objetiva del tamaño y características morfológicas de la lesión (contenido sólido, papilas, septos, vascularización mediante Doppler), se incrementa la capacidad diagnóstica de la imagen. Una vez segmentada la imagen, los modelos de clasificación aplican algoritmos de aprendizaje profundo (como CNNs: Convolutional Neural Networks) para predecir la naturaleza benigna o maligna de la masa ovárica. Estos modelos pueden ser entrenados con etiquetas clínicas (con confirmación histológica), lo que les permite aprender a identificar patrones sutiles invisibles para el ojo humano. Algunos estudios multicéntricos han demostrado que estas redes neuronales alcanzan áreas bajo la curva (AUC) superiores a 0,93, y pueden integrarse en flujos de trabajo clínico con mínima necesidad de intervención. Además, la combinación de algoritmos de segmentación y clasificación puede integrarse en sistemas CAD (Computer-Aided Diagnosis), que actúan como asistentes en tiempo real durante la adquisición de la imagen ecográfica, ofreciendo una segunda opinión al ecografista. Esta tecnología puede suponer una herramienta estratégica para mejorar la calidad del diagnóstico y reducir derivaciones innecesarias a unidades de referencia. El futuro de esta tecnología incluye la incorporación de sistemas de aprendizaje combinado, que permitirán entrenar modelos a partir de datos entre múltiples centros hospitalarios. En resumen, la segmentación y clasificación automatizada con inteligencia artificial representa un avance en el estudio por imagen ginecológica, con un impacto directo en la precisión, eficiencia y equidad del diagnóstico del cáncer de ovario. Modelos como U-Net, entrenados con miles de imágenes ecográficas, han sido capaces de segmentar automáticamente tumores y sus componentes (sólidos, quísticos, papilares) con índices de concordancia > 90%. Estos resultados han sido validados tanto en simulación como en pruebas con expertos clínicos.

3. Deep learning en imagen multimodal

El “deep learning” ha demostrado su utilidad en el análisis de imágenes médicas complejas, además de la ecografía, como las obtenidas por tomografía computarizada (TC), resonancia magnética (RM) o tomografía por emisión de positrones (PET). Estas técnicas proporcionan información anatómica, funcional y metabólica que puede ser aprovechada por modelos de aprendizaje profundo (deep learning) para mejorar la caracterización de lesiones ováricas sospechosas y apoyar decisiones clínicas. Los modelos de redes neuronales convolucionales (CNNs) han sido aplicados en el análisis de imágenes axiales de TC y RM. Estas redes extraen automáticamente características espaciales relevantes de las imágenes sin necesidad de segmentación manual previa, lo que reduce la carga de trabajo para los radiólogos. Modelos entrenados para clasificar lesiones ováricas como benignas o malignas han mostrado valores de área bajo la curva (AUC) superiores a 0,94, incluso en estudios multicéntricos. Uno de los desarrollos más interesantes en este campo es el sistema OvaMTA, que combina imágenes fijas y secuencias de video de estudios de imagen ginecológicos en una arquitectura híbrida que integra CNNs con redes recurrentes. Este sistema ha mostrado resultados equiparables al diagnóstico de radiólogos expertos y ha sido evaluado en estudios clínicos reales, consolidándose como una herramienta de apoyo clínico. Asimismo, el uso de PET combinado con aprendizaje profundo ha lo-

grado identificar patrones de captación anómala en lesiones ováricas con alta sensibilidad, facilitando el diagnóstico en casos difíciles o con imágenes poco concluyentes. Estas aplicaciones no sólo mejoran la detección y caracterización de tumores, sino que también aportan valor en la planificación quirúrgica. Por ejemplo, los mapas de predicción generados por estos modelos pueden utilizarse para estimar el índice de carcinomatosis peritoneal y valorar la posibilidad de citorreducción. El futuro de este enfoque radica en la integración de modelos multimodales que combinen información de múltiples fuentes de imagen (ecografía, TC, PET, RM, biomarcadores) en sistemas de inteligencia artificial capaces de realizar diagnósticos precisos, pronósticos individualizados y recomendaciones terapéuticas personalizadas. Estas herramientas no sólo mejoran la detección precoz, sino que además permiten automatizar procesos de triaje clínico, reducir la carga diagnóstica y optimizar la priorización quirúrgica.

Modelos basados en biomarcadores sanguíneos

Los biomarcadores sanguíneos han constituido históricamente una herramienta fundamental en el diagnóstico y seguimiento del cáncer de ovario, siendo el Ca-125 el más utilizado. Sin embargo, su escasa especificidad y sensibilidad en estadios iniciales ha motivado la investigación en ese campo para la búsqueda de métodos más precisos y combinaciones de variables clínicas y bioquímicas. El uso de modelos de algoritmos como Light Gradient Boosting Machine (LightGBM), Random Forest, y XGBoost han sido entrenados con bases de datos que incluyen además de Ca-125 y HE4, variables demográficas (edad, menopausia), clínicas (antecedentes familiares, síntomas), bioquímicas (glucosa, colesterol, ferritina, albúmina), e incluso hábitos de vida. La precisión diagnóstica de estos modelos supera en muchos casos el 85–90 %, con áreas bajo la curva (AUC) cercanas a 0.93 en validaciones externas. Particularmente prometedores son los modelos que utilizan inteligencia artificial explicable (XAI). Estos proporcionan una predicción y además permiten comprender cómo se ha llegado a esa conclusión, mediante técnicas como SHAP (SHapley Additive exPlanations) o LIME. Así en estos casos, el modelo puede informar al médico que la elevación de los marcadores tumorales (Ca 125 o HE-4), combinada con otros factores, como hipoalbuminemia y edad, fueron relevantes para predecir riesgo alto de malignidad. Esto genera transparencia, lo cual es clave para la aceptación clínica de los algoritmos. En estudios recientes, estos modelos explicables han superado el rendimiento del algoritmo ROMA (Risk of Ovarian Malignancy Algorithm), que combina Ca-125, HE4 y estado menopáusico, el cual logre una sensibilidad de 75–80 % en detección de cáncer epitelial de ovario, mientras que los modelos IA multivariable alcanzan hasta un 92 % con mayor especificidad, evitando cirugías innecesarias. Además, la integración de datos de laboratorio en algoritmos de triaje permite su uso en áreas donde no se dispone de imagen avanzada o profesionales expertos. De esta forma, en entornos con menos recursos, estos modelos podrían facilitar el cribado inicial, derivando a unidades especializadas solo los casos sospechosos, y así, optimizar el uso de los recursos del sistema sanitario. A futuro, se espera que estos modelos se complementen con otros tipos de datos, como genética (BRCA1/2), expresión proteica, o datos recogidos automáticamente desde dispositivos portátiles (frecuencia cardíaca, variabilidad en el sueño o menstruación irregular). Con ello, la IA podría crear perfiles personalizados de riesgo, anticipando la aparición de una neoplasia ovárica. En conclusión, los modelos basados en biomarcadores sanguíneos y algoritmos de IA constituyen una herramienta accesible, escalable y de alto rendimiento que puede transformar el cribado y diagnóstico temprano del cáncer de ovario. Su capacidad de interpretar múltiples variables, su bajo coste y su aplicabilidad en múltiples contextos asistenciales los convierten en una pieza clave de la medicina de precisión del futuro.

5.1.2.4. Limitaciones actuales y perspectivas futuras

A pesar del notable avance tecnológico y científico alcanzado en el campo de la inteligencia artificial aplicada al cáncer de ovario, es fundamental reconocer que actualmente no existe una estrategia de detección precoz eficaz validada para su implementación en cribado poblacional. Las herramientas disponibles, como el marcador CA-125, la ecografía transvaginal, y los algoritmos de predicción basados en IA, han mostrado mejoras

en sensibilidad y especificidad, pero aún no alcanzan el grado de precisión diagnóstica y coste-efectividad necesario para su uso sistemático en mujeres asintomáticas.

Las principales limitaciones actuales incluyen:

1. Ausencia de biomarcadores únicos y universales con valor predictivo suficiente para estadios iniciales.
2. Falta de validación clínica prospectiva de muchos modelos desarrollados en cohortes retrospectivas.
3. Dificultad en la integración de IA en flujos asistenciales reales, por carencia de interoperabilidad entre sistemas y falta de formación del personal médico.
4. Sesgos inherentes a los conjuntos de datos de entrenamiento, que pueden limitar la generalización de los modelos en poblaciones diversas.

También, existen retos éticos y regulatorios que ralentizan la adopción generalizada de estas tecnologías, como la necesidad de garantizar transparencia de los algoritmos, la privacidad del paciente y la certificación médica de las herramientas digitales. Sin embargo, el futuro de la detección precoz del cáncer de ovario con IA es prometedor. Se anticipa que en los próximos años se consolidarán:

Modelos integrados multiómicos que combinen información genética, epigenética, proteómica, clínica y de imagen en sistemas unificados. Sistemas de inteligencia artificial explicable, que no solo proporcionen predicciones, sino también justificaciones claras para apoyar la toma de decisiones médicas.

Estrategias de aprendizaje federado y colaborativo, que permitan entrenar modelos con datos de múltiples instituciones sin comprometer la privacidad. Validaciones prospectivas multicéntricas que faciliten la incorporación de estas tecnologías en guías clínicas internacionales.

La IA puede complementar el trabajo médico con herramientas más precisas y objetivas. Y si se desarrolla de forma ética y supervisada, podría transformar radicalmente el abordaje del cáncer de ovario, permitiendo una detección más temprana, personalizada y equitativa para las pacientes con independencia de su nivel sociocultural.

5.1.3. Inteligencia Artificial En El Diagnóstico Precoz Del Carcinoma De Endometrio

5.1.3.1. Introducción

El cáncer de endometrio es la sexta neoplasia más frecuente en mujeres y la tercera neoplasia ginecológica tras el cáncer de mama y de cérvix. Se calcula una incidencia de 420.368 nuevos casos (8,4 casos/100.000 mujeres) y una mortalidad de 97.723 muertes (1,7 casos/100.000 mujeres) en el 2022 (1). En Europa, la incidencia es de 124.874 nuevos casos (15,5 casos/100.000 mujeres) y una mortalidad de 30.272 muertes (2,8 casos/100.000 mujeres) (1). En España, el cáncer de endometrio representa la cuarta neoplasia más frecuente con 6.698 nuevos casos en 2022 (12,9 casos/100.000 mujeres) y presenta una mortalidad de 1.625 muertes (2,1 casos/100.000 mujeres). Es el segundo en mortalidad del tracto genital femenino, tras el cáncer de ovario (1). Aproximadamente un 75-80 % de los cánceres de endometrio se diagnostican en estadios iniciales (estadio I), con una tasa de supervivencia a los 5 años de más de 95%. Sin embargo, la tasa de supervivencia a los 5 años disminuye cuando existe diseminación regional (68%) o a distancia (17%) (2). La patogénesis y los tratamientos del cáncer de endometrio han evolucionado significativamente durante la última década (3). El diagnóstico precoz y el tratamiento individualizado siguen siendo clave en el manejo de este cáncer y en general, en el cáncer ginecológico. La IA ha facilitado el camino hacia la medicina de la precisión y la personalización de la oncología. Existe una creciente contribución de las técnicas de IA a la estratificación precisa del riesgo y al manejo integral de pacientes; centrándose en la información y las características extraídas de datos clínicos (historias clínicas electrónicas), imágenes radiológicas, imágenes digitales citológicas e histopatológicas, y perfiles moleculares. Sin embargo; aún existen limitaciones y desafíos importantes.

Las aplicaciones de la IA en el carcinoma de endometrio incluyen el diagnóstico y la estadificación mediante el análisis histológico, imágenes radiológicas, la asistencia en cirugía mínimamente invasiva y la predicción del pronóstico en función de las características del tumor y la metástasis de los ganglios linfáticos. Una de las ramas que más se ha desarrollado y más éxito ha tenido en este sentido, es la radiómica. Ésta surge de décadas de diagnóstico por imágenes radiológicas y diagnóstico asistido por computadora. En este campo, las imágenes radiológicas se convierten en características cuantitativas de alto rendimiento. Estas características poseen el potencial de mejorar los diagnósticos y las predicciones de pronóstico mejorando la precisión (5,6).

5.1.3.2. Aplicaciones de la inteligencia artificial en el diagnóstico precoz del carcinoma endometrial

Una de las primeras inquietudes en el cáncer de endometrio, es determinar la población diana de riesgo y cómo la IA nos puede ayudar en la evaluación de ese riesgo. Hart y sus colaboradores, realizaron un estudio utilizando siete algoritmos de aprendizaje automático diferentes. Estos algoritmos estaban basados únicamente en datos de salud personales. Observaron que el modelo “Random Forest” o fue el mejor, seguido de un modelo de red neuronal. Los modelos de aprendizaje automático proporcionaron una forma no invasiva y rentable de identificar poblaciones de alto riesgo que pueden beneficiarse de la detección temprana del cáncer de endometrio, antes de la aparición de la enfermedad (7).

Con respecto a los métodos de detección del carcinoma endometrial, Zhang y sus colegas usaron la IA en las imágenes histeroscópicas de lesiones endometriales. Este estudio incluyó 1851 imágenes de 454 pacientes, estas imágenes se preprocesaron primero y se ingresó un conjunto de entrenamiento de 6478 imágenes en un modelo VGGNet-16; posteriormente se utilizaron 250 imágenes para probar el rendimiento. Después de que el modelo hiciera su diagnóstico, lo compararon con el diagnóstico dado por los ginecólogos.

Este estudio confirma que podemos utilizar el aprendizaje profundo de la IA para evaluar imágenes de lesiones endometriales obtenidas mediante histeroscopia y puede proporcionar evidencia diagnóstica objetiva para los histeroscopistas (8).

En cuanto a las técnicas de imagen para el diagnóstico del cáncer de endometrio, se han realizado estudios en modelos de IA basados en resonancia magnética (RM) (9) y en ultrasonidos (US) (10). En cuanto a los estudios de RM buscaron comparar el rendimiento diagnóstico de los modelos de aprendizaje profundo que utilizan redes neuronales convolucionales con el de los radiólogos; objetivando un alto rendimiento diagnóstico para el diagnóstico del cáncer de endometrio mediante el uso de IA en resonancia magnética (9).

En el caso de la utilización de US, a pesar de que la ecografía transvaginal muestra una sensibilidad notable, su especificidad sigue siendo limitada; por lo que se propuso un modelo de segmentación automatizado y un modelo clasificador basado en IA, que mejorara la precisión diagnóstica de la ecografía transvaginal. Logrando entrenar un algoritmo basado en IA para diferenciar la hiperplasia atípica y el /cáncer endometrial de las condiciones benignas (10).

Por último, el análisis patológico de las muestras de las biopsias obtenidas, está cada vez más digitalizada, con portaobjetos escaneados y vistos en pantallas en lugar de a través de microscopios, Los cánceres de útero, del cuello uterino y endometrio, tienen diferentes subtipos con diferentes manejos. Por lo tanto, la correcta distinción de un origen endometrial y endocervical es esencial para las decisiones de tratamiento.

Aunque la discriminación se puede ayudar con varios marcadores inmunohistoquímicos, no existe un marcador definitivo. Song y colaboradores, estudiaron la viabilidad de la clasificación basada en el aprendizaje profundo para determinar el sitio de origen de los adenocarcinomas; a partir de las imágenes de los portaobjetos completos del tejido. Los resultados demostraron claramente la viabilidad de los clasificadores basados en IA para la discriminación de cánceres de cuello uterino y de endometrio (11).

5.1.3.3. Aplicaciones de la inteligencia artificial en la estadificación, el tratamiento y el pronóstico del carcinoma endometrial

Las imágenes radiológicas son otro pilar en la estadificación del cáncer de endometrio. Las modalidades de imagen preoperatoria, como la ecografía transvaginal, la tomografía computarizada, la tomografía por emisión de positrones y la resonancia magnética, son herramientas valiosas para evaluar la extensión del cáncer de endometrio y el estudio de los ganglios linfáticos. Estas modalidades de diagnóstico por imágenes ayudan a guiar el curso óptimo del tratamiento al proporcionar información crucial sobre la estadificación del tumor.

La resonancia magnética pélvica ha sido ampliamente reconocida como una técnica de imagen valiosa para la estadificación preoperatoria para detectar la invasión miometrial profunda, la invasión del estroma cervical y los ganglios linfáticos. Sin embargo, el rendimiento diagnóstico de la RM presenta cierto grado de variabilidad en la interpretación de los hallazgos entre diferentes operadores y/o diferentes secuencias (12). Además, los radiólogos proporcionan datos cualitativos y semicuantitativos de imágenes médicas para describir los tumores y su heterogeneidad, que pueden no reflejar eficazmente las características biológicas reales del tumor (13).

Para reducir estas deficiencias surge la radiómica y los algoritmos de IA que ofrecen la conversión de imágenes en datos cuantitativos que pueden analizarse sistemáticamente, con la extracción de numerosos parámetros cuantitativos (denominados características radiómicas) (5). Estas características capturan las diversidades dentro de las imágenes y ofrecen información valiosa sobre las características del fenotipo del cáncer (13).

Mao y colaboradores desarrollaron un modelo automático de predicción basado en IA para el cáncer de endometrio temprano en imágenes de resonancia magnética (RM), utilizando como referencia la relación del área de la región tumoral con la región uterina (14). Con un estudio publicado en 2021, Han y colaboradores exploraron un enfoque radiómico de doble secuencia que empleaba la segmentación de todo el útero y descubrieron que tenía un rendimiento diagnóstico equivalente con la evaluación radiológica convencional realizado por dos radiólogos altamente experimentados que trabajaron en consenso (15).

El desarrollo y la validación de estos modelos radiómicos requieren grandes y diversos conjuntos de datos y protocolos de estandarización y aún queda un camino por recorrer para la integración de la radiómica en la práctica clínica (16). Por otra parte, la introducción de la clasificación molecular en el cáncer de endometrio propuesta por la TCGA, tiene una importancia pronóstica independiente, que al integrarlo con los factores clínico-patológicos tradicionales, mejoró la capacidad pronóstica y de estratificación de riesgo. Por lo tanto, la clasificación molecular ha tenido un impacto en el tratamiento del cáncer de endometrio (17).

El uso de la IA para predecir la clasificación molecular basado en hematoxilina y eosina, resulta interesante sobre todo en aquellos lugares donde no pueda realizarse por el costo asociado.

En esa línea se realizó un estudio que es el primero en utilizar un conjunto de datos de imágenes completas teñidas con hematoxilina y eosina a gran escala de 2028 pacientes con cáncer de endometrio de tres ensayos aleatorios y cuatro cohortes clínicas para desarrollar un modelo interpretable basado en el aprendizaje profundo (im4MEC) adaptado a la predicción de la clasificación molecular del cáncer de endometrio.

El modelo im4MEC es novedoso, ya que aprovecha el aprendizaje auto-supervisado para aprender la representación de las características morfológicas específicas del cáncer de endometrio de los mosaicos en imágenes de diapositivas completas, junto con un modelo de clasificación basado en la atención para la predicción a nivel de imagen de diapositivas completas.

Estas opciones de diseño ayudaron a establecer correlatos morfomoleculares conocidos y novedosos para cada clase molecular, además el uso de portaobjetos de histerectomía completa sin regiones de interés anotadas por humanos apoyó el descubrimiento de características específicas de clase molecular relevantes fuera de la región tumoral.

El trabajo futuro debe centrarse en la validación prospectiva, la exploración adicional de la heterogeneidad tumoral en el cáncer de endometrio, resolviendo la dificultad actual para distinguir sobre todo el grupo POLE mutado. (18)

5.1.3.4. Aplicaciones de la inteligencia artificial en el tratamiento quirúrgico mínimamente invasivo

Uno de los aspectos de mayor relevancia en los últimos años en el manejo quirúrgico del cáncer de endometrio, ha sido la adopción de la biopsia selectiva del ganglio centinela (BSGC) en lugar de la clásica linfadenectomía sistemática para la valoración del estado ganglionar. Sin embargo, la BSGC requiere de una técnica quirúrgica reglada para la identificación de estructuras anatómicas obligatorias. (19). Una identificación adecuada no solo evita el daño, sino que también garantiza una visualización completa de las vías linfáticas. Este enfoque aumenta la probabilidad de detectar con precisión el ganglio linfático centinela adecuado.

El estudio LYSE incorpora la IA en forma de análisis de vídeos para una “visión crítica de seguridad” de los pasos cruciales a seguir, como apoyo a los cirujanos; en especial en las primeras fases de la curva de aprendizaje. El análisis de vídeo de cirugías laparoscópicas o robóticas ofrece datos valiosos, a través de la anotación de video y el análisis de datos, es posible evaluar objetivamente la correlación entre los pasos quirúrgicos y los resultados.

Esto conduce al desarrollo de modelos predictivos que pueden anticipar las acciones quirúrgicas y ofrecer asistencia en tiempo real a los cirujanos durante los procedimientos. El estudio muestra un análisis objetivo de los criterios de seguridad mediante la evaluación de vídeo y apoya el desarrollo de herramientas automatizadas de inteligencia artificial basadas en vídeo. Estas herramientas permiten evaluar el logro de los pasos quirúrgicos recomendados y estandarizar las listas de verificación de seguridad en todas las instituciones.

Cuantificar y analizar los eventos intraoperatorios, como la tasa de cumplimiento de los pasos quirúrgicos recomendados o la tasa de eventos adversos intraoperatorios (es decir, hemorragias leves, tracciones extremas, vacilaciones, etc.), es crucial para optimizar la adherencia e implementación de las guías identificando nuevas estrategias para reducir los riesgos quirúrgicos. (20)

La evaluación en video de los criterios definidos de Visión Crítica de la Seguridad podría validarse clínicamente con la ayuda de estudios prospectivos y multiinstitucionales.

5.2. Estado actual del uso de la inteligencia artificial en la aplicación de las técnicas de reproducción asistida

5.2.1. Introducción

La fertilización *in vitro* está cerca de cumplir los 50 años. Un tratamiento concebido en su momento para obviar de forma eficaz la obstrucción tubárica se ha convertido en una forma mayoritaria de tratar la infertilidad. La evolución de las conductas sociales con respecto a la reproducción, especialmente la búsqueda de gestación en edades avanzadas, ha ampliado el foco de la infertilidad, que ahora gira en torno a la gran variedad de componentes del proceso reproductivo: la reserva ovárica, la calidad de los ovocitos, las características endometriales y la calidad seminal. También han evolucionado de forma extraordinaria las opciones para mejorar en el laboratorio las posibilidades de éxito de los embriones.

Con este abordaje de proceso completo como es la FIV, coexisten una serie de opciones segmentarias que aspiran a resolver alteraciones puntuales del proceso reproductivo. Podemos considerarlas “técnicas satélite”, mucho más enfocadas a decisiones concretas.

Entre ellas, podemos destacar la normalización de la ovulación, las alteraciones de la calidad espermática o la concepción en ausencia de actividad coital, como ocurre en la opción de la maternidad en mujeres sin pareja masculina. Estos escenarios se resuelven con intervenciones de menor complejidad, como la inducción de la ovulación o la inseminación, pero que también implican decisiones optimizables.

Al conjunto de recursos técnicos que hacen posible esta ayuda al proceso reproductivo nos referimos como “Reproducción Asistida (Médicamente)” o Técnicas de Reproducción Asistida (TRA), a menudo referenciadas con las siglas en inglés ART (Assisted Reproductive Technologies).

Para hacernos cargo del volumen de actividad científica que movilizan estas tecnologías, podemos aplicar a "PubMed" estos términos de búsqueda y obtendremos cerca de 15.000 entradas en los últimos 35 años (Figura 1).

Un ciclo completo de FIV constituye una cadena de valor en la que las mejoras en cada etapa repercuten directamente en la siguiente y en el rendimiento del proceso completo. Las podemos enumerar de forma convencional como: hiperestimulación ovárica controlada, descarga preovulatoria, punción folicular, clasificación de los ovocitos, decisión de la forma de fertilización, día y tipo de transferencia. Estas son etapas que exigen conocimientos y habilidades distintos y en las que el componente de experiencia individual y, en consecuencia, la subjetividad, juegan un papel importante.

En la Figura 2. presentamos una gráfica que intenta identificar las distintas etapas en las que puede ser dividido el proceso de FIV y cómo la IA puede asistir en los procesos de toma de decisión que tienen lugar en cada una de ellas.

La experiencia no es más que un sumatorio de resultados obtenidos por un observador ante decisiones tomadas subjetivamente en función de la concurrencia de factores que considera comunes. Como tal, tiene una serie de limitaciones, como el número de observaciones, la información sobre los resultados de una decisión o sobre las variables que, en el contexto de una paciente determinada, se pueden añadir a la observación inicial.

Como se ha explicado en los capítulos introductorios, la inteligencia artificial (IA) es capaz de identificar asociaciones entre datos de diversos tipos que replican y mejoran el concepto de experiencia humana. La acumulación de datos, cuantitativamente incomparables a la experiencia individual, sobre contextos clínicos concretos, permite el entrenamiento de sistemas o "Machine Learning" (ML) que llevan a la construcción de algoritmos que conducen a decisiones clínicas más eficientes.

Más recientemente aparece el concepto de modelo fundacional (1). Este término fue acuñado por los investigadores para describir los modelos de ML entrenados en un amplio espectro de datos generalizados y sin etiquetar, y capaces de realizar una gran variedad de tareas generales como comprender el lenguaje, generar texto e imágenes y conversar en lenguaje natural. Debemos esperar que esto signifique un nuevo paso en la optimización de modelos complejos como la RA.

Debemos ser conscientes de que la utilización de la IA en reproducción asistida está más en el mundo de las intenciones que en el de las realidades. El objetivo de este capítulo será identificar aquellos escenarios clínicos o de laboratorio para los que se han propuesto y valorado las opciones de mejora con la aplicación de distintas formas de IA y, en su caso, los resultados obtenidos. La conciencia de que la incorporación de estas herramientas va a significar, en un futuro indeterminado, cambios significativos en la aplicación y los resultados de las TRA ha implicado, entre otras, la creación de grupos de interés específicos en sociedades científicas como ASRM (<https://www.asrm.org/membership/asrm-member-groups/special-interest-groups/artificial-intelligence-special-interest-group-aisig/>) o también sociedades únicamente centradas en este tema (<https://aifertility.org/>) (2).

5.2.2. Metodología

Para la redacción de este capítulo se ha procedido de forma similar a la de una revisión narrativa, realizando dos etapas de búsqueda. Una primera etapa, con el objetivo de conocer los procedimientos de las revisiones existentes sobre el tema y los contenidos más relevantes. La segunda etapa se centró en el análisis de los artículos identificados como de calidad en la primera búsqueda y, más específicamente, en los avances en la aplicación de la IA en cada una de las etapas de la FIV.

Se realizó una búsqueda en PubMed con los términos: *assisted reproductive technologies AND artificial intelligence* y con los filtros: *last 5 years, Free full text, Meta-Analysis, Review, English, Humans*. La búsqueda identificó 44 artículos. Después de la lectura de títulos y resúmenes, se seleccionaron 7 que valoraban de forma general todo el procedimiento de FIV y no se centraban en etapas concretas. De ellos, solo 2 eran revisiones, una narrativa (3) y una sistemática (4).

Los 5 restantes son artículos de opinión basados en búsquedas genéricas, pero que no pretendían cubrir el tema de forma exhaustiva.

Como los autores son investigadores experimentados y las publicaciones aparecen escalonadas desde el año 2020 al 2025, nos permiten valorar la evolución de la opinión del mundo de la reproducción asistida sobre la utilidad de la IA a lo largo de estos años. Posteriormente, entraremos en la valoración del valor de la IA en cada etapa del proceso de FIV a partir de los artículos identificados en las revisiones sistemáticas, utilizando criterios rigurosos de selección. Compararemos las diferencias entre ambas revisiones que utilizan términos similares de búsqueda, pero explorando distintas bases de datos.

5.2.3. Análisis cualitativo

En 2020, Raimundo JM y cols. presentan en la "International Conference on Health and Social Care Information Systems and Technologies 2020" una propuesta de aplicación de la IA en las distintas etapas de la FIV. Se trataba únicamente de revisar algunas de las opciones de aplicación de ML sin entrar en las posibilidades disponibles en aquel momento o su impacto en los resultados (5).

Un año más tarde, Riegler y cols. plantean de una forma más didáctica la descripción del proceso metodológico de ML en la clínica. Después de revisar como ejemplo dos situaciones que perciben como más susceptibles de aplicación de la IA, la calidad espermática y la selección de embriones con mayores posibilidades de implantación, introducen un apartado de "dificultades" que me parece especialmente interesante y del que destacaría su primera frase que define, por ella misma, lo que marcará la evolución futura de la aplicación clínica de la IA: "Los algoritmos de IA son tan buenos como los datos usados para construirlos" (6).

En 2023, Letterie plantea en *Fertility and Sterility* una reflexión sobre el grado de madurez que, en aquel momento, había alcanzado la aplicación de la IA a la reproducción asistida (7). Debemos tener en cuenta que Chat GPT llevaba tan solo un año disponible en su primera versión.

Resalta en aquellos momentos que, más allá de la promesa de mejorar los resultados, la aplicación de la IA debería ponerse también el objetivo de mejorar los flujos del proceso, optimizando los tiempos y minimizando el estrés de los participantes, tanto de pacientes como de proveedores. Insiste en los riesgos de estrategias que puedan basarse en datos de baja calidad y, especialmente, en la posibilidad de inducir errores sistemáticos a causa de algoritmos viciados por un sesgo de información. También reflexiona sobre la necesidad de información robusta sobre la bondad de los resultados, basada en los métodos aceptados por las sociedades científicas en un mundo de la "medicina basada en pruebas". Finalmente, pone a consideración la necesidad de actualizar criterios bioéticos de utilización de la información para el entrenamiento de los sistemas y su control institucional.

Finalmente, Jacques Cohen, un embriólogo reproductivo desde los tiempos iniciales, ya que fue miembro del equipo de Edwards en Bourn Hall, publica una revisión/narración de la implementación de la IA en los tratamientos de reproducción (8). Aunque es una visión sesgada desde la óptica de la embriología, aporta aplicaciones colaterales que no se mencionan en los artículos convencionales de revisión. Entre ellos, destaca el uso del reconocimiento facial para la elección de donantes. Con ello se facilita la mejor similitud fenotípica entre donante y receptor o compañero de paciente sin vulnerar las normas de privacidad.

Cohen revisa las distintas etapas del proceso de FIV susceptibles de ser mejoradas por la IA y llama la atención sobre aspectos a valorar a partir de su experiencia: Las medidas necesarias para la preservación de la seguridad de los datos, la posibilidad de generar algoritmos con errores sistemáticos que se perpetúen en el tiempo o la posibilidad de que el uso de herramientas controladas por IA conduzca a una pérdida de entrenamiento en los operadores humanos.

En este sentido, llama la atención sobre la posibilidad de que los estudios que comparen el rendimiento de modelos automatizados de micromanipulación con los operados por humanos estén sesgados por el llamado efecto Hawthorne, según el cual los operados que se saben observados mejoran su rendimiento con respecto a su actividad rutinaria.

Cohen acaba afirmando que la introducción de la IA en los tratamientos de RA debe inspirar confianza, integrarse de forma no distorsionante en los flujos de trabajo y ofrecer beneficios reales, garantizando que los embriólogos sigan siendo fundamentales para el avance de la tecnología de reproducción asistida.

5.2.4. Análisis de las revisiones sistemáticas

Durante el primer semestre de 2025 se han publicado dos revisiones, una sistemática y una narrativa, sobre la aplicación de la IA a la reproducción asistida (Olawade, Wu) enfocadas casi exclusivamente a la FIV. Existen diferencias entre ellas que tienen el inconveniente de que no pueden usarse como confirmatorias mutuas de los resultados, pero que ofrecen una información amplia sobre el estado actual de la situación.

Olawade y cols. proponen desde el principio una revisión narrativa. Realizan su búsqueda en PubMed, Scopus, Web of Science y Google Scholar. Los términos de búsqueda son amplios, tanto en los aspectos de la IA ("Artificial Intelligence", "Machine Learning", "Deep Learning") como en los de la reproducción asistida (*In vitro fertilization*, FIV, *Ovarian stimulation*, *oocyte quality*, *embryo selection*, *sperm selection* y *IFV outcomes*). El periodo estudiado es de 2020 a 2024. Aunque no realizan una descripción exhaustiva de los criterios de selección, presentan un gráfico PRISMA en el que parten de 315 artículos que, después de un filtrado a partir de los títulos y lecturas completas, incluyen 53 artículos en la revisión.

Wu y cols. anuncian en el título una revisión sistemática, pero no cumplen con los criterios PRISMA de especificar los criterios de selección de los artículos. Las bases de datos exploradas son, aparte de PubMed, Embase y la biblioteca Cochrane. Los criterios de búsqueda: "*artificial intelligence AND infertility*", "*artificial intelligence AND In vitro fertilization*" y "*artificial intelligence AND assisted reproductive technology*". Obtienen 1253 referencias que, después del proceso de selección por lectura de título, *abstract* y texto completo, incluyen 35 artículos para revisión.

Nos encontramos con un total de 88 artículos seleccionados, de los que tan solo 3 se encuentran en ambas selecciones. Esto es consecuencia de las diferencias entre las bases de datos consultadas, los términos de búsqueda y los criterios de selección. En conjunto, constituyen una selección actualizada del material más interesante sobre el tema.

Dado que ambas revisiones segmentan sus resultados en grupos temáticos muy similares, basaremos nuestro análisis en los comentarios vertidos sobre cada etapa en cada una de las dos revisiones.

5.2.5. Evidencias sobre las distintas etapas de la reproducción asistida

1.- Análisis de las decisiones clínicas

La primera etapa de un ciclo de FIV se centra en la optimización del proceso de obtención de ovocitos. En esta etapa, las decisiones se toman sobre la experiencia adquirida en escenarios clínicos similares a los de la paciente a estimular. Se basa, pues, en información no gráfica sobre un número muy amplio de datos a combinar: edad, peso, valores hormonales, existencia de ciclos previos, etc. Por tanto, los modelos a desarrollar dependerán de la cantidad y calidad de los datos almacenados (Figura 3).

Estimulación del desarrollo folicular múltiple

Elección de dosis de inicio

El primer paso en la optimización de la FIV fue la hiperestimulación ovárica controlada. La racionalidad, en un momento en que la tasa de fertilización era muy baja, se basaba en el incremento del número de folículos en desarrollo, el número de ovocitos obtenidos y un mayor potencial de embriones a transferir, aumentando a su vez las posibilidades de embarazo.

Pronto se pusieron de manifiesto inconvenientes derivados de esta estrategia: No todos los ovarios respondían de la misma forma. Las dosis que podían considerarse "normales", en algunos casos eran evidentemente excesivas, desencadenando incluso síndromes de hiperestimulación, y resultaban insuficientes para otros. Ello exigía identificar criterios para clasificar a las pacientes y ajustar las dosis de inicio. La información sobre la reserva ovárica que nos ofrece la morfología ovárica valorada por ecografía (recuento de folículos antrales) o las determinaciones hormonales (FSH o HAM) permite clasificar a las pacientes en normales, en riesgo de hiperestimulación (las que presentan un patrón de ovario poliquístico) o bajas respondedoras. Al mismo tiempo, estos patrones pueden determinar el tipo de gonadotropinas a utilizar: preparados que ejercen únicamente actividad FSH, tanto extractiva como recombinante, o las que ejercen también actividad "LH-like" como las menotropinas o las combinaciones de recombinantes.

La práctica ha demostrado que esta clasificación es útil para una mayoría de casos y ha ahorrado un número significativo de hiperestimulaciones, pero, por otra parte, ha llevado a un uso excesivo de gonadotropinas que no ha mejorado la respuesta ovárica en las clasificadas como "bajas respondedoras". También queda poco respaldada por evidencias robustas la elección entre preparados con solo actividad FSH o las combinaciones.

La IA puede ser de ayuda para optimizar estas decisiones. Zieliński (9) y cols., basándose en una base de datos de 516 estimulaciones, combinaron los marcadores biológicos clásicos con variantes genéticas en genes relacionados con la reproducción y desarrollaron un modelo predictivo de la respuesta folicular, específicamente del número de ovocitos MII, que triplica la precisión de los parámetros biológicos. Ello puede contribuir a la gestión de candidatas dentro de programas públicos de provisión de tratamientos.

La elección de la dosis de inicio y el momento de administración del "trigger" puede influir también en la eficiencia del proceso. Hasta ahora, tan solo se ha valorado la contribución de la IA en la elección de dosis en estudios retrospectivos que Hariton (10) (2023) revisa críticamente.

El grupo de Eugin (11) (Correa (2)) propone un estudio prospectivo y randomizado de muestra muy amplia del que no he podido identificar los resultados publicados, pero que tiene un diseño riguroso. La información más sólida sobre el potencial del uso de IA en la elección de dosis la ofrece el estudio de Fanton (12), basado en la utilización retrospectiva de la información de 18.591 ciclos realizados en tres clínicas de USA en cuatro años. Comparando los tratamientos usados con los que su algoritmo propondría, se habrían obtenido 1,5 ovocitos MII más por ciclo que se convirtieron en 0,6 blastocistos transferibles usando menos FSH.

Recientemente, en un estudio de casos y controles, se observaron resultados equivalentes en el grupo en el que ambas decisiones se tomaron por parte de los clínicos, o bien siguiendo su experiencia o las indicaciones de un software desarrollado específicamente. Los resultados mostraron un número equivalente de MII, pero con dosis menores de FSH y un periodo más corto de estimulación (Bixby 2025) (13). Este sería el primer estudio comparativo en vida real, pero en el que el análisis se limita al número de MII y no realiza un seguimiento del resto del proceso ni del número de recién nacidos en casa.

Resumiendo, con la utilización de algoritmos entrenados con un número elevado de casos que han utilizado de forma consistente dosis iniciales, se puede generar un modelo que informe de las dosis iniciales de FSH óptimas.

Elección de pauta de tratamiento

Los distintos fenotipos ováricos (normal, baja reserva u ovario poliquístico) requieren el uso diferenciado de combinaciones de los dos tipos de actividad gonadotropa. Si bien en todos los casos se precisa la presencia de FSH, la actividad LH no es necesaria y probablemente no deseable en los casos de OPQ, y algunos grupos opinan que las menotropinas pueden ser mejores que los productos recombinantes en las bajas respondedoras.

Por otra parte, un problema que surgió al inicio de la aplicación de la hiperestimulación controlada es el incremento, de forma precoz, de los niveles de estradiol hasta valores que desencadenen una elevación o "pico" de la LH y la luteinización de los folículos, en algunos casos aún inmaduros.

La aparición de los agonistas y antagonistas de la GnRH ofreció una solución a este problema al bloquear de forma consistente la producción endógena de gonadotropinas. Por ello, se diseñaron distintas estrategias

sobre el inicio y la duración de la administración de agonistas o antagonistas y su adecuación a los distintos fenotipos ováricos.

Se supone que el uso de algoritmos entrenados con material registrado de forma adecuada para cada posible combinación debería ofrecer una mejor elección que la intuición clínica basada en resultados previos de muestras pequeñas. Sin embargo, Wu (4) inicia el apartado dedicado a este tema con la frase: "La investigación sobre la aplicabilidad de la IA para la elección de protocolo se encuentra en la infancia."

Refiriéndose a los trabajos de Murillo (14) y Wald (15) y también a la editorial que Quaas (16) publica en la edición del *Fertility* en la que se publica este último, existe poca confianza en la importancia del tipo de protocolo a la hora de definir los resultados. En resumen, no hay hasta ahora evidencias de que adaptar los protocolos al perfil de las pacientes aporte mejoras significativas a los resultados.

Por tanto, no existen estudios de diseño adecuado sobre la posibilidad de que la IA identifique la pauta más adecuada para cada paciente.

Elección del día de luteinización o "trigger"

El proceso de hiperestimulación controlada se termina con la administración de sustancias con actividad LH que desencadene la finalización de la maduración folicular y la progresión de los ovocitos a Metafase II. Ello se obtiene con la administración de HCG o de GnRH en el caso de haber usado antagonistas para evitar el pico espontáneo.

La adecuación de esta decisión es relevante porque determina: 1) la duración de la fase de estimulación y, por tanto, el consumo de gonadotropinas; 2) la programación del día de punción y su impacto en el flujo asistencial; y 3) una buena correlación entre folículos excesivamente maduros versus inmaduros.

La información para tomar esta decisión se basa en los valores de estradiol y la evolución de las imágenes foliculares por ecografía seriada.

La ecografía tiene el inconveniente de la variabilidad entre operadores y la información imprecisa de la ecografía 2D (17). La IA puede generar información muy completa a partir de imágenes 3D (18).

Liang (19), entrenando un sistema de *Deep Learning* a partir de la información generada por 515 ecografías 3D realizadas el día de la administración de HCG, ha podido establecer que un volumen de 0,5 cm³ en el folículo dominante garantizaba la mejor "cosecha" folicular y permitía establecer modelos de predicción del síndrome de hiperestimulación.

Hariton, Chi (20) (2021) aplicó un modelo T-learner con árboles de decisión basado en el tamaño folicular y los valores de estradiol de 7866 pacientes de FIV. Aunque el diseño es complejo y compara los casos en los que un clínico experto o el algoritmo aconseja esperar o administrar el *trigger*, calcula que siguiendo los consejos del algoritmo se obtiene un número significativamente superior de MII y blastocistos viables que los que se obtendrían con la decisión clínica.

Fanton (12), al que nos hemos referido en el apartado de determinación de dosis, mejoró con su algoritmo la predicción del mejor día de *trigger* ya en el día 7 de la estimulación, basándose en el número de folículos medianos y pequeños y los valores de estradiol basales. Como consecuencia, se obtiene un número superior de ovocitos en MII y blastocistos viables. Si tenemos en cuenta que el estudio tiene también una parte de determinación de la mejor dosis de FSH inicial, no puede atribuirse la bondad de estos resultados tan solo a la oportunidad en la elección del momento de la descarga de LH, sino también a la adecuación de la dosis utilizada.

En conjunto, cualquier anticipación sobre la evolución y los resultados en número de ovocitos en relación con el proceso de estimulación facilitan la planificación del trabajo en la clínica y el laboratorio.

En un estudio basado en los datos de 1591 ciclos con una información de base completa, Letterie (21) desarrolló un algoritmo que identificó el día ideal de *trigger* con una precisión de 1,3 días y una ventana de 3 días como potencialmente adecuados para la punción.

Quisiera destacar que los estudios mencionados, publicados en el año 2022, no han generado publicaciones posteriores sobre los resultados de la aplicación generalizada de las herramientas en las clínicas que los desarrollaron.

Por tanto, la experiencia clínica sigue siendo la mejor herramienta para la toma de decisiones en el proceso de hiperestimulación ovárica controlada.

2.- Análisis de las decisiones en el laboratorio

Una vez obtenido el material reproductivo, corresponde al laboratorio la elección de los gametos en mejores condiciones para fertilizar y generar un embrión de calidad. Disponer de tecnología que eligiera de modo objetivo y reproducible aquellos gametos más favorables reduciría de forma muy significativa la carga de trabajo en la cadena de procedimientos de laboratorio y, por tanto, la eficiencia de todo el proceso (Figura 4).

En este contexto, el material a utilizar son las imágenes, tanto estáticas como dinámicas (*time lapse*). Por una parte, se garantiza la objetividad de la información relacionable con los resultados. Por otra, requiere una cantidad más importante de imágenes acumuladas para generar un modelo que incorpore diferencias morfológicamente "sutiles", pero con valor pronóstico importante.

Además, aquí aparece como compañero necesario el software utilizado para la obtención de las imágenes. La combinación de la robótica con la IA es lo que permite vincular las imágenes con las decisiones adecuadas (22).

5.2.6. La IA y la gestión del semen en reproducción asistida

En contraste con la diversidad y complejidad de los factores que intervienen en la fertilidad femenina, en el caso del varón, su contribución al éxito del proceso reproductivo se concentra en la calidad, cuantitativa y cualitativa del semen.

Una valoración adecuada de estos parámetros juega un papel importante en dos momentos de la atención a la infertilidad: en el diagnóstico de la pareja y en la elección de la técnica de inseminación y del espermatozoide óptimo para la inyección intracitoplasmática (ICSI) o inseminación de los ovocitos.

Para la redacción de este apartado hemos realizado una búsqueda específica con los términos de búsqueda "*Male infertility AND Assisted reproductive technologies AND Artificial intelligence*", que ha identificado 8 artículos de los que, después de revisar el título y resumen, hemos seleccionado 5 (23–27).

El primer paso de la valoración del factor masculino es el espermiograma. Pretende informar de la cantidad, morfología y movilidad de los espermatozoides. También se pueden analizar parámetros bioquímicos del líquido seminal. La prueba está sujeta a sesgos relacionados con el observador, ocupa mucho tiempo y la información es únicamente relevante en caso de normalidad o de afectaciones importantes de los parámetros evaluados.

A inicios de los años 80 del pasado siglo, se introdujo la informática en la valoración del semen con los dispositivos y aplicaciones que se denominaron genéricamente CASA (*Computer Assisted Semen Analysis*), con aportaciones cada vez más precisas del componente celular: número, motilidad y morfología.

Actualmente existen numerosos dispositivos que proporcionan análisis automatizados del semen, de forma que en el registro de aplicaciones médicas de la FDA se registran ya 11 dispositivos con esta finalidad.

Como más innovadora, tenemos una aplicación que permite el "seminograma domiciliario": el paciente recoge una muestra de semen que mantiene a temperatura ambiente hasta la licuefacción. Coloca una gota de semen licuado en un set de "porta y cubre" que proporciona la aplicación y realiza varios videos con el teléfono. Estos se remiten "online" a un analizador central que remite al poco tiempo los resultados (28). Estos dispositivos de automatización del seminograma, al simplificar el procedimiento, facilitan valorar la evolución del semen como respuesta a actuaciones terapéuticas como la cirugía del varicocele o algunos tratamientos médicos.

También disponemos de combinaciones "hardware/software" capaces de identificar alteraciones morfológicas que se asocian con problemas como la fragmentación del ADN (24).

Hay que señalar que la mayoría de pruebas sobre estas aplicaciones se ha establecido con estudios no comparativos ni aleatorizados y que están pendientes de confirmación con estudios adecuados.

El segundo ámbito en el que la IA puede cambiar el enfoque andrológico de la FIV es en la selección de la técnica, FIV o ICSI, de acuerdo con una predicción de la capacidad fertilizante del semen más allá de la evaluación clásica y, aún más determinante, en la selección del mejor espermatozoide candidato para la ICSI.

Montjean y cols. (29) presentan un estudio prospectivo y aleatorizado de 626 MII "hermanos" en el que 320 fueron microinyectados de acuerdo con una selección del mejor espermatozoide por un clínico (júnior o experimentado) y 326 de acuerdo con un software de identificación de espermatozoide único (*Single-Sperm Selection Software* (SiD)).

Se observó una tendencia no significativa hacia mejores resultados en el grupo ICSI-SiD en la tasa de fertilización, la tasa de segmentación, la tasa de desarrollo embrionario en el día 3, la tasa de desarrollo de blastocisto en el día 5, la tasa de desarrollo de blastocisto de buena calidad en el día 5 y la tasa de desarrollo de blastocisto de alta calidad en el día 5.

Aunque las diferencias no hayan sido significativas (posiblemente se precise una muestra mayor), el uso de un sistema automatizado de elección disminuye la fatiga del equipo y acorta la duración del procedimiento. Sin embargo, tiene el inconveniente de disminuir el entrenamiento de los biólogos y les hace progresivamente más dependientes de la tecnología.

Debemos esperar que los procesos de entrenamiento actualmente en curso permitan integrar la IA tanto en el diagnóstico del factor masculino como en la optimización de la fertilización de los ovocitos de calidad obtenidos en la punción.

5.2.7. Valoración y selección de los ovocitos a inseminar

La elección del ovocito adecuado para fertilizar determina las posibilidades de éxito del resto del proceso. El objetivo de la hiperestimulación ovárica controlada es la obtención del mayor número de ovocitos en MII; sin embargo, no todos tendrán las mismas opciones de fertilizar y progresar. Evitar fertilizar o microinyectar ovocitos de calidad subóptima significa ahorrar costes y carga de trabajo al laboratorio durante la etapa siguiente.

En el contexto de la preservación social de ovocitos, conocer la calidad de lo preservado ayuda a poner en el punto justo las expectativas de gestación en el momento de su descongelación. En los países en los que no está permitida la congelación de material reproductivo, una buena elección de los ovocitos a fertilizar evita el fracaso de todo el proceso por haber utilizado ovocitos que no eran, sin saberlo, la mejor opción.

Sin embargo, en la actualidad, la herramienta a la que se confía esta selección es el microscopio óptico de calidad y la experiencia del biólogo que los valora. Este proceso es subjetivo, no está homologado y no nos da una información que permita la comparación de resultados, más allá de la identificación de características de pronóstico como la morfología del corpúsculo polar, imágenes citoplasmáticas como la presencia de fragmentos o de características de la zona pelúcida para sistematizar su valoración. Sin embargo, nunca se ha llegado a establecer un índice de calidad aceptado universalmente.

El avance de la microscopía ha llevado al desarrollo de técnicas adicionales: la espectroscopia confocal Raman, la fluorescencia o la captación de las características del uso meiótico con el microscopio de luz polarizada.

Esta última parece estar en el estado más avanzado para incorporarse a la clínica. Durante la metafase de la meiosis II, los microtúbulos del huso meiótico alinean los cromosomas a lo largo del ecuador. Para adecuar el ovocito para la fertilización, es fundamental que, en el huso meiótico, se produzca la segregación adecuada de los cromosomas que condiciona su reducción adecuada en el ovocito a la mitad. De no ser así, la aneuploidía es responsable de causar malos resultados reproductivos. Se calcula que más del 50% de los ovocitos de mujeres mayores de 40 años son aneuploides, lo que provoca abortos espontáneos o implantación fallida, causados en gran medida por defectos en la formación del huso meiótico.

La obtención de imágenes del huso meiótico se ha utilizado como un método no invasivo para determinar la calidad de los ovocitos en laboratorios de FIV, pero los resultados en estudios con muestras pequeñas no

son siempre coincidentes (30). Con la llegada de la IA se pueden desarrollar modelos que combinen la información fotográfica obtenida en el microscopio de luz polarizada. Esto tiene el potencial de utilizarse en la selección de ovocitos euploides antes de la fertilización (31).

En la actualidad se encuentra en proceso de entrenamiento, como mínimo, un protocolo que combina las imágenes del huso meiótico con los resultados posteriores obtenidos por laboratorios que no usaron esta información para tomar las decisiones de los ovocitos a fertilizar (Figura 5).

5.2.8. Valoración y selección de los embriones a transferir

En un porcentaje elevado de casos se obtienen varios embriones a partir de un proceso de estimulación. Tal como ocurre con los ovocitos, tener información sobre su calidad incrementa la eficiencia del proceso: facilita la política de transferencia de embrión único, disminuye el número de embriones a congelar e incrementa la tasa de niño en casa por ciclo iniciado.

Desde el inicio y en la mayoría de laboratorios, la valoración de la calidad de los embriones se establece a partir de la observación sistematizada por parte de embriólogos expertos. Aunque su precisión, a la hora de determinar la viabilidad a largo plazo de los embriones, es menor que la de los métodos invasivos que describiremos a continuación, está a disposición de todos los laboratorios y no precisa de utillaje caro, y el entrenamiento de los observadores no es complejo.

Para incrementar la comparabilidad de resultados en los estudios de investigación, la ESHRE promovió un grupo de trabajo para sistematizar la metodología de valoración de los embriones por microscopía óptica (32), que continúa siendo la más utilizada. La aparición de los registros en *Time Lapse* permite el registro de imágenes del proceso de desarrollo embrionario con mucha más frecuencia que con la observación periódica. Las imágenes que proporcionan las cámaras permiten la generación de software que clasifica a los embriones por su dinámica de evolución. Con ello se puede incrementar la predictibilidad de éxito que ofrece la observación sistematizada, pero no identifica las aneuploidías que pueden darse con frecuencia, especialmente en pacientes mayores de 35 años.

Con este objetivo se desarrollaron técnicas de Diagnóstico Genético Preimplantacional (DGP). Es una técnica invasiva que implica la retirada de una o más células del embrión sobre las que se pueden realizar técnicas de biología molecular, mayoritariamente secuenciación de nueva generación (NGS) que establece la ploidía del embrión. Esta técnica tiene inconvenientes que limitan su difusión. Es costosa tanto por el utillaje y reactivos que se utilizan como por la necesidad de tener embriólogos muy expertos que no perjudiquen al embrión en el momento de biopsiar. Además, existe la posibilidad de falsos positivos y negativos. Si el embrión presenta un mosaicismo, la biopsia puede inducir a descartar embriones potencialmente viables si la célula biopsiada aneuploide no representa la ploidía de todo el embrión o, al contrario, transferir un embrión aneuploide si se biopsia una célula euploide cuando el resto es aneuploide (33).

La IA ofrece una alternativa no invasiva al combinar los datos morfológicos y morfocinéticos que ofrecen las grabaciones de las cámaras *time lapse* de las incubadoras con los resultados obtenidos con los embriones previamente valorados y con los datos de historia clínica de cada mujer. Herramientas de DL identifican los parámetros comunes en los embriones euploides con una evolución exitosa.

El entrenamiento de modelos con esta información ofrece una capacidad de predicción mucho más alta que con las técnicas no relacionales.

Para desarrollar modelos de este tipo se precisan cantidades muy importantes de datos recogidos de forma estandarizada y que permitan añadir información clínica recogida también de forma sistematizada.

Una primera experiencia que combina la información morfológica de alta calidad con los resultados clínicos es la realizada por Diakiw y cols. (34). Se analizaron un total de 15.192 imágenes de embriones en estadio de blastocisto con sus resultados clínicos recogidos retrospectivamente. Se añadieron dos conjuntos de datos recopilados prospectivamente y cegados para los investigadores, proporcionados por clínicas de FIV que utilizan el modelo de IA genética en la práctica clínica. De estas imágenes, se utilizaron 5.050 imágenes

de embriones en el día 5 de cultivo *in vitro* para el desarrollo del modelo de IA. Posteriormente, estas imágenes se utilizaron en 2.438 mujeres tratadas consecutivamente que se sometieron a procedimientos de FIV en EE. UU. entre 2011 y 2020.

La precisión para la predicción de euploidía fue del 65,3 %, con una sensibilidad del 74,6 %. Al eliminar las imágenes de baja calidad y mal etiquetadas, la precisión general aumentó al 77,4 %. Se observó una correlación positiva significativa entre la puntuación de IA y la proporción de embriones euploides: los embriones con puntuaciones muy altas (9,0-10,0) tenían el doble de probabilidades de ser euploides que los embriones con puntuaciones más bajas (0,0-2,4).

Al utilizar el modelo de IA genética para clasificar los embriones en una cohorte, la probabilidad de que el embrión mejor clasificado fuera euploide fue del 82,4 %. La probabilidad aumentó al 97,0 % al considerar la probabilidad de que uno de los dos embriones mejor clasificados fuera euploide. Los resultados sugirieron que el modelo de IA podría utilizarse para diferenciar embriones en mosaico según el nivel de mosaicismo.

Posteriormente, Barnes y colaboradores, con muestras muy homogéneas generadas en Cornell e IVI Valencia (35), entrenaron a un sistema de DL con 10.378 blastocistos humanos, de entre día 5 y día 6, procedentes de 1.385 pacientes de Well Cornell a los que se agregaron datos clínicos y morfológicos. El objetivo era el desarrollo de un método de DL llamado STORK-A, que utiliza imágenes capturadas por microscopía de *time lapse* combinadas con información clínica como la edad materna, junto con parámetros morfocinéticos y morfológicos, para predecir con precisión la ploidía de un embrión. Su capacidad de discriminación se puso a prueba con dos conjuntos de embriones: uno de 841 embriones procedentes de Cornell y otro de 554 aportado por el IVI.

Como prueba de concepto, STORK-A mostró una capacidad para predecir la ploidía del embrión de manera no invasiva y un potencial para complementar los métodos tradicionales de selección de embriones y priorización para la realización de PGT-A.

Podemos decir que, en la actualidad, los sistemas de soporte a las decisiones sobre la calidad de los embriones se encuentran en un estado avanzado de desarrollo. Los análisis morfológicos de los embriones se ven reforzados por una mayor calidad en el registro de los detalles (como cambios morfodinámicos sutiles, calidad de las relaciones intercelulares, grado de fragmentación) que permiten optar de forma más precisa por un embrión determinado a la hora de priorizar su implantación (36).

5.2.9. Comentario final

Queremos finalizar este apartado con una serie de reflexiones sobre su validez y utilidad futura.

La inteligencia artificial es una disciplina en evolución continua que ofrece constantemente nuevas herramientas de análisis basadas en su utilización. La información que ofrecemos es la disponible en PubMed, en el mes de septiembre del 2025, con los criterios de búsqueda descritos. Si conocemos los plazos que precisa una información generada en un laboratorio para llegar a ser publicada, seremos conscientes de que nuestro texto será pronto superado por material en proceso de revisión o de elaboración. Por lo tanto, nuestro texto tiene únicamente utilidad para intuir cómo será la implantación de la IA en la Medicina Reproductiva del futuro.

Hemos omitido voluntariamente campos muy relevantes como la privacidad de los datos, la necesidad de recurrir a metodologías de almacenamiento de datos que permitan contribuir al aprendizaje de sistemas generadores de algoritmos o la relación de interfaz entre datos numéricos, cualitativos y de imagen.

Hemos dejado para otra ocasión el análisis de la eficiencia que generaría la aplicación de la IA a los tratamientos reproductivos. A menudo olvidamos el coste medioambiental (utilización de recursos naturales y vertido de CO₂ al medio) y el uso de energía costosa. Ello puede conducir a su limitación a centros y capas sociales con capacidad adquisitiva elevada.

Tampoco hemos analizado los aspectos bioéticos que entran en discusión cuando un algoritmo decide sobre el futuro de un embrión. Se ha planteado la posibilidad de un sesgo de preferencia si, debido a las

características de los aportadores de datos, se pueden favorecer grupos étnicos determinados o cuando, haciendo previsión de las posibilidades de éxito, dirige a una mujer o pareja hacia la utilización de material heterólogo (37).

La falta de transparencia de los procesos en "Black box" y la posible "deshumanización" de las decisiones están también en la discusión ética de su uso.

Pero es relevante destacar que, en la actualidad, no existe información de la utilización normalizada y sistemática de las opciones de tratamiento que hemos analizado y discutido en el capítulo. Solo la experiencia con metodología de análisis rigurosa nos dará la respuesta en el futuro.

5.3. Tratamiento Asistido por IA en Ginecología

*Dr. Javier de la Torre Fernández de Vega
Ginecólogo, Quirón Barcelona – Hospital Vall d'Hebron
Profesor asociado de Ginecología, UAB*

5.3.1. Introducción

La inteligencia artificial (IA) está transformando la medicina moderna, y la ginecología no es la excepción. Gracias a técnicas como el aprendizaje automático (*machine learning*) y el aprendizaje profundo (*deep learning*), es posible analizar grandes volúmenes de datos clínicos para mejorar el diagnóstico, tratamiento y seguimiento de las pacientes.

La IA se aplica en diversas áreas de la ginecología, desde el diagnóstico hasta el tratamiento y seguimiento de pacientes. Algunas de sus aplicaciones más relevantes incluyen:

- **Diagnóstico asistido por IA:** Utilización de algoritmos de aprendizaje automático para analizar imágenes médicas y detectar anomalías con mayor precisión que los métodos tradicionales.
- **Planificación de tratamientos:** Modelos predictivos basados en algoritmos de inteligencia artificial que analizan datos médicos, realizan diagnósticos y predicen resultados, ayudando a los médicos a seleccionar el tratamiento más adecuado para cada paciente con base en datos clínicos y genéticos. La personalización de tratamientos mediante IA ofrece numerosos beneficios, como tratamientos más adaptados a las características individuales de cada paciente, lo que aumenta la eficacia y reduce los efectos secundarios.

Figura 1 Tasas de Éxito en Tratamientos Personalizados Asistidos por IA vs Tradicionales.



Este gráfico compara la tasa de éxito de los tratamientos ginecológicos personalizados asistidos por inteligencia artificial frente a los tratamientos tradicionales.

Johnson, L., & Brown, K. (2019). Advances in Robotic-Assisted Gynecologic Surgery. *Obstetrics & Gynecology*, 134(5), 987-993.

Johnson, L. et al. (2019). Personalized Medicine in Gynecology: The Role of AI. *International Journal of Women's Health*, 11, 345-352.

- **Seguimiento personalizado:** Sistemas de IA que monitorizan el progreso de las pacientes y ajustan los tratamientos en función de la respuesta individual. Esto optimiza el uso de recursos médicos, reduciendo costos y la carga para los profesionales, mejorando así la eficiencia del sistema de salud y la experiencia de las pacientes.

A pesar de los beneficios, la implementación de la IA en la personalización de tratamientos plantea varios desafíos éticos y legales:

- **Privacidad de datos y ética:** La recopilación y análisis de datos médicos sensibles requiere medidas estrictas para garantizar la privacidad y seguridad de la información.
- **Responsabilidad médica:** La toma de decisiones asistida por IA plantea interrogantes sobre la responsabilidad en caso de errores o resultados adversos, aunque es fundamental recordar que la IA no reemplaza al profesional, sino que lo asiste.
- **Aceptación por parte de los profesionales:** La integración de la IA en la práctica clínica requiere la aceptación y adaptación por parte de los profesionales de la salud, lo que puede ser un proceso complejo. Es importante considerar que no todos los modelos están validados para todos los entornos o poblaciones.

Este capítulo explora cómo la IA está revolucionando la ginecología, con especial énfasis en la personalización de tratamientos de diferentes patologías ginecológicas y en la asistencia que aporta en la cirugía, concretamente en la robótica.

5.3.2. Cirugía Robótica e IA

La cirugía ginecológica ha experimentado avances significativos en las últimas décadas, especialmente con la incorporación de tecnologías emergentes. La inteligencia artificial (IA) ha comenzado a desempeñar un papel crucial en la mejora de los procedimientos quirúrgicos, ofreciendo nuevas herramientas para la planificación, ejecución y evaluación de las intervenciones.

La IA puede analizar imágenes médicas para identificar estructuras anatómicas y planificar la cirugía de manera más precisa. Esto incluye la predicción de complicaciones y la optimización de los abordajes quirúrgicos.

Durante la cirugía, los sistemas de IA pueden asistir a los cirujanos mediante robots quirúrgicos, navegación quirúrgica y visión computacional. Estos sistemas mejoran la precisión y reducen el riesgo de errores.

La IA también puede ser utilizada para evaluar la recuperación postoperatoria y predecir posibles complicaciones. Los modelos predictivos basados en IA ayudan a personalizar el seguimiento de los pacientes.

Existen múltiples estudios y ensayos clínicos que demuestran la eficacia de la IA en la cirugía ginecológica. Por ejemplo, la utilización de robots quirúrgicos ha mostrado una reducción en el tiempo operatorio y en la pérdida sanguínea.

El futuro de la IA en cirugía ginecológica incluye la integración con tecnologías como la realidad aumentada y los gemelos digitales. La personalización del tratamiento quirúrgico mediante IA generativa y simulación quirúrgica promete revolucionar la práctica médica.

La inteligencia artificial está transformando la cirugía ginecológica, ofreciendo herramientas avanzadas para mejorar la precisión, seguridad y resultados de los procedimientos. Aunque existen desafíos, las perspectivas futuras son prometedoras y apuntan hacia una mayor personalización y eficiencia en el tratamiento quirúrgico.

5.3.2.1. Tratamiento Quirúrgico Asistido por Robótica en Ginecología

La cirugía ginecológica ha experimentado una transformación significativa con la introducción de la robótica. La tecnología robótica ha permitido a los cirujanos realizar procedimientos complejos con mayor precisión, flexibilidad y control.

Las aplicaciones de la robótica en la cirugía ginecológica son diversas y abarcan una amplia gama de procedimientos. Entre las intervenciones más comunes se incluyen la histerectomía, la miomectomía, la sacrocolpopexia y la linfadenectomía. La cirugía robótica ofrece numerosas ventajas sobre las técnicas laparoscópicas y abiertas tradicionales.

La integración de la inteligencia artificial en la cirugía robótica está revolucionando la medicina moderna. Es posible realizar una planificación quirúrgica personalizada gracias al aprendizaje automático.

Los sistemas de IA pueden:

- Analizar imágenes médicas.
- Identificar estructuras anatómicas con precisión.
- Simular diferentes escenarios quirúrgicos.
- Sugerir rutas de acceso óptimas y estrategias quirúrgicas personalizadas para cada paciente.

Además, durante la cirugía, los robots como el sistema Da Vinci actúan como extensiones del cirujano, y con la IA se podría proporcionar asistencia intraoperatoria inteligente, al:

- Detectar patrones de riesgo en tiempo real.
- Alertar al cirujano ante posibles errores o complicaciones, como sangrados o lesiones nerviosas.
- Ajustar automáticamente la trayectoria de los instrumentos para mejorar la precisión.

Por otro lado, con la IA se consigue que los robots obtengan mayor autonomía. Aunque aún requieren supervisión humana, se están desarrollando sistemas que permiten:

- Aprender de cirugías anteriores para mejorar su rendimiento.
- Colaborar con el cirujano en tiempo real, como un copiloto quirúrgico.

Entre las principales ventajas se incluyen:


- Mayor precisión y control, y menor margen de error.
- Reducción del tiempo quirúrgico y de la estancia hospitalaria por tiempos de recuperación más rápidos.
- Mejor visualización de las estructuras anatómicas y acceso a zonas complejas con mínima invasión.
- Menos complicaciones postoperatorias, menor pérdida de sangre y menor dolor postoperatorio.

A pesar de sus numerosas ventajas, la cirugía robótica también presenta algunas limitaciones:

- Alto costo de los equipos y mantenimiento.
- Necesidad de formación especializada para los cirujanos.
- Tiempo de operación más largo en algunos casos.
- Falta de regulación clara sobre autonomía quirúrgica.
- Disponibilidad limitada en algunos centros médicos y países en desarrollo.

Numerosos estudios han evaluado la eficacia y seguridad de la cirugía robótica en ginecología. La evidencia científica sugiere que la cirugía robótica es comparable o superior a las técnicas tradicionales en términos de resultados quirúrgicos y recuperación de la paciente. Por ejemplo, un estudio reciente encontró que la histerectomía robótica se asocia con una menor tasa de complicaciones en comparación con la histerectomía laparoscópica convencional.

Figura 2: Tasas de Complicaciones en Diferentes Tipos de Cirugía Ginecológica



Este gráfico muestra la tasa de complicaciones asociadas a tres tipos de cirugía ginecológica: robótica, laparoscópica y abierta.

Johnson, L., & Brown, K. (2019). Advances in Robotic-Assisted Gynecologic Surgery. *Obstetrics & Gynecology*, 134(5), 987

5.3.2.2. Tecnologías Emergentes en Cirugía Robótica

Visión Computacional y Realidad Aumentada. La visión computacional y la realidad aumentada (RA) combinadas con inteligencia artificial (IA) están revolucionando la cirugía robótica, aportando precisión, seguridad y capacidades predictivas sin precedentes.

La visión computacional permite a los sistemas robóticos:

- Interpretar imágenes médicas en tiempo real, como resonancias magnéticas, tomografías o imágenes de cámaras endoscópicas. Sus aplicaciones incluyen:
 - Reconocimiento de tejidos y estructuras anatómicas: ayuda a identificar órganos, vasos sanguíneos o tumores con alta precisión.
 - Seguimiento de instrumentos quirúrgicos: mejora la coordinación entre el robot y el cirujano.
 - Detección de riesgos: algoritmos de IA pueden alertar sobre posibles errores o movimientos peligrosos durante la operación.

Realidad Aumentada (RA) en Cirugía Robótica. La RA superpone información digital (como modelos 3D de órganos o trayectorias quirúrgicas) sobre la visión del cirujano. Esto permite:

- Planificación quirúrgica avanzada: el cirujano puede visualizar el procedimiento antes de realizarlo.
- Guía intraoperatoria: durante la cirugía, la RA muestra rutas seguras para evitar estructuras críticas.
- Entrenamiento médico: los residentes pueden practicar con simulaciones hiperrealistas.

IA como Motor de Integración. La inteligencia artificial actúa como el “cerebro” que une la visión computacional y la RA, permitiendo:

- Análisis predictivo: anticipa complicaciones basándose en datos históricos y en tiempo real.
- Asistencia autónoma: algunos sistemas pueden sugerir o incluso ejecutar movimientos quirúrgicos simples bajo supervisión humana.
- Personalización del tratamiento: adapta la cirugía a la anatomía específica de la paciente.

5.3.2.3. Cirugías Autónomas Asistidas por IA

Las cirugías autónomas robóticas asistidas por inteligencia artificial (IA) en ginecología están avanzando rápidamente, combinando precisión tecnológica con capacidades de aprendizaje automático para mejorar los resultados quirúrgicos.

Son procedimientos quirúrgicos realizados con la ayuda de sistemas robóticos que integran algoritmos de IA para asistir, guiar o incluso ejecutar tareas quirúrgicas con mínima intervención humana. En ginecología, esto se aplica a procedimientos como histerectomías, miomectomías, endometriosis profunda y cirugías oncológicas.

El sistema Da Vinci, por ejemplo, sigue siendo el más utilizado. Aunque no es completamente autónomo, ya incorpora funciones de asistencia inteligente, como estabilización de instrumentos y filtrado de temblores.

Avances recientes con IA:

- **Asistencia predictiva:** Los robots pueden alertar al cirujano sobre posibles riesgos durante la operación, como sangrados o errores anatómicos, gracias al análisis en tiempo real de imágenes y datos quirúrgicos.

- **Aprendizaje automático:** Algunos sistemas están siendo entrenados con miles de videos quirúrgicos para aprender patrones y sugerir mejores rutas quirúrgicas o técnicas de sutura.
- **Cirugía remota y telesupervisión:** Se están desarrollando plataformas que permiten a expertos supervisar o incluso intervenir remotamente en cirugías realizadas por robots en zonas rurales o de difícil acceso.

5.3.3. IA en el Tratamiento de Enfermedades Ginecológicas

La inteligencia artificial (IA) está revolucionando la práctica médica en todas sus especialidades, incluyendo la ginecología. Esta disciplina, centrada en la salud reproductiva femenina, ha comenzado a beneficiarse de algoritmos de aprendizaje automático, modelos predictivos y sistemas de apoyo a decisiones clínicas que mejoran la precisión diagnóstica y terapéutica en contextos como el diagnóstico de patologías ginecológicas y la medicina reproductiva.

5.3.3.1. Endometriosis

La IA analiza síntomas, imágenes médicas y datos clínicos para facilitar un diagnóstico más rápido y preciso, reduciendo la necesidad de procedimientos invasivos.

- **Diagnóstico asistido por IA:** Algoritmos que procesan síntomas, ecografías y resonancias.
- En algunos casos, la IA puede ayudar a evitar laparoscopias innecesarias.
- La IA también optimiza decisiones sobre medicamentos hormonales o cirugía.

5.3.3.2. Síndrome de Ovario Poliquístico (SOP)

Algoritmos de IA ayudan a identificar patrones hormonales y metabólicos complejos, personalizando tratamientos según las características individuales de cada paciente.

- Personalizan el tratamiento según el fenotipo: metabólico, reproductivo, estético, etc.

5.3.3.3. Miomas

La IA puede analizar resonancias o ecografías para:

- Clasificar los miomas según su localización e impacto.
- Sugerir si se requiere cirugía, embolización o tratamiento farmacológico (Ej.: ulipristal).

5.3.3.4. Infecciones

Algoritmos analizan resultados de microbiomas vaginales y síntomas autoinformados para recomendar el tratamiento antifúngico o antibiótico más adecuado.

5.3.3.5. Cáncer Ginecológico

La IA mejora la detección temprana y la planificación de tratamientos personalizados, optimizando la respuesta a terapias como la quimioterapia y la radioterapia. Una de las aplicaciones más estudiadas es el uso de IA en el diagnóstico precoz del cáncer cérvico-uterino. Algoritmos de visión computacional entrenados con miles de imágenes de colposcopia y citologías han demostrado alta sensibilidad y especificidad en la detección de lesiones intraepiteliales de alto grado [2]. Estudios recientes indican que el uso de redes neuronales convolucionales (CNN) puede igualar o superar a expertos en la interpretación de imágenes colposcópicas [2].

Otras aplicaciones incluyen:

- Predicción de la respuesta a quimioterapia o radioterapia.
- Asistencia en decisiones de cirugía conservadora (por ejemplo, en cáncer de cuello uterino temprano).
- Modelos de pronóstico de supervivencia y recurrencia.

5.3.4. Consideraciones Éticas y Futuro de la IA en Ginecología

El uso de IA plantea dilemas éticos sobre la privacidad de los datos, el consentimiento informado y la responsabilidad legal en caso de errores diagnósticos. Se necesitan marcos regulatorios claros; las guías internacionales, como las propuestas por la OMS y la Unión Europea, buscan establecer marcos éticos y regulatorios para el uso seguro y equitativo de estas tecnologías [7]. Además, hay que considerar que la IA complementa, no reemplaza, el juicio clínico y requiere una formación continua de los profesionales.

5.3.5. Futuro de la IA en la Práctica Ginecológica

Se espera que en los próximos años surjan sistemas más autónomos, capaces de realizar tareas quirúrgicas específicas sin intervención humana directa, siempre bajo supervisión médica. También se prevé una mayor integración con tecnologías como la realidad aumentada y los gemelos digitales para planificar y simular cirugías antes de realizarlas.

El futuro de la cirugía robótica en ginecología es prometedor. Se espera que los avances en inteligencia artificial y aprendizaje automático mejoren aún más la precisión y eficiencia de los procedimientos robóticos. Además, la integración de la realidad aumentada y la simulación virtual podría proporcionar a los cirujanos herramientas adicionales para planificar y ejecutar procedimientos complejos. La personalización del tratamiento quirúrgico mediante el uso de gemelos digitales y modelos predictivos también representa un área de investigación emergente.

5.3.6. Conclusiones

La inteligencia artificial está redefiniendo la ginecología moderna, desde el diagnóstico hasta la cirugía. Aunque persisten desafíos éticos, técnicos y regulatorios, su implementación responsable promete mejorar significativamente la atención médica y la calidad de vida de las pacientes.

Bibliografía

1. Sengupta P, Dutta S, Bagchi S, Hegde P, Sebastian S, Taylor DCM, Henkel R. Strategic Guidelines to Integrate Artificial Intelligence in Obstetrics and Gynecology: Best Practices and Ethical Considerations. *Reprod Sci*. 2025 Jun; DOI: 10.1007/s43032-025-01903-w
2. Zhang L, et al. Cervical cancer diagnosis using deep learning and CNNs. *J Biomed Inform*. 2020;103:103383.
3. Tran D, Cooke S, Illingworth PJ. Artificial intelligence-assisted embryo selection: a systematic review. *Hum Reprod Update*. 2021;27(4):599-619.
4. Liu Y, et al. Early prediction of preeclampsia with machine learning. *Am J Obstet Gynecol*. 2019;220(4):382.e1-382.e11.
5. Hung AJ, et al. Robotic surgery: role of artificial intelligence. *Urol Clin North Am*. 2020;47(3):359-366.
6. Esteva A, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542(7639):115-118.
7. Williams K, et al. Ethical Considerations in AI-Assisted Gynecological Treatments. *Bioethics*. 2021;35(2):89-98.
8. Johnson L, et al. Personalized Medicine in Gynecology: The Role of AI. *Int J Womens Health*. 2019;11:345-352.
9. Smith J, et al. Artificial Intelligence in Gynecology: Current Applications and Future Directions. *J Gynecol Surg*. 2020;36(4):123-130.

10. Hammer HL, Thambawita V, Riegler MA. Foundation models: the next level of AI in ART. *Human Reproduction* [Internet]. 2025 Jul 15; Available from: <https://academic.oup.com/humrep/advance-article/doi/10.1093/hum-rep/deaf136/8203021>
11. Curchoe CL. Proceedings of the first world conference on AI in fertility. Vol. 40, *Journal of Assisted Reproduction and Genetics*. Springer; 2023. p. 215–22.
12. Olawade DB, Teke J, Adeleye KK, Weerasinghe K, Maidoki M, Clement David-Olawade A. Artificial intelligence in in-vitro fertilization (IVF): A new era of precision and personalization in fertility treatments. Vol. 54, *Journal of Gynecology Obstetrics and Human Reproduction*. Elsevier Masson s.r.l.; 2025.
13. Wu YC, Chia-Yu Su E, Hou JH, Lin CJ, Lin KB, Chen CH. Artificial intelligence and assisted reproductive technology: A comprehensive systematic review. Vol. 64, *Taiwanese Journal of Obstetrics and Gynecology*. Elsevier Ltd; 2025. p. 11–26.
14. Raimundo JM, Cabrita P. Artificial intelligence at assisted reproductive technology. In: *Procedia Computer Science*. Elsevier B.V.; 2021. p. 442–7.
15. Riegler MA, Stensen MH, Witczak O, Andersen JM, Hicks SA, Hammer HL, et al. Artificial intelligence in the fertility clinic: Status, pitfalls and possibilities. Vol. 36, *Human Reproduction*. Oxford University Press; 2021. p. 2429–42.
16. Letterie G. Artificial intelligence and assisted reproductive technologies: 2023. Ready for prime time? Or not. Vol. 120, *Fertility and Sterility*. Elsevier Inc.; 2023. p. 32–7.
17. Cohen J, Silvestri G, Paredes O, Martin-Alcala HE, Chavez-Badiola A, Alikani M, et al. Artificial intelligence in assisted reproductive technology: separating the dream from reality. Vol. 50, *Reproductive BioMedicine Online*. Elsevier Ltd; 2025.
18. Zieliński K, Puksza S, Mickiewicz M, Kotlarz M, Wygocki P, Zieleń M, et al. Personalized prediction of the secondary oocytes number after ovarian stimulation: A machine learning model based on clinical and genetic data. *PLoS Comput Biol*. 2023 Apr 1;19(4).
19. Hariton E, Pavlovic Z, Fanton M, Jiang VS. Applications of artificial intelligence in ovarian stimulation: a tool for improving efficiency and outcomes. Vol. 120, *Fertility and Sterility*. Elsevier Inc.; 2023. p. 8–16.
20. Correa N, Cerquides J, Arcos JL, Vassena R. Supporting first FSH dosage for ovarian stimulation with machine learning. *Reprod Biomed Online*. 2022 Nov 1;45(5):1039–45.
21. Fanton M, Nutting V, Rothman A, Maeder-York P, Hariton E, Barash O, et al. An interpretable machine learning model for individualized gonadotrophin starting dose selection during ovarian stimulation. *Reprod Biomed Online*. 2022 Dec 1;45(6):1152–9.
22. Bixby CJ, Miller B. Real-world use of an artificial intelligence–powered clinical decision support tool for ovarian stimulation. *F and S Reports*. 2025 Jun 1;6(2):140–6.
23. Murillo F, Fanton M, Baker VL, Loewke K. Causal inference indicates that poor responders have similar outcomes with the antagonist protocol compared with flare. *Fertil Steril*. 2023 Aug 1;120(2):289–96.
24. Wald K, Hariton E, Morris JR, Chi EA, Jaswa EG, Cedars MI, et al. Changing stimulation protocol on repeat conventional ovarian stimulation cycles does not lead to improved laboratory outcomes. *Fertil Steril*. 2021 Sep 1;116(3):757–65.
25. Quaas AM. Ovarian stimulation protocols: Don't immediately change a losing team. Vol. 116, *Fertility and Sterility*. Elsevier Inc.; 2021. p. 664–5.
26. Shapiro BS, Rasouli MA, Verma K, Raman A, Garner FC, Aguirre M, et al. The effect of ovarian follicle size on oocyte and embryology outcomes. *Fertil Steril*. 2022 Jun 1;117(6):1170–6.
27. Liu G, Huang W, Li Y, Zhang Q, Fu J, Tang H, et al. A weakly-supervised follicle segmentation method in ultrasound images. *Sci Rep*. 2025 Dec 1;15(1).
28. Liang X, Liang J, Zeng F, Lin Y, Li Y, Cai K, et al. Evaluation of oocyte maturity using artificial intelligence quantification of follicle volume biomarker by three-dimensional ultrasound. *Reprod Biomed Online*. 2022 Dec 1;45(6):1197–206.
29. Hariton E, Chi EA, Chi G, Morris JR, Braatz J, Rajpurkar P, et al. A machine learning algorithm can optimize the day of trigger to improve in vitro fertilization outcomes. *Fertil Steril*. 2021 Nov 1;116(5):1227–35.
30. Letterie G, MacDonald A, Shi Z. An artificial intelligence platform to optimize workflow during ovarian stimulation and IVF: process improvement and outcome-based predictions. *Reprod Biomed Online* [Internet]. 2022 Feb 1 [cited 2025 Sep 13];44(2):254–60. Available from: <https://www.sciencedirect.com/science/article/abs/pii/S1472648321005186>
31. Mapari SA, Shrivastava D, Bedi GN, Pradeep U, Gupta A, Kasat PR, et al. Revolutionizing Reproduction: The Impact of Robotics and Artificial Intelligence (AI) in Assisted Reproductive Technology: A Comprehensive Review. *Cureus*. 2024 Jun 25;

32. Naik N, Roth B, Lundy SD. Artificial Intelligence for Clinical Management of Male Infertility, a Scoping Review. Vol. 26, *Current Urology Reports*. Springer; 2025.
33. Kılıç Ş. Deep feature engineering for accurate sperm morphology classification using CBAM-enhanced ResNet50. Shaikh A, editor. *PLoS One* [Internet]. 2025 Sep 10;20(9):e0330914. Available from: <https://dx.plos.org/10.1371/journal.pone.0330914>
34. Jaruenpunyasak J, Maneelert P, Nawae M, Choksuchat C. Artificial intelligence model for the assessment of unstained live sperm morphology. *Reproduction & fertility*. 2025 Apr 1;6(2).
35. Qaderi K, Sharifipour F, Dabir M, Shams R, Behmanesh A. Artificial intelligence (AI) approaches to male infertility in IVF: a mapping review. *Eur J Med Res*. 2025 Apr 5;30(1).
36. Lustgarten Guahmich N, Borini E, Zaninovic N. Improving outcomes of assisted reproductive technologies using artificial intelligence for sperm selection. Vol. 120, *Fertility and Sterility*. Elsevier Inc.; 2023. p. 729–34.
37. Tsai VFS, Zhuang B, Pong YH, Hsieh JT, Chang HC. Web- And artificial intelligence–based image recognition for sperm motility analysis: Verification study. *JMIR Med Inform*. 2020 Nov 1;8(11).
38. Montjean D, Godin Pagé MH, Pacios C, Calvé A, Hamiche G, Benkhalifa M, et al. Automated Single-Sperm Selection Software (SiD) during ICSI: A Prospective Sibling Oocyte Evaluation. *Medical sciences*. 2024 Jun 1;12(2).
39. Boylan CF, Sambo KM, Neal-Perry G, Brayboy LM. Ex ovo omnia—why don't we know more about egg quality via imaging? *Biol Reprod*. 2024 Jun 1;110(6):1201–12.
40. Keefe D, Liu L, Wang W, Silva C. Imaging meiotic spindles by polarization light microscopy: Principles and applications to IVF. Vol. 7, *Reproductive BioMedicine Online*. Reproductive Healthcare Ltd; 2003. p. 24–9.
41. Balaban B, Brison D, Calderón G, Catt J, Conaghan J, Cowan L, et al. The Istanbul consensus workshop on embryo assessment: Proceedings of an expert meeting. In: *Human Reproduction*. Oxford University Press; 2011. p. 1270–83.
42. del Arco de la Paz A, Giménez-Rodríguez C, Selntigia A, Meseguer M, Galliano D. Advancements and Challenges in Preimplantation Genetic Testing for Aneuploidies: In the Pathway to Non-Invasive Techniques. Vol. 15, *Genes*. Multidisciplinary Digital Publishing Institute (MDPI); 2024.
43. Diakiw SM, Hall JMM, VerMilyea MD, Amin J, Aizpurua J, Giardini L, et al. Development of an artificial intelligence model for predicting the likelihood of human embryo euploidy based on blastocyst images from multiple imaging systems during IVF. *Human Reproduction*. 2022 Aug 1;37(8):1746–59.
44. Barnes J, Brendel M, Gao VR, Rajendran S, Kim J, Li Q, et al. A non-invasive artificial intelligence approach for the prediction of human blastocyst ploidy: a retrospective model development and validation study. *Lancet Digit Health*. 2023 Jan 1;5(1):e28–40.
45. Lee T, Natalwala J, Chapple V, Liu Y. A brief history of artificial intelligence embryo selection: From black-box to glass-box. Vol. 39, *Human Reproduction*. Oxford University Press; 2024. p. 285–92.
46. Koplin JJ, Johnston M, Webb ANS, Whittaker A, Mills C. Ethics of artificial intelligence in embryo assessment: mapping the terrain. Vol. 40, *Human Reproduction*. Oxford University Press; 2025. p. 179–85.

6. PROCESAMIENTO DE IMÁGENES MÉDICAS CON IA

6. Procesamiento de imágenes médicas con IA

Dr. Pablo Naval Baudín^{1,2,3}
Dra. Nadine Romera Lobato¹

1. Servicio de Radiología, Hospital Quironsalud Barcelona, Barcelona 08023, España.
2. Translational Imaging Biomarkers Group, Institut D'Investigació Biomèdica de Bellvitge (IDIBELL), L'Hospitalet de Llobregat, 08907, Barcelona, España.
3. Departamento de Ciencias Clínicas, Facultad de Medicina, Universitat de Barcelona (UB), L'Hospitalet de Llobregat 08907, Barcelona, España.
4. Institut de Diagnòstic Per La Imatge (IDI), Centre Bellvitge, L'Hospitalet de Llobregat, 08907, Barcelona, España.

Correspondencia:

Pablo Naval Baudín
Servicio de Radiología,
Hospital Quironsalud Barcelona
Barcelona 08023, España.
pablo.naval@quironsalud.es

Abreviaturas:

Resonancia Magnética (RM); Coeficiente de Difusión Aparente (ADC, del inglés *Apparent Diffusion Coefficient*); Región de Interés (ROI, del inglés *Region of Interest*); Inteligencia Artificial (IA); Red Neuronal Convolutiva (CNN, del inglés *Convolutional Neural Network*); Segment Anything Model (SAM); Criterios de Evaluación de Respuesta en Tumores Sólidos (RECIST, del inglés *Response Evaluation Criteria in Solid Tumors*); Radioterapia (RT); Tomografía Computarizada (TC); Vision Transformer (ViT); Intersección sobre Unión (IoU, del inglés *Intersection over Union*); Error de Volumen Relativo (RVE, del inglés *Relative Volume Error*).

6.1. Introducción

La segmentación de imágenes médicas es el proceso de etiquetar cada elemento de una imagen (píxel en imágenes 2D, vóxel en escaneos 3D) según el tejido o la estructura que representa. En otras palabras, la segmentación divide una imagen en regiones de tal manera que cada región corresponde a una estructura anatómica o patología particular. Por ejemplo, una resonancia magnética de la pelvis podría segmentarse para clasificar cada vóxel como tumor, útero, vejiga, recto, entre otros. Este etiquetado a nivel de píxel proporciona un mapa detallado de la ubicación de los diferentes tejidos y lesiones, lo que constituye la base para mediciones y análisis precisos.

Un concepto importante es la distinción entre límites anatómicos duros y blandos. Los límites duros son aquellos con una transición clara y nítida entre tejidos, por ejemplo, la interfaz entre el aire y el tejido pulmonar en una tomografía computarizada o la delineación de un órgano con un plano de grasa circundante. En estos casos, los algoritmos de segmentación (o un experto humano) suelen dibujar una línea bastante definida alrededor de la estructura.

Por el contrario, los límites blandos se producen cuando la transición entre los tejidos es gradual o mal definida. Un ejemplo práctico es la frontera entre el endometrio y el miometrio en el útero en la resonancia magnética: el cambio del revestimiento interno a la pared muscular es sutil, con intensidades de señal similares que se mezclan entre sí¹. Estos límites ambiguos o de bajo contraste plantean un mayor desafío para los métodos de segmentación². El proceso de segmentación debe lidiar con tal incertidumbre y, a menudo,

la "verdad fundamental" de dónde termina un tejido y comienza otro puede ser algo subjetivo, incluso entre los expertos.

La segmentación es una forma de anotación de las imágenes. En la segmentación manual, un anotador dibuja contornos alrededor de un tumor u órgano en cada corte de una imagen, creando así una máscara etiquetada. Este contorno manual es la forma tradicional de delinear tumores o estructuras, por ejemplo, para la planificación del tratamiento o el análisis volumétrico³. La segmentación manual sigue siendo común y necesaria, pero es laboriosa, requiere mucho tiempo y plantea problemas de variabilidad inter-anotador. Los contornos manuales pueden variar de un experto a otro. Es importante valorar siempre esta variabilidad inter-anotador en cualquier métrica obtenida a través de una segmentación. Por ejemplo, los parámetros radiómicos son cuantitativos y, por ello, se podría pensar que son robustos. No obstante, el resultado de estas métricas también es susceptible a diferencias entre observadores en la segmentación⁴. Por estas razones, los protocolos de anotación coherentes y las herramientas de segmentación automatizadas son cada vez más importantes.

Más allá de ser un fin en sí misma, la segmentación suele ser el primer paso para análisis posteriores. En el campo emergente de la radiómica, se extraen cientos de características cuantitativas (como descriptores de textura o forma) de las imágenes médicas, calculadas dentro de una región de interés que corresponde a la patología de interés³. Un flujo de trabajo típico de radiómica comienza con la adquisición de imágenes seguida de la segmentación, tras la cual se calculan las características a partir de la región segmentada⁴. Por ejemplo, en las imágenes de RM de difusión se puede extraer el coeficiente de difusión aparente (ADC), una métrica cuantitativa muy utilizada en la práctica clínica. Esta métrica se obtiene promediando el valor del mapa en una segmentación de un tumor en una secuencia de difusión de resonancia magnética. Por ello, es necesario delinear primero la región del tumor en el mapa de ADC; de lo contrario, el "ADC promedio" podría diluirse por los tejidos circundantes⁵.

La segmentación también es fundamental para muchas aplicaciones de inteligencia artificial (IA) y aprendizaje automático en imágenes. Por un lado, las imágenes segmentadas manualmente sirven como datos de entrenamiento para los algoritmos de aprendizaje supervisado: se utilizan grandes conjuntos de imágenes segmentadas para entrenar modelos de IA para reconocer tumores u órganos. Sin anotaciones fiables, los algoritmos de IA a menudo no pueden aprender de forma eficaz. En otro aspecto, la segmentación en sí misma puede ser el resultado de un sistema de IA: por ejemplo, un modelo de aprendizaje profundo podría segmentar automáticamente un tumor de ovario en una resonancia magnética. Las tareas posteriores, como la detección, la clasificación o incluso la robótica quirúrgica, se benefician de la localización precisa de las estructuras que proporciona la segmentación. Por ejemplo, un sistema de navegación o de realidad aumentada en el quirófano debe saber dónde están el tumor y las estructuras críticas, información que proviene de la segmentación de imágenes preoperatorias. De hecho, la segmentación de imágenes en medicina se utiliza para una amplia gama de aplicaciones que, en última instancia, tienen un impacto en la atención del paciente: ayuda a localizar estructuras y tumores y delinear su extensión, cuantificar volúmenes de tejido, planificar cirugías, guiar la navegación intraoperatoria y delinear objetivos para terapias como la radiación⁶.

Desde una perspectiva clínica, ¿por qué los lectores clínicos deberían preocuparse por la segmentación? Primero, porque permite la obtención de imágenes cuantitativas. Por ejemplo, en el seguimiento longitudinal, en lugar de descriptores vagos como "el tumor ha disminuido de tamaño" o métricas subrogadas simples como diámetros únicos o perpendiculares en un único plano⁷, que pueden llevar a error en casos de morfologías irregulares o diferencias de plano⁸, la segmentación permite expresar de manera más objetiva la variación específica del volumen de una lesión. Además, la segmentación informa la planificación quirúrgica y de radioterapia (RT). Finalmente, abre la puerta a análisis avanzados como la radiómica o el modelado computacional que pueden correlacionar patrones de imagen con genómica o resultados.

6.2. Evolución y contexto histórico

El campo de la segmentación de imágenes ha evolucionado a lo largo de décadas. Evidentemente, la introducción de la segmentación fue con la segmentación manual. Si bien se considera el "estándar de oro" para la precisión, la segmentación manual requiere mucho tiempo y no es escalable cuando se trata de muchas imágenes o grandes volúmenes 3D3.

Para ayudar en este proceso, cada vez más, se incorporan algoritmos computacionales. Estos incluyen técnicas simples como el umbral de intensidad (división de píxeles en objeto frente a fondo en función de un umbral específico máximo o mínimo de intensidad), algoritmos de "crecimiento de región" (*region growing*) (que comienzan desde un punto de "semilla" y expanden una región agregando píxeles vecinos con propiedades similares) y la detección de bordes o modelos de contorno activos (como el algoritmo de "serpientes" o *snakes* que deforma iterativamente una curva para bloquearla en los bordes de la imagen)⁹.

Al entrar en la década de 2000, a medida que crecía la potencia informática, hubo interés en una segmentación más automatizada y surgieron varios modelos estadísticos y basados en atlas anatómicos ⁵. Por ejemplo, en algunas aplicaciones, una imagen de atlas preetiquetada (como una resonancia magnética con órganos ya delineados) se deforma para adaptarla a la exploración de un nuevo paciente, transfiriendo las etiquetas de segmentación definidas en un espacio estándar del atlas anatómico. Tales métodos tuvieron cierto éxito para segmentar órganos sanos con una anatomía consistente como el cerebro, pero menos para tumores, órganos patológicos o con una morfología muy variable.

La verdadera revolución se produjo con la llegada del aprendizaje profundo, en particular las redes neuronales convolucionales (CNN). En 2015, la introducción de la arquitectura U-Net, una CNN adaptada a la segmentación de imágenes biomédicas, demostró un rendimiento drásticamente mejorado, incluso con datos de entrenamiento relativamente limitados ¹⁰. Básicamente, los modelos de aprendizaje profundo aprenden a clasificar cada píxel/vóxel como tumoral frente a normal (o cualquier clase de interés) entrenándose con muchos ejemplos de imágenes segmentadas manualmente. Capturan de manera efectiva patrones complejos de textura, intensidad y forma con los que los algoritmos clásicos tenían problemas. Hoy en día, las variantes de U-Net y otras redes profundas forman la columna vertebral de la mayoría de las herramientas de segmentación de última generación ¹¹. La segmentación automatizada mediante redes profundas ya se ha abierto camino en la investigación y, en algunos casos, en la práctica clínica (por ejemplo, herramientas de detección automática de lesiones ^{12,13}). Estos modelos pueden acelerar significativamente el proceso y generar una segmentación inicial en segundos, que un clínico puede refinar si es necesario. Sin embargo, incluso el aprendizaje profundo tiene desafíos: los modelos entrenados con los datos de un hospital pueden fallar con los de otro debido a diferencias en los escáneres o protocolos; la generalización sigue siendo un problema ⁴.

Una frontera más reciente, que actualmente está en pleno desarrollo, es el uso de los modelos fundacionales (*foundation models* en inglés) en imágenes. Los modelos fundacionales son grandes modelos de IA entrenados en conjuntos de datos masivos, diseñados para ser de propósito general en muchas tareas ¹⁴. Un buen ejemplo en el ámbito de la segmentación es el Segment Anything Model (SAM) de Meta AI ¹⁵. SAM se entrenó con más de mil millones de máscaras de segmentación de imágenes naturales y es capaz de producir segmentaciones de objetos en imágenes basadas en indicaciones (como puntos o cuadros proporcionados por el usuario) ¹⁵. La idea es que un modelo de este tipo (fundacional), con un entrenamiento adicional mínimo, podría adaptarse a las imágenes médicas, lo que podría permitir que un modelo maneje muchas tareas de segmentación (desde órganos hasta tumores) sin necesidad de una IA personalizada para cada una. Se trata de un cambio significativo con respecto a la norma actual de modelos de tareas específicas, y es prometedor para el futuro. Se han creado modelos fundacionales de bases médicas especializadas (como "MedSAM") ajustando SAM en datos médicos para mejorar su rendimiento en áreas como RM y TC2. En un futuro próximo, es concebible que un anotador pueda cargar cualquier escaneo pélvico en un sistema de software y, con un clic, obtener segmentaciones instantáneas y de alta calidad de todas las estructuras relevantes, impulsadas por una sólida IA de base que ha "visto" millones de ejemplos, pero prácticamente sin entrenamiento específico.

6.3. Aplicaciones clínicas

Pero, ¿cuál es la importancia práctica de la segmentación? En medicina, los profesionales de la salud a menudo deben tomar decisiones clínicas basadas en imágenes: decisiones sobre la respuesta al tratamiento, la planificación quirúrgica o la orientación de la radiación. La segmentación de imágenes nos permite obtener medidas más objetivas y precisas de varias maneras clave:

1. Seguimiento longitudinal con volumetría:

En oncología, el tamaño de un tumor es un indicador clave para la estadificación y la respuesta. El estándar predominante en los ensayos clínicos y en la práctica oncológica ha sido RECIST (*Response Evaluation Criteria in Solid Tumors*), que utiliza mediciones unidimensionales (esencialmente el diámetro más largo del tumor en un corte de imagen) para categorizar la respuesta (enfermedad completa, parcial, estable o progresiva)⁷. Si bien esta técnica es simple y reproducible, sólo proporciona una instantánea del tamaño del tumor en un solo plano. La segmentación permite la medición volumétrica de los tumores, lo que captura todo el tamaño tridimensional de la lesión en lugar de un solo diámetro de corte⁸. Esto puede ser crucial, ya que los tumores a menudo tienen formas irregulares. Las técnicas basadas en diámetros únicos o perpendiculares presentan algunas limitaciones: (1) no pueden representar completamente los cambios volumétricos en el tamaño del tumor y (2) por lo general rastrean solo unas pocas lesiones objetivo, lo que podría pasar por alto otras localizaciones de la enfermedad¹⁶. La segmentación volumétrica supera estos problemas al tener en cuenta toda la carga tumoral^{16,17}. En resumen, la volumetría basada en segmentación proporciona una imagen más completa y precisa del tamaño del tumor y sus cambios a lo largo del tiempo^{16,17}.

2. Métricas cuantitativas:

Las técnicas modernas de imagen van más allá de las representaciones anatómicas y proporcionan mapas cuantitativos o funcionales. Un ejemplo común es la resonancia magnética de difusión, que produce (entre otros) el mapa del coeficiente de difusión aparente (ADC) que refleja la movilidad de las moléculas de agua en el tejido (inversamente relacionada con la celularidad de los tejidos). Al delinear el tumor y aplicar la máscara de segmentación al mapa cuantitativo, se pueden calcular métricas como la media de ADC del tumor, el histograma de los valores de ADC, con valores máximos, mínimos, percentiles, sesgo, entropía, etc., o incluso métricas de textura. Estos valores pueden servir como biomarcadores de imagen. Es importante tener en cuenta que la estrategia de segmentación puede afectar notablemente a los valores derivados, por ejemplo, la inclusión de áreas necróticas o edema adyacente en la ROI cambiará el ADC medio¹⁸. Por lo tanto, se necesita una segmentación cuidadosa y coherente para realizar un seguimiento fiable de estos parámetros.

3. Definición del objetivo de la radioterapia:

Quizás uno de los usos más gráficos de la segmentación es en la planificación de la radioterapia. En un paciente candidato a radioterapia (RT), el primer paso en la planificación es definir los volúmenes objetivo en las imágenes, por lo general, una tomografía computarizada o una resonancia magnética que se utilizan para la planificación. Se segmenta el volumen tumoral bruto (el tumor visible) y, a partir de ahí, se define el volumen clínico objetivo y los órganos en riesgo que deben preservarse¹⁹. La máquina de tratamiento dirige la radiación donde se indique que está el tumor²⁰. La segmentación tumoral es un paso fundamental para la planificación de la RT: una delineación precisa del tumor primario garantiza que la dosis de radiación cubra el tumor por completo y minimice la exposición a tejidos sanos. Si la segmentación es demasiado amplia (sobrepasando el tejido normal), se pueden lesionar tejidos sanos, pero si es demasiado ajustada, puede no tratar efectivamente. La segmentación en las imágenes permite crear campos de tratamiento precisos e individualizados^{21,22}.

4. Planificación y navegación quirúrgica:

En cirugía tumoral, la segmentación también puede proporcionar un mapa de la extensión del tumor en relación con otras estructuras anatómicas. Además, la segmentación ayuda a la planificación quirúrgica en general. Se puede utilizar para crear modelos impresos en 3D o reconstrucciones de realidad

aumentada del tumor y los órganos de un paciente, que pueden utilizarse para el ensayo o la orientación intraoperatoria ²³. Todas estas aplicaciones se derivan de tener primero algún tipo de segmentación precisa del tumor y de la anatomía relevante.

6.4. Diferentes enfoques de segmentación

6.4.1. Segmentación manual

La delineación manual de estructuras por parte de expertos humanos es el método de referencia para la segmentación de imágenes médicas. El anotador utiliza un software para pintar o trazar regiones de interés corte por corte. Estas máscaras dibujadas manualmente a menudo sirven como la "verdad fundamental" (*ground truth*) para evaluar otros métodos.

A pesar de su precisión, la segmentación manual requiere mucho trabajo y tiempo. El proceso también es subjetivo: diferentes expertos (o incluso el mismo experto en diferentes momentos) pueden producir segmentaciones ligeramente diferentes de la misma imagen, con una cierta variabilidad inter e intraobservador ²⁴. Estos inconvenientes (lentitud, alto costo y variabilidad) motivan el uso de métodos (semi)automatizados como alternativas o ayudas.

6.4.2. Segmentación semiautomatizada

Los enfoques semiautomatizados combinan la entrada del usuario con la asistencia algorítmica, con el objetivo de reducir el esfuerzo manual y, al mismo tiempo, aprovechar la orientación de los expertos. En estos métodos, un operador suele proporcionar alguna inicialización (como un punto de semilla, un resaltado de región o una configuración de parámetros) y el software expande o refina la segmentación a partir de ahí. Este proceso interactivo es más rápido que el dibujo puramente manual y puede manejar partes rutinarias de la tarea automáticamente, aunque un experto permanece "al tanto" para corregir errores. Las técnicas semiautomatizadas comunes incluyen:

- **Umbral:** El usuario selecciona un umbral de intensidad para separar las estructuras del fondo. Los vóxeles por encima o por debajo del umbral se clasifican como la región de destino. Este método es simple y rápido, pero elegir el umbral correcto no es trivial, y es posible que la anatomía con rangos de intensidad superpuestos no se segmente limpiamente ²⁵. A menudo sirve como un paso inicial que puede ser refinado por otros métodos. La Figura 1 es un ejemplo de segmentación por umbral.




Figura 1. Ejemplo de uso de umbrales de densidad en máscaras de segmentación. (a) TC abdominal con administración de contraste en fase portal de una paciente con un tumor ovárico solido-quístico. (b) Mismo TC con sobreposición de una máscara de segmentación realizada con método de umbral (umbral de densidad mínima de -55 Unidades Hounsfield). Véase que además del tumor, quedan segmentadas otras estructuras de más de -55 Unidades Hounsfield como la musculatura, el hueso, el útero, el recto, o los vasos, pero se excluye la mayor parte del tejido adiposo. Imagen de acceso libre obtenida de la base de datos TCGA-OV ²⁶.

- **Crecimiento de región (*region growing*):** A partir de uno o más puntos de inicialización colocados por el usuario dentro de la estructura de interés, el algoritmo "crece" automáticamente la región mediante la inclusión de píxeles/vóxeles vecinos con intensidades similares. El crecimiento continúa hasta que fallan los criterios de intensidad o se alcanzan los límites. El crecimiento de regiones es intuitivo y puede llenar formas irregulares, pero puede filtrarse a los tejidos adyacentes si sus intensidades se superponen, por lo que los usuarios deben monitorear y ajustar los parámetros (como la tolerancia de similitud). La Figura 2 es un ejemplo de segmentación por crecimiento de región.




Figura 2. Ejemplo de segmentación con técnica región growing. (a) TC abdominal con administración de contraste en fase portal de una paciente con un tumor ovárico solido-quístico. (b) Mismo TC con superposición de una máscara cruda con dos etiquetas: tumor en verde y no-tumor en amarillo. Máscara pintada rápidamente en un solo corte en segundos. (c) Resultado tras ejecución del algoritmo “region growing” en la máscara cruda manual. Se observa la mejor definición de los márgenes tumorales. Imagen de acceso libre obtenida de la base de datos TCGA-OV ²⁶.

- **Contornos activos (serpientes):** Este método clásico introduce una curva o superficie deformable que se ajusta a los límites del objeto. Por lo general, el usuario inicializa un contorno aproximado alrededor del objetivo, y el algoritmo de contorno activo ajusta iterativamente esa curva para minimizar una función de energía: un término la empuja hacia bordes fuertes en la imagen, mientras que otro término impone suavidad²⁷. Los contornos activos pueden delinear contornos bastante complejos y pueden ser semiautomatizados (el usuario solo necesita inicializar y dejar que se ejecute), pero pueden quedarse atascados en límites incorrectos si la ubicación inicial o el contraste de la imagen no son ideales.
- **Aprendizaje automático interactivo:** Uno (o varios clics, dependiendo del sistema) y un modelo de aprendizaje profundo entrenado predice inmediatamente la región de interés alrededor de ese clic. Esencialmente, la red neuronal generaliza a partir de esas entradas mínimas del usuario para inferir todos los límites del objeto. El usuario puede añadir unos pocos clics correctivos y el modelo actualiza la mascarilla en tiempo real. Esto acelera en gran medida la anotación de órganos o lesiones, ya que la IA rellena la mayor parte de la región y el experto simplemente la corrige según sea necesario. La Figura 3 muestra el uso del algoritmo nnInteractive²⁸.




Figura 3. Ejemplo uso del algoritmo nnInteractive. (a) TC abdominal con administración de contraste en fase portal de una paciente con un tumor ovárico solido-quístico. (b) Anotación básica manual de áreas del tumor en un único corte para inicializar el algoritmo. (c) Resultado inicial automático del algoritmo nnInteractive (nótese que aparte del tumor también ha incluido útero sano). (d) Corrección manual de la segmentación en un corte para excluir útero normal. (e) 2ª iteración automática del algoritmo nnInteractive. Segmentación básica manual del tumor. (f) Visualización del 3D de toda la segmentación, para la cual sólo se han hecho 2 clics (clic inicial de inicialización y segundo clic de corrección). Imagen de acceso libre obtenida de la base de datos TCGA-OV²⁶.

En general, los métodos semiautomatizados actúan como un término medio: son menos tediosos que el rastreo puramente manual y, a menudo, mucho más rápidos, pero permiten a los usuarios mantener el control sobre los resultados. Muchos investigadores clínicos utilizan estas técnicas para acelerar la segmentación y, al mismo tiempo, garantizar que la supervisión de un experto mantenga la calidad.

6.4.3. Segmentación automatizada

Los enfoques de segmentación totalmente automatizados tienen como objetivo producir segmentaciones precisas sin intervención humana durante el proceso de segmentación. Estos métodos se basan en algoritmos, entrenados con imágenes de ejemplo, para reconocer y delinear la anatomía o las anomalías en nuevas exploraciones. Las técnicas automatizadas han evolucionado significativamente con el tiempo:

- **Segmentación basada en atlas:** Una de las primeras estrategias automatizadas utiliza un atlas, esencialmente una imagen de referencia (o un conjunto de imágenes) con segmentaciones conocidas, para guiar el proceso. El atlas (una plantilla, a menudo un paciente promedio o un representante elegido) se registra en la exploración del nuevo paciente, deformándola para que sus estructuras anatómicas se alineen con la imagen objetivo⁵. Una vez alineados, las etiquetas del atlas (por ejemplo, los límites de los órganos) se transfieren a la nueva imagen, lo que produce una segmentación. Los métodos basados en atlas pueden ser bastante efectivos para estructuras que tienen una forma y apariencia consistentes en todos los individuos. Sin embargo, si la anatomía de un paciente es inusual o la patología causa distorsión, es posible que el atlas no se alinee perfectamente, lo que lleva a errores.
- **Aprendizaje Profundo (Deep Learning):** La llegada del aprendizaje profundo revolucionó la segmentación automatizada. Las redes neuronales convolucionales (CNN) pueden aprender características jerárquicas enriquecidas directamente de los datos, lo que elimina la necesidad de un diseño ma-

nual de características ²⁵. En imágenes médicas, la arquitectura U-Net ¹⁰ ha cobrado especial importancia. U-Net es una CNN diseñada para la segmentación que presenta una estructura de codificador-decodificador: el codificador reduce gradualmente la resolución de la imagen extrayendo características abstractas, y el decodificador aumenta la muestra y utiliza conexiones de omisión para localizar con precisión esas características, produciendo una máscara de segmentación. Este enfoque puede aprender a identificar los límites de órganos o lesiones con alta precisión si se dan suficientes ejemplos de entrenamiento (unos pocos cientos pueden dar resultados sorprendentes, dependiendo de la tarea y la homogeneidad de los datos). La familia U-Net y sus numerosas variantes han destacado por su éxito para tareas de segmentación. Una extensión notable, nnU-Net, es una canalización autoconfigurable que ajusta automáticamente la arquitectura de red y los parámetros para un conjunto de datos determinado, lo que requiere un ajuste humano mínimo y un uso mucho más simple. En la práctica, la segmentación profunda basada en CNN puede acercarse a la calidad de nivel experto. Estos modelos requieren grandes conjuntos de datos etiquetados para el entrenamiento y recursos computacionales sustanciales para entrenar y ejecutar, pero una vez entrenados, pueden segmentar nuevas imágenes en segundos. Un ejemplo de nnU-Net de acceso libre y fácil es el algoritmo Total Segmentator, disponible en varias plataformas, que puede ejecutarse localmente, pero también en línea sin recursos avanzados (<https://totalsegmentator.com>). Segmenta de manera automática y muy precisa todo tipo de estructuras fisiológicas (Figura 4) ²⁹.




Figura 4. Ejemplo uso del algoritmo automático nnU-net Total Segmentator en planos axial (a), sagital (b), y coronal (c), que muestra la imagen original con una segmentación completamente automática. Nótese que no está conceptualizado para segmentar patología sino imagen fisiológica. El tumor se ha etiquetado erróneamente como si fuese vejiga urinaria. Imagen de acceso libre obtenida de la base de datos TCGA-OV ²⁶.

- **Transformadores y modelos híbridos:** Más recientemente, se han comenzado a incorporar arquitecturas de transformadores (populares en el procesamiento del lenguaje natural como ChatGPT de la empresa OpenAI) en tareas de visión como la segmentación ³⁰. Los transformadores utilizan mecanismos de autoatención para capturar relaciones de largo alcance en la imagen, complementando a las CNN, que son muy buenas en el reconocimiento de patrones locales. Los transformadores de visión (ViT) y los modelos híbridos dividen la imagen en parches y los procesan de modo que el modelo pueda "ver" todo el contexto de la imagen al tomar decisiones sobre una ubicación determinada ³¹. Los modelos de segmentación basados en transformadores han comenzado a superar a las CNN puras en algunas tareas, especialmente en los casos en que las dependencias de largo alcance son importantes (como la segmentación de lesiones dispersas o estructuras complejas ³²).

A pesar del tremendo progreso en la segmentación automatizada, es importante tener en cuenta las limitaciones. Los modelos avanzados, en particular los de aprendizaje profundo, consumen muchos datos y requieren un hardware potente. El entrenamiento de un modelo de CNN o transformador exige una gran cantidad de imágenes anotadas (que a menudo son escasas en medicina) y recursos computacionales (GPU/TPU) durante días o semanas. Incluso después del entrenamiento, algunos modelos pueden hacer un uso intensivo

de la memoria o ser lentos para obtener imágenes 3D de resolución completa. Además, ningún método automatizado es perfecto: se sigue recomendando el control de calidad por parte de un experto humano, especialmente en aplicaciones críticas ⁵.

6.4.2. Control de calidad y evaluación

El control de calidad en la segmentación de imágenes médicas se basa en métricas y protocolos rigurosos para garantizar que los modelos sean precisos, fiables y reproducibles. Las medidas de superposición estándar, como el coeficiente de Dice (puntuación F1) y el índice de Jaccard, se utilizan ampliamente para cuantificar la similitud entre la salida de un algoritmo y la "verdad fundamental" (*ground truth*) establecida. Las métricas basadas en la distancia, como la distancia de Hausdorff, capturan errores de límite, mientras que el error de volumen relativo mide las discrepancias en el volumen segmentado. Por ejemplo, en una revisión reciente se informa que se utiliza Dice como métrica principal y se complementa con un error de volumen relativo (RVE) en la evaluación de las segmentaciones tumorales.

- **Métricas de superposición (Dice y Jaccard):** Calculan la concordancia de vóxeles entre dos máscaras (puede ser entre una máscara automática y una de "verdad fundamental"). Estas métricas evalúan directamente cuánto se superpone la región predicha con la lesión verdadera. El índice Dice se calcula como el doble del número de vóxeles coincidentes dividido por la suma de los vóxeles de ambas segmentaciones. El índice Jaccard (también conocido como "Intersección sobre Unión" o IoU) mide la proporción del volumen combinado que está correctamente segmentado. Es similar al Dice, aunque un poco más estricto (valores más bajos en general).
- **Índice Hausdorff:** En vez de vóxeles coincidentes, evalúa cuán bien coinciden los bordes o contornos entre la predicción y la referencia, se utilizan métricas de distancia. Mide el mayor error de segmentación a lo largo del margen de la segmentación. El índice percentil 95 de distancia de Hausdorff excluye medidas extremas y se correlaciona mejor con la aceptación clínica.
- **Precisión del volumen (RVE):** Compara el volumen total de la segmentación predicha con el volumen de la "verdad fundamental", expresándolo como un porcentaje. Un valor cercano a cero indica buena concordancia. Valores positivos indican que el modelo segmentó más volumen del que debía, mientras que valores negativos reflejan que segmentó menos. Esta métrica es útil para evaluar, por ejemplo, si un modelo tiende sistemáticamente a sobredimensionar los tumores o a omitir partes relevantes.

Más allá de las métricas, un control de calidad sólido exige una revisión basada en la realidad: anotaciones coherentes y revisadas por expertos creadas según procedimientos estándar. Las prácticas de control de calidad evitan las exageraciones de "caja negra" y promueven la reproducibilidad, lo que garantiza que los resultados informados sean estadísticamente sólidos y clínicamente significativos.

Bibliografía

1. Park H, Lee HJ, Kim HG, et al. Endometrium segmentation on transvaginal ultrasound image using key-point discriminator. *Med Phys* 2019;46:3974–84.
2. Ma J, He Y, Li F, et al. Segment anything in medical images. *Nat Commun* 2024;15:654.
3. Kurata Y, Nishio M, Moribata Y, et al. Automatic segmentation of uterine endometrial cancer on multi-sequence MRI using a convolutional neural network. *Sci Rep* 2021;11:14440.
4. van Timmeren JE, Cester D, Tanadini-Lang S, et al. Radiomics in medical imaging—"how-to" guide and critical reflection. *Insights Imaging* 2020;11:91.
5. Pareto D, Naval-Baudin P, Pons-Escoda A, et al. Image analysis research in neuroradiology: bridging clinical and technical domains. *Neuroradiology* 2025.

6. Sharp G, Fritscher KD, Pekar V, et al. Vision 20/20: perspectives on automated image segmentation for radiotherapy. *Med Phys* 2014;41:050902.
7. Eisenhauer EA, Therasse P, Bogaerts J, et al. New response evaluation criteria in solid tumours: revised RECIST guideline (version 1.1). *Eur J Cancer* 2009;45:228–47.
8. Cervera Deval J. RECIST y el radiólogo. *Radiología* 2014;56:193–205.
9. Ramesh KKD, Kumar GK, Swapna K, et al. A Review of Medical Image Segmentation Algorithms. *EAI Endorsed Trans Pervasive Heal Technol* 2021;7:e6.
10. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. In: *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference. Munich, Germany: Springer international publishing; 2015:234–41.*
11. Krithika alias AnbuDevi M, Suganthi K. Review of Semantic Segmentation of Medical Images Using Modified Architectures of UNET. *Diagnostics* 2022;12:3064.
12. Rovira A, Corral JF, Auger C, et al. Assessment of automatic decision-support systems for detecting active T2 lesions in multiple sclerosis patients. *Mult Scler* 2022;28:1209–18.
13. Robert C, Munoz A, Moreau D, et al. Clinical implementation of deep-learning based auto-contouring tools-Experience of three French radiotherapy centers. *Cancer Radiother* 2021;25:607–16.
14. Berrezueta S, Baldeon-Calisto M, Navarrete D, et al. Foundation Models for Medical Image Segmentation: A Literature Review. In: *2025 13th International Symposium on Digital Forensics and Security (ISDFS). IEEE; 2025:1–7.*
15. Kirillov A, Mintun E, Ravi N, et al. Segment Anything. *Proc IEEE Int Conf Comput Vis* <https://doi.org/10.1109/ICCV51070.2023.00371>.
16. Tan M, Li Z, Qiu Y, et al. A New Approach to Evaluate Drug Treatment Response of Ovarian Cancer Patients Based on Deformable Image Registration. *IEEE Trans Med Imaging* 2016;35:316–25.
17. XIAO J, TAN Y, LI W, et al. Tumor volume reduction rate is superior to RECIST for predicting the pathological response of rectal cancer treated with neoadjuvant chemoradiation: Results from a prospective study. *Oncol Lett* 2015;9:2680–6.
18. Chatziantoniou C, Schoot RA, van Ewijk R, et al. Methodological considerations on segmenting rhabdomyosarcoma with diffusion-weighted imaging—What can we do better? *Insights Imaging* 2023;14:19.
19. Erdur AC, Rusche D, Scholz D, et al. Deep learning for autosegmentation for radiotherapy treatment planning: State-of-the-art and novel perspectives. *Strahlenther Onkol* 2025;201:236–54.
20. Njeh CF. Tumor delineation: The weakest link in the search for accuracy in radiotherapy. *J Med Phys* 2008;33:136–40.
21. Jin D, Guo D, Ho T-Y, et al. DeepTarget: Gross tumor and clinical target volume segmentation in esophageal cancer radiotherapy. *Med Image Anal* 2021;68:101909.
22. Lee S-W, Kim A, Lee SJ, et al. Intensity-Modulated Radiation Therapy for Uterine Cervical Cancer to Reduce Toxicity and Enhance Efficacy - an Option or a Must?: A Narrative Review. *Cancer Res Treat* 2024;56:1–17.
23. Shah NR, Weadock WJ, Williams KM, et al. Use of modern three-dimensional imaging models to guide surgical planning for local control of pediatric extracranial solid tumors. *Pediatr Blood Cancer* 2024;71:e30933.
24. Lo BP, Donnelly MR, Barisano G, et al. A standardized protocol for manually segmenting stroke lesions on high-resolution T1-weighted MR images. *Front Neuroimaging* 2022;1.
25. Iratni M, Abdullah A, Aldhaheri M, et al. Transformers for Neuroimage Segmentation: Scoping Review. *J Med Internet Res* 2025;27:e57723.
26. Holback C, Jarosz R, Prior F, et al. The Cancer Genome Atlas Ovarian Cancer Collection (TCGA-OV) (Version 4) [Data set]. *Cancer Imaging Arch* <https://doi.org/10.7937/K9/TCIA.2016.NDO1MDFQ>.
27. Andrey P, Boudier T. Adaptive active contours (snakes) for the segmentation of complex structures in biological images. *ImageJ Conf* 2006. [Epub ahead of print].
28. Isensee F, Rokuss M, Krämer L, et al. nnInteractive: Redefining 3D Promptable Segmentation. 2025 Mar 11. [Epub ahead of print].
29. Wasserthal J, Breit H-C, Meyer MT, et al. TotalSegmentator: Robust Segmentation of 104 Anatomic Structures in CT Images. *Radiol Artif Intell* 2023;5:e230024.
30. Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. *Adv Neural Inf Process Syst* 2017;30.
31. Gu H, Dong H, Yang J, et al. How to build the best medical image segmentation algorithm using foundation models: a comprehensive empirical study with Segment Anything Model. *Mach Learn Biomed Imaging* 2025;3:88–120.
32. Gu H, Dong H, Yang J, et al. How to build the best medical image segmentation algorithm using foundation models: a comprehensive empirical study with Segment Anything Model. *Mach Learn Biomed Imaging* 2025;3:88–120.

7. RECOPIACIÓN Y ANÁLISIS DE DATOS EN INTELIGENCIA ARTIFICIAL

7. Recopilación y análisis de datos en inteligencia artificial

Luis Cabero y Esther Martínez

7.1 Fuentes de Datos en Obstetricia y Ginecología

La inteligencia artificial (IA) se fundamenta en la capacidad de aprender a partir de grandes volúmenes de datos. Este capítulo explora de manera integral las fases de recopilación y análisis de datos, aspectos cruciales para el éxito de cualquier proyecto de IA. Desde la identificación y obtención de datos hasta el procesamiento e interpretación de la información, se abordan tanto las tecnologías como las consideraciones éticas inherentes a este proceso.

En este apartado, además de revisar someramente el contenido relacionado con las bases de datos, se hace énfasis en las bases de datos existentes y sus principales propiedades. Es importante tener presente que día a día surgen nuevas fuentes, más o menos especializadas, que proporcionan información adicional sobre campos concretos.

En las últimas dos décadas, la inteligencia artificial (IA) ha comenzado a ocupar un lugar relevante en diversas disciplinas médicas, y la ginecología y obstetricia no han sido la excepción. Inicialmente explorada en entornos académicos como parte de sistemas de apoyo a la toma de decisiones clínicas, su evolución se ha visto acelerada por el avance del aprendizaje automático y el procesamiento de grandes volúmenes de datos clínicos e imagenológicos.

Durante los primeros años del siglo XXI, los desarrollos en IA se centraron en herramientas para el monitoreo fetal, la predicción de complicaciones obstétricas y el análisis básico de imágenes ginecológicas, con resultados aún limitados. Sin embargo, el verdadero punto de inflexión llegó con la incorporación del aprendizaje profundo, que permitió el desarrollo de algoritmos capaces de interpretar mamografías, colposcopias y ecografías obstétricas con niveles de precisión comparables a los de expertos humanos. Estos avances abrieron nuevas posibilidades diagnósticas y de predicción clínica, especialmente valiosas en contextos con acceso restringido a especialistas. Un ejemplo destacado es el estudio publicado en *Nature Medicine* (2019), en el que un modelo de IA logró diagnosticar anomalías fetales a partir de ecografías con una precisión similar a la de médicos especializados. Este tipo de innovación ha reforzado el papel de la IA como herramienta complementaria en la práctica clínica gineco-obstétrica, tanto en la mejora de la precisión diagnóstica como en la optimización de los recursos disponibles.

A pesar de sus beneficios potenciales, la incorporación de la IA plantea desafíos importantes en términos éticos, regulatorios y prácticos. La Organización Mundial de la Salud (OMS) ha subrayado la necesidad de aplicar estas tecnologías bajo principios de equidad, seguridad, transparencia y respeto por la autonomía de las pacientes. Este artículo aborda el estado actual del uso de la IA en ginecología y obstetricia, sus aplicaciones clínicas más relevantes, y los principales aspectos éticos y operativos que deben considerarse para su implementación responsable en los sistemas de salud. La IA en medicina puede adoptar diversas formas y realizar diversas tareas, desde la predicción de riesgos o el diagnóstico y cribado hasta los sistemas de apoyo a la toma de decisiones clínicas (SADC) basados en IA [1]. Los sistemas de IA también se han introducido en diversas especialidades médicas, como la oncología, la neumología y la radiología [2].

El uso de la inteligencia artificial (IA) en ginecología y obstetricia ha crecido significativamente en los últimos años, ofreciendo herramientas para mejorar el diagnóstico, el tratamiento y el seguimiento de las pacientes. Se ha descubierto que la autonomía médica influye en la aceptación y adopción de tecnologías médicas por parte de los profesionales [3], y en particular, de la IA [1]. Si bien la autonomía médica se ha

convertido en un concepto cada vez más importante en las últimas décadas [4, 7], aún no existe una definición consensuada en la literatura. No obstante, se considera generalmente que la autonomía médica incluye tanto las libertades clínicas como las sociales y económicas [6, 7]. La primera se refiere a la autonomía del médico en la práctica clínica, incluyendo su control sobre el diagnóstico y el tratamiento de los pacientes y sobre las evaluaciones de su atención. La segunda se refiere a la autonomía de los médicos como profesionales, incluyendo la elección de su especialidad y el control sobre la naturaleza y el volumen de sus tareas [5]. Diversas revisiones recientes han concluido que la temida pérdida de autonomía médica representa una barrera para la aceptación de la IA [1, 8, 10].

7.1.1 Fuentes de Datos Generales

Los datos pueden provenir de diversas fuentes, las cuales se pueden clasificar en:

- **Datos estructurados:** Bases de datos relacionales, hojas de cálculo y sistemas de gestión de datos que presentan información organizada en tablas.
- **Datos no estructurados:** Texto, imágenes, videos y otros formatos que requieren procesamiento adicional para extraer información significativa.
- **Datos semiestructurados:** Archivos JSON, XML, entre otros, que poseen una estructura flexible, pero contienen etiquetas o claves que facilitan la interpretación.

7.1.2 Métodos de Recopilación

Existen múltiples métodos para recolectar datos, entre los que destacan:

- **APIs y Web Services:** Permiten acceder a datos de plataformas externas de manera estructurada.
- **Scraping web:** Técnica para extraer información de páginas web, que requiere un manejo cuidadoso respecto a la legalidad y la ética.
- **Sensores y dispositivos IoT:** Utilizados para recopilar datos en tiempo real en campos como la salud, el medio ambiente o la industria.
- **Encuestas y formularios:** Herramientas para obtener datos directamente de los usuarios, fundamentales para áreas como la experiencia del cliente o estudios de mercado.

7.1.3 Fuentes de Datos Específicas en Ginecología y Obstetricia

En ginecología y obstetricia, existen diversas fuentes de datos que pueden utilizarse para el desarrollo de proyectos de inteligencia artificial en salud. A continuación, se presenta una lista de fuentes estructuradas y no estructuradas:

1. Bases de datos abiertas y registros públicos

- **MIMIC-IV (Medical Information Mart for Intensive Care):** Contiene datos de pacientes en cuidados intensivos, incluyendo aspectos obstétricos.
<https://physionet.org/content/mimiciv>
- **NHANES (National Health and Nutrition Examination Survey):** Datos de salud y nutrición en mujeres embarazadas.
<https://www.cdc.gov/nchs/nhanes>

- **Perinatal Data System:** Sistemas nacionales de salud que recopilan datos sobre nacimientos y complicaciones.
- **DHS Program (Demographic and Health Surveys):** Encuestas demográficas y de salud con información sobre salud materno-infantil.
<https://dhsprogram.com>
- **UK Biobank:** Base de datos con información sobre salud y genética, incluyendo salud reproductiva.
<https://www.ukbiobank.ac.uk>

2. Repositorios de imágenes médicas

- **The Digital Database for Screening Mammography (DDSM):** Base de datos de mamografías para estudios de detección de cáncer de mama.
<http://marathon.csee.usf.edu/Mammography/Database.html>
- **Breast Cancer Digital Repository (BCDR):** Datos sobre mamografías y cáncer de mama.
<http://bcdr.ceta-ciemat.es>
- **OB-GYN Ultrasound Image Database:** Repositorios con imágenes ecográficas de embarazos normales y patológicos.

3. Estudios clínicos y publicaciones

- **ClinicalTrials.gov:** Base de datos de estudios clínicos en obstetricia y ginecología.
<https://clinicaltrials.gov>
- **PubMed Open Access:** Publicaciones médicas con conjuntos de datos sobre salud reproductiva.
<https://pubmed.ncbi.nlm.nih.gov>
- **BioGPS y Gene Expression Omnibus (GEO):** Datos genómicos y transcriptómicos relacionados con ginecología.
<https://www.ncbi.nlm.nih.gov/geo>

4. Sistemas electrónicos de salud (EHRs)

- **Epic y Cerner:** Grandes proveedores de sistemas EHR con información gineco-obstétrica.
- **OpenMRS:** Un sistema de EHR de código abierto con módulos para salud materno-infantil.
<https://openmrs.org>

5. Redes sociales y foros médicos

- **Reddit y foros de médicos (Medscape, Sermo, Doximity):** Discusiones clínicas que pueden analizarse con Procesamiento de Lenguaje Natural (NLP).
- **Twitter/X y Facebook:** Datos de percepción y opinión sobre temas de salud materna.

6. Bases de datos científicas generales

Contienen gran cantidad de artículos sobre obstetricia, ginecología y salud materno-fetal:

- **PubMed / MEDLINE:** Principal fuente de literatura biomédica. Se pueden usar filtros específicos por área (obstetrics, perinatology, etc.).
<https://pubmed.ncbi.nlm.nih.gov>
- **Cochrane Library:** Revisiones sistemáticas y ensayos clínicos controlados. Excelente para encontrar evidencia basada en estudios bien diseñados.
<https://www.cochranelibrary.com/>

- **Scopus:** Amplia base de datos multidisciplinaria, útil para métricas y análisis bibliométrico.
<https://www.scopus.com/>
- **Web of Science (WoS):** Similar a Scopus, muy potente para buscar artículos relevantes y estudios citados.
<https://www.webofscience.com/>

7. Bases de datos clínicas especializadas

Ideales para temas de gineco-obstetricia desde la práctica clínica:

- **UpToDate:** Fuente de consulta rápida con revisiones clínicas basadas en evidencia. Requiere suscripción, pero es muy usada en entornos hospitalarios.
<https://www.uptodate.com/>
- **BMJ Best Practice:** Información diagnóstica y terapéutica con enfoque clínico.
<https://bestpractice.bmj.com/>
- **DynaMed:** Alternativa a UpToDate con contenidos similares.
<https://www.dynamed.com/>

8. Revistas científicas clave en obstetricia y ginecología

Muchas de ellas están indexadas en PubMed o Scopus:

- *Obstetrics & Gynecology* (Green Journal) – ACOG
- *BJOG: An International Journal of Obstetrics and Gynaecology*
- *American Journal of Obstetrics and Gynecology* (AJOG)
- *Ultrasound in Obstetrics and Gynecology* – ISUOG
- *The Lancet Global Health* – Especialmente relevante para salud materno-infantil global
- *Reproductive Health* – Open access, orientada a salud pública y reproductiva
- *Fertility and Sterility* – Relevante en ginecología reproductiva

9. Otros recursos útiles

- **ClinicalTrials.gov:** Registro de ensayos clínicos en obstetricia/ginecología y salud materna.
<https://clinicaltrials.gov/>
- **WHO Reproductive Health Library (RHL):** Guías y recomendaciones globales, especialmente para entornos con recursos limitados.
<https://srhr.org/rhl>
- **Global Health Observatory (WHO):** Estadísticas de salud materna, parto, acceso a servicios, etc.
<https://www.who.int/data/gho>

A continuación, se detallan algunos de los principales usos y aplicaciones de la IA en ginecología y obstetricia:

1. Diagnóstico y Predicción

- **Ginecología:**
 - **Cáncer ginecológico:** Algoritmos de IA pueden analizar imágenes (como resonancias o tomografías) para detectar de forma temprana cánceres de ovario, cuello uterino o endometrio.
 - **Lesiones precancerosas:** Uso de IA para interpretar pruebas de Papanicolaou (citología) o colposcopias con mayor precisión.

- **Obstetricia:**

- **Predicción de complicaciones:** La IA puede analizar datos maternos (edad, antecedentes, presión arterial, etc.) para predecir riesgos como:
 - Preeclampsia
 - Parto prematuro
 - Diabetes gestacional
 - Estudios de la FCF (ante e intraparto)

2. Análisis de Imágenes Médicas

- **Ecografías obstétricas:** Modelos de IA ayudan a interpretar ecografías, identificando malformaciones fetales, evaluando el crecimiento fetal o estimando la edad gestacional con alta precisión.
- **Ecografías ginecológicas:** Detección automatizada de anomalías en ovarios, útero, miomas o endometriosis.

3. Asistencia en Cirugías y Tratamientos

- **Cirugía asistida por IA:** Uso de robots quirúrgicos (como Da Vinci) guiados por algoritmos que mejoran la precisión en procedimientos ginecológicos mínimamente invasivos.
- **Planificación personalizada del tratamiento:** En casos como fertilidad o cáncer ginecológico, la IA puede ayudar a elegir la mejor estrategia según los datos individuales de cada paciente.

4. Medicina Personalizada y Seguimiento

- **Apps y wearables:** Monitorización continua del bienestar materno-fetal mediante dispositivos que envían datos a sistemas de IA para alertar sobre posibles riesgos.
- **Seguimiento del ciclo menstrual y fertilidad:** Algoritmos que ayudan a identificar ventanas fértiles, posibles trastornos hormonales, etc.

5. Educación Médica y Toma de Decisiones Clínicas

- **Sistemas de apoyo a decisiones clínicas (CDSS):** Asistentes que sugieren diagnósticos o planes de tratamiento a partir de bases de datos y guías clínicas.
- **Simuladores con IA:** Formación en ginecología y obstetricia mediante simuladores realistas para entrenamiento quirúrgico y en emergencias obstétricas.

6. Desafíos y Consideraciones Éticas

- **Privacidad de los datos:** Es fundamental proteger los datos médicos sensibles de las pacientes.
- **Sesgo algorítmico:** Los sistemas deben entrenarse con datos diversos para evitar sesgos que afecten la calidad del diagnóstico en distintas poblaciones.
- **Complemento, no reemplazo:** La IA debe apoyar, no sustituir, el juicio clínico del especialista.



7.2 Calidad y Ética en la Recopilación de Datos

7.2.1 Asegurando la Calidad de los Datos

La calidad de los datos es vital para el éxito de cualquier modelo de IA. Entre las prácticas recomendadas se encuentran:

- **Verificación de integridad:** Asegurarse de que los datos no contengan valores faltantes o erróneos.
- **Actualización y mantenimiento:** Los datos deben estar actualizados y ser relevantes para el problema a resolver.
- **Documentación:** Mantener registros detallados sobre la procedencia y el proceso de recolección de datos para facilitar auditorías y futuras mejoras.

7.2.2 Consideraciones Éticas y de Privacidad

La recopilación de datos implica desafíos éticos y de privacidad, tales como:

- **Consentimiento informado:** Garantizar que los usuarios conozcan y acepten el uso de sus datos.
- **Anonimización:** Proteger la identidad de las personas mediante técnicas que impidan la identificación directa.
- **Cumplimiento normativo:** Asegurarse de que la recopilación y el uso de datos cumplan con leyes y regulaciones, como el GDPR en Europa o la LOPD en otros países.

7.2.3 Preprocesamiento y Limpieza de Datos

Antes de analizar los datos, es necesario realizar un preprocesamiento que incluya:

- **Limpieza:** Eliminación de duplicados, corrección de errores y manejo de valores nulos.
- **Normalización y escalado:** Ajustar las escalas de los datos para que los algoritmos de IA puedan procesarlos de manera uniforme.
- **Transformación:** Convertir datos no estructurados en formatos estructurados o extraer características relevantes que potencien el aprendizaje automático.

7.2.4 Técnicas de Análisis de Datos

El análisis de datos en IA se lleva a cabo mediante una combinación de técnicas estadísticas y métodos de aprendizaje automático:

7.2.4.1 Análisis Exploratorio de Datos (EDA)

- **Visualización:** Uso de gráficos y diagramas para identificar patrones, tendencias y anomalías en los datos.
- **Estadística descriptiva:** Cálculo de medias, medianas, desviaciones estándar y otras métricas que resumen la información.

7.2.4.2 Técnicas de Aprendizaje Automático

- **Modelos supervisados:** Algoritmos que aprenden a partir de datos etiquetados para realizar tareas de clasificación o regresión.
- **Modelos no supervisados:** Métodos para identificar patrones o agrupaciones en datos sin etiquetas, como el *clustering*.
- **Modelos de aprendizaje profundo:** Redes neuronales que pueden procesar grandes volúmenes de datos y detectar patrones complejos, especialmente útiles en tareas de reconocimiento de imágenes y procesamiento del lenguaje natural.

7.2.5 Herramientas y Plataformas

Existen diversas herramientas que facilitan tanto la recopilación como el análisis de datos:

- **Lenguajes de programación:** Python y R son ampliamente utilizados debido a sus bibliotecas especializadas (*pandas*, *NumPy*, *scikit-learn*, *TensorFlow*, *PyTorch*).
- **Plataformas de Big Data:** Apache Hadoop, Spark y bases de datos NoSQL permiten el manejo eficiente de grandes volúmenes de información.
- **Sistemas de visualización:** Herramientas como Tableau o Power BI ayudan a transformar datos complejos en visualizaciones comprensibles.

7.2.6 Casos Prácticos y Aplicaciones

La integración de datos y su análisis han permitido avances significativos en diversos campos:

- **Salud:** Predicción de brotes epidemiológicos, diagnósticos asistidos por IA y análisis de imágenes médicas.
- **Finanzas:** Detección de fraudes, análisis de riesgos y optimización de carteras de inversión.
- **Retail y marketing:** Personalización de experiencias de usuario, segmentación de clientes y análisis de tendencias de consumo.
- **Automoción:** Desarrollo de vehículos autónomos mediante la fusión de datos provenientes de sensores y sistemas de navegación.

7.2.7 Desafíos y Futuro del Análisis de Datos en IA

A pesar de los avances, persisten desafíos como:

- **Escalabilidad:** Manejar y procesar volúmenes masivos de datos en tiempo real.

- **Integración de fuentes heterogéneas:** Combinar datos de distintas fuentes y formatos de manera coherente.
- **Privacidad y seguridad:** Desarrollar métodos que aseguren la protección de datos sin limitar la innovación.
- **Interpretabilidad:** Mejorar la capacidad de entender y explicar los modelos de IA para aumentar la confianza y la adopción en sectores críticos.

La evolución constante de tecnologías y metodologías promete seguir transformando la forma en que recopilamos y analizamos datos, abriendo nuevas oportunidades para aplicaciones innovadoras y soluciones eficientes en diversos ámbitos.

7.2.7.1 Conclusión

La recopilación y el análisis de datos constituyen la columna vertebral de la inteligencia artificial. Un manejo adecuado de estas fases no solo mejora la precisión de los modelos, sino que también abre la puerta a la creación de soluciones éticas, seguras y escalables. Al combinar técnicas avanzadas con un enfoque riguroso en la calidad y la ética, es posible aprovechar el verdadero potencial de la IA en la resolución de problemas complejos y la mejora continua de procesos en múltiples industrias.

A continuación, se proporciona una descripción más detallada del uso de la inteligencia artificial (IA) en ginecología y obstetricia, respaldada por ejemplos concretos y referencias bibliográficas actualizadas.

7.2.8 Aplicaciones Clínicas de la IA en Ginecología y Obstetricia

1. Detección y Diagnóstico Precoz

- **Cáncer de cuello uterino:** Un estudio realizado en Tucumán, Argentina, demostró que la videocolposcopia asistida por IA mejora la precisión diagnóstica de lesiones preneoplásicas del cuello uterino en comparación con la videocolposcopia convencional [1].
- **Cáncer de mama:** En la Comunidad Valenciana, España, se implementó un sistema de IA para la interpretación de mamografías, mejorando la precisión diagnóstica y reduciendo la carga de trabajo en los servicios de radiología [2].

2. Predicción de Complicaciones Obstétricas

- **Preeclampsia:** Investigaciones en Cedars-Sinai han desarrollado un algoritmo de IA que identifica a las pacientes en riesgo de preeclampsia y automatiza la prescripción de aspirina, mejorando la equidad en la atención [3, 4].
- **Hemorragias posparto:** Utilizando datos en tiempo real durante el trabajo de parto, se ha creado una herramienta basada en IA que predice el riesgo de hemorragias posparto graves, permitiendo una intervención temprana [3].

3. Mejora en la Interpretación de Imágenes Ginecológicas

- **Trastornos ginecológicos benignos:** Una revisión sistemática de 59 estudios mostró que los modelos de IA pueden clasificar y segmentar imágenes de ecografías para detectar condiciones como el síndrome de ovario poliquístico, endometriosis y miomas uterinos, aunque muchos estudios presentan un alto riesgo de sesgo [5].

4. Asistencia en la Toma de Decisiones Clínicas

- **Interpretación de citologías cervicales:** En Cedars-Sinai, se ha desarrollado una aplicación de IA que contextualiza los resultados de las citologías cervicales, proporcionando recomendaciones personalizadas y mejorando la comunicación con las pacientes [4].

Si profundizamos en cómo la inteligencia artificial (IA) está transformando la experiencia de los pacientes y la práctica de los profesionales en ginecología y obstetricia, tanto en el ámbito asistencial como en la investigación y el conocimiento científico.

7.3 Calidad Asistencial

7.3.1 Ética de la Recopilación de Datos y Privacidad

La Organización Mundial de la Salud (OMS) ha establecido orientaciones sobre la ética y la gobernanza de la inteligencia artificial (IA) en el ámbito de la salud, con el objetivo de garantizar que estas tecnologías se utilicen de manera segura, equitativa y respetuosa con los derechos humanos. Estas directrices se basan en el trabajo de un grupo de expertos internacionales y están diseñadas para ser aplicadas por gobiernos, desarrolladores, proveedores de atención sanitaria y la sociedad civil.

7.3.2 IA en Ginecología y Obstetricia: Orientación Ética y Gobernanza (OMS)

7.3.2.1 Contexto y Necesidad

El uso de IA en ginecología y obstetricia está en crecimiento: diagnóstico automatizado, predicción de riesgos en embarazos, análisis de imágenes, planificación del parto, etc. La OMS advierte que, sin una guía ética clara, la IA puede profundizar desigualdades de género, marginar a poblaciones vulnerables o generar riesgos clínicos.

7.3.2.2 Principios Éticos Fundamentales

La OMS propone principios rectores para el uso de la IA en salud con el objetivo de preservar la autonomía humana y asegurar que las decisiones médicas sigan siendo responsabilidad de los profesionales de la salud y los pacientes.

Se debe promover el bienestar y la seguridad, y la IA debe cumplir con estándares de seguridad y eficacia, siendo utilizada para fines bien definidos y sin caer en la maleficencia. Debe garantizarse la transparencia con información clara y accesible, y ser justa, inclusiva y equitativa, sin discriminar por razones de género, edad, raza u otras características. La IA debe ser utilizada de manera responsable, aunque parezca un juego de palabras, de forma que no se tomen decisiones automatizadas sin la posibilidad de reparación. A su vez, debe tener capacidad de respuesta, ser adaptable y sostenible a largo plazo.

A continuación, se desarrollan los 5 principios éticos fundamentales, tal y como se observan en la siguiente figura.

5 PRINCIPIOS ÉTICOS



Justicia
Trato equitativo



Beneficencia
Promoción del bienestar



No maleficencia
No causar daño



Responsabilidad
Asumir obligaciones



Autonomía
Decisión informada

✓ Equidad

- La IA no debe replicar ni reforzar sesgos estructurales (de género, etnia o condición económica).
- Se requiere que los algoritmos se entrenen con datos diversos, no solo de mujeres blancas o de países ricos.
- **Ejemplo:** Un sistema de predicción de preeclampsia que no ha sido probado en mujeres afrodescendientes puede fallar gravemente en su diagnóstico.

✓ Seguridad y Eficacia

- Los algoritmos deben estar basados en evidencia científica.
- La OMS insiste en que la IA debe ser sometida a ensayos clínicos controlados, igual que un medicamento.
- **Ejemplo:** Un sistema que evalúa ecografías debe demostrar precisión comparable (o superior) a un profesional humano.

✓ Transparencia y Explicabilidad

- Las decisiones basadas en IA deben poder explicarse.
- Deben existir mecanismos para auditar y cuestionar el funcionamiento de los algoritmos.

✓ Responsabilidad

- Nunca se debe delegar completamente la responsabilidad clínica a la IA.
- Siempre debe haber supervisión médica humana.

- Si un sistema falla, debe estar claro quién responde: desarrolladores, hospital, profesional.

✓ Autonomía

- Las mujeres deben tener el derecho a decidir si desean o no que se utilice IA en su atención médica. Además, tienen el derecho de buscar más información o una doble consulta.
- La tecnología no debe reemplazar el consentimiento informado.
- **Ejemplo:** Si se usa un algoritmo para predecir complicaciones en el embarazo, la paciente debe saber cómo y por qué se usó.

7.3.2.3 Gobernanza y Regulación

La OMS también ofrece recomendaciones específicas para gobiernos y desarrolladores:

Para los gobiernos, recomienda:

- Invertir en infraestructuras públicas y no lucrativas accesibles para los desarrolladores.
- Usar las leyes y las políticas para garantizar que la IA cumpla con estándares éticos y de derechos humanos.
- Designar agencias reguladoras que evalúen las aplicaciones y las recomendaciones de la IA en ginecología y obstetricia.
- Auditar estas decisiones y recomendaciones, y realizar evaluaciones imparciales por terceros independientes.

Para los desarrolladores, recomienda:

- Diseñar sistemas de IA para tareas específicas, que sean precisos y fiables.
- Ser inclusivos para todas las partes interesadas, profesionales de la salud y pacientes.
- Prever y considerar los posibles resultados derivados de la IA.

La OMS pide que se establezcan marcos legales y éticos locales, con participación de mujeres, pacientes, expertos en salud pública y bioética. Se deben implementar comités de revisión ética, regulaciones de certificación de IA médica y auditorías periódicas, tal y como muestra la siguiente figura:



7.3.2.4 Ética de la Recopilación de Datos y Privacidad

1. **Consentimiento Informado:** Debe ser claro, libre, específico y revocable. Las pacientes deben estar informadas sobre los datos que se recogen, el uso que se les dará (diagnóstico, investigación, entrenamiento de IA), por cuánto tiempo se almacenarán y quién tendrá acceso a ellos.
2. **Protección de Datos Sensibles:** En ginecología y obstetricia se manejan datos íntimos: ciclos menstruales, abortos, embarazos, VIH, infecciones, etc. Los datos usados deben ser anónimos y se deben aplicar medidas de seguridad como el cifrado extremo. Además, se debe controlar el acceso y realizar auditorías que muestren tanto el número de accesos a los datos como la identidad de las personas que los realizan. Existe el riesgo de que los datos, a pesar de todos los mecanismos establecidos, se filtren; si esto ocurre, pueden ser utilizados para discriminación laboral, social o legal (por ejemplo, en países donde el aborto está penalizado).
3. **Minimización y Proporcionalidad:** Solo deben recolectarse los datos estrictamente necesarios para el fin médico o científico, sin acceder al resto de los datos de la historia clínica, ya que esto incurriría en un hecho legalmente cuestionable.
4. **Equidad en los Datos:** Los datos usados para entrenar IA deben ser inclusivos y representativos, ya que el sesgo en los datos puede llevar a errores clínicos peligrosos y no responder al estudio o a la población sobre la que va dirigida.

5. **Derechos de la Paciente sobre sus Datos:** Las pacientes deben tener derecho al acceso de sus datos, a poderlos rectificar o eliminar si identifican algún dato erróneo, y a estar informadas si sus datos han sido usados para una herramienta de IA, así como el modo y la finalidad de dicho uso.

7.3.2.5 Desafíos y Consideraciones Adicionales

La OMS ha designado al Centro de Ética Digital de la Universidad Tecnológica de Delft como un centro colaborador para la gobernanza de la IA en salud, con el fin de promover la investigación y la capacitación en este ámbito. Este centro pretende evitar los posibles sesgos de los datos para que no se altere la equidad y la precisión de los datos, minimizar la desinformación derivada del contenido erróneo o engañoso producido por la IA generativa, y, finalmente, proteger los datos para garantizar la privacidad y la seguridad de la información de ginecología y obstetricia utilizada por la IA.

Estas orientaciones buscan asegurar que la IA en salud se utilice de manera que beneficie a todas las personas, respetando los principios éticos y los derechos humanos.

7.3.2.6 Inteligencia Artificial en Ginecología y Obstetricia: Una Herramienta Prometedora con Exigencias Éticas

La inteligencia artificial (IA) está adquiriendo un papel cada vez más relevante en el ámbito médico, y la ginecología y obstetricia no son la excepción. La posibilidad de procesar grandes volúmenes de datos clínicos, analizar imágenes médicas con alta precisión y predecir riesgos obstétricos mediante algoritmos avanzados ofrece oportunidades reales para mejorar la calidad, la eficiencia y la accesibilidad de los servicios de salud reproductiva. No obstante, la Organización Mundial de la Salud (OMS) ha advertido que este avance tecnológico solo será beneficioso si se desarrolla y se implementa bajo principios éticos sólidos, con especial atención a la equidad, la seguridad, la transparencia y el respeto a los derechos humanos.

En su informe *Ethics and Governance of Artificial Intelligence for Health* (2021), la OMS señala que la IA tiene el potencial de transformar significativamente la atención ginecológica y obstétrica. Actualmente, ya se están utilizando algoritmos capaces de interpretar mamografías, ecografías y colposcopias con niveles de sensibilidad y especificidad comparables —e incluso superiores— a los de profesionales con experiencia. Estas herramientas no solo pueden detectar patologías como el cáncer de cuello uterino o anomalías fetales con mayor rapidez, sino que también ofrecen una valiosa ayuda en contextos con escasez de especialistas, donde su impacto puede ser crítico para la vida de las pacientes.

Un ejemplo de ello es el estudio publicado en *Nature Medicine* (2019), en el que un modelo de IA, entrenado con miles de ecografías obstétricas, logró identificar malformaciones congénitas con precisión similar a la de médicos expertos. Este tipo de avances refuerza el potencial de la IA como instrumento de apoyo al diagnóstico, seguimiento y toma de decisiones clínicas en la práctica gineco-obstétrica.

Sin embargo, la adopción de estas tecnologías no está exenta de desafíos. La OMS insiste en que su implementación debe regirse por principios éticos que garanticen que las herramientas de IA no perpetúen desigualdades ni comprometan la seguridad de las pacientes. Un aspecto crítico es la representatividad de los datos utilizados para entrenar los algoritmos. Si estos datos no reflejan la diversidad de la población —incluyendo variables como edad, origen étnico, nivel socioeconómico o condiciones de salud preexistentes— existe el riesgo de que las herramientas desarrolladas resulten ineficaces o incluso dañinas para determinados grupos.

Asimismo, la protección de la privacidad y la autonomía de las pacientes es un pilar central. En un área tan sensible como la salud sexual y reproductiva, el manejo de datos debe cumplir con los más altos estándares de confidencialidad, y cualquier intervención asistida por IA debe estar sujeta al consentimiento informado. La confianza en estas tecnologías dependerá en gran medida de la transparencia con la que se comuniquen sus capacidades, limitaciones y procesos de decisión.

La OMS propone seis principios rectores para orientar el uso ético de la IA en salud: proteger la autonomía humana; promover el bienestar, la seguridad y el interés público; garantizar la transparencia y la explicabilidad; fomentar la responsabilidad y la rendición de cuentas; asegurar la inclusión y la equidad; y promover

sistemas sostenibles que puedan adaptarse y mejorar con el tiempo. Estos principios no solo deben guiar a los desarrolladores tecnológicos, sino también a los profesionales de la salud, quienes tienen un rol fundamental en la validación clínica, la integración práctica y la evaluación crítica de estas herramientas.

Para ginecólogos, obstetras y otros profesionales implicados en la atención materno-infantil, la IA representa una oportunidad para enriquecer la práctica clínica, reducir la carga asistencial y mejorar los desenlaces perinatales. Pero esta oportunidad debe ir acompañada de un compromiso activo con la ética médica, la equidad en el acceso a la innovación y la defensa de los derechos de las pacientes.

En definitiva, la inteligencia artificial no sustituirá el juicio clínico ni la relación médico-paciente, pero puede complementarlos de forma significativa si se utiliza con responsabilidad. El desafío no es solo tecnológico, sino también humano: garantizar que las decisiones automatizadas respeten los valores que sustentan el acto médico. Como señala la OMS, el verdadero progreso vendrá cuando las herramientas digitales estén al servicio de la salud con justicia, seguridad y dignidad para todas las personas.

Las herramientas de IA en ginecología pueden tener aplicabilidad en dos grandes campos: la oncología ginecológica y el área de la obstetricia para favorecer la interrelación materno-filial, cómo reduce la ansiedad y mejora los resultados de las campañas médicas y preventivas en esta área. En cualquier lugar ha de hacerse mención de las responsabilidades de cada actor en el proceso. Hay un aspecto que, junto con la formación médica, debe unirse al de la responsabilidad administrativa del personal administrativo. El cuidado y la guarda de esta información no puede ser manejado por personal administrativo no cualificado y responsable, si bien es cierto que un programa bien construido con formación profunda (tal como se explicó en el capítulo correspondiente), y con algoritmos que incluyan el control de error, han de ser también enfatizados en el conjunto asistencial.

Añadamos dos ejemplos:

En el área de la ginecología, con el artículo titulado “Diagnosis Test Accuracy of Artificial Intelligence for Endometrial Cancer: Systematic Review and Meta-Analysis” [6], publicado el 18 de abril de 2025 en el *Journal of Medical Internet Research*, se presenta una revisión sistemática y un meta-análisis sobre la precisión diagnóstica de la inteligencia artificial (IA) en el cáncer endometrial.

Objetivo

Evaluar la exactitud diagnóstica de las herramientas basadas en IA para la detección del cáncer endometrial, con el fin de proporcionar evidencia para su aplicación en programas de cribado.

Métodos

- **Selección de estudios:** Se incluyeron 13 estudios que evaluaron el rendimiento de la IA en el cribado del cáncer endometrial.
- **Evaluación de la calidad:** Se utilizó la herramienta QUADAS-2 para valorar la calidad de los estudios seleccionados.
- **Análisis estadístico:** Se aplicó el modelo de resumen jerárquico de la curva característica operativa del receptor (HSROC) para calcular la sensibilidad y especificidad global de la IA en el cribado del cáncer endometrial.

Resultados

- **Sensibilidad:** 86% (intervalo de confianza del 95%: 79%-90%).
- **Especificidad:** 92% (intervalo de confianza del 95%: 87%-95%).
- **Calidad de la evidencia:** Baja, según los criterios GRADE, debido a factores como riesgo de sesgo, imprecisión y falta de estudios de alta calidad.

Conclusiones: Las herramientas basadas en IA muestran una alta sensibilidad y especificidad en la detección del cáncer endometrial, lo que sugiere su potencial en programas de cribado. Sin embargo, se requiere realizar estudios poblacionales a gran escala para confirmar su eficacia y mejorar la calidad de la evidencia. En el área de la relación materno-filial, destacamos un estudio relacionado titulado “Effects of Fetal Images Produced in Virtual Reality on Maternal-Fetal Attachment: Randomized Controlled Trial” [7], publicado en

el *Journal of Medical Internet Research* en 2023. Este estudio, realizado por Kyong No Lee, Hyeon Ji Kim, Kiroong Choe, Aeri Cho, Bohyoung Kim, Jinwook Seo, Woojae Myung, Jee Yoon Park y Kyung Joon Oh, investigó el impacto de imágenes fetales generadas en realidad virtual (VR) sobre el apego materno-fetal.

Resumen del Estudio

Objetivo

Evaluar el efecto de imágenes fetales producidas en VR sobre el apego materno-fetal y los síntomas depresivos a través de una aplicación móvil de educación prenatal.


Métodos

Ensayo clínico aleatorizado con dos grupos: uno que utilizó solo la aplicación móvil y otro que, además, visualizó imágenes fetales en VR basadas en ecografías. Ambos grupos completaron cuestionarios antes y después de la intervención para evaluar el apego materno-fetal y los síntomas depresivos.

Resultados

El grupo que utilizó imágenes en VR mostró una puntuación significativamente mayor en la interacción con el feto en comparación con el grupo de control (0.4 frente a 0.1, $P = 0.004$). Además, el 43% de las participantes en el grupo VR aumentaron su puntuación en esta categoría, frente al 13% en el grupo de control ($P = 0.005$). Los cuestionarios de retroalimentación indicaron un aumento en la percepción de la apariencia fetal en el grupo VR.

El proceso de desarrollo del programa.



Conclusiones

El uso de una aplicación móvil con imágenes fetales en VR aumentó significativamente la interacción materna con el feto. Este estudio sugiere que la integración de la realidad virtual en programas de educación prenatal puede ser beneficiosa para fortalecer el vínculo entre la madre y el feto.

7.4 La IA en la Práctica Médica: Experiencia, Perspectiva y Formación

CALIDAD ASISTENCIAL

Dimensiones de la calidad

Definidas por la OMS é Instituto de Medicina:



Seguridad

Evitar unecesasas al paciente



Oportunidad

Atención en tele tiempo atreto



Efectividad

Comprender mejor esencifica vlablé



Equidad

Garantir el mismo nivel de saluturd



Eficiencia

Utilizar recursos en una optima



Atención centrada en el paciente

Respetar las aacien- cias, valores y pacie-

¿Cómo se mide?

Tres inicdicadors de qualita:



Estructura

Proceso

Resultados

- Recursos, personal, tecnologia
- Cómo se debre de: protocolos
- Salud el paciente, complicacio- nes, satisfacción

¿Por qué es clave?



Mejora la experiencia del pacienté



Reducir eventos adversos y errores médicos



Optimizar el uso de recursos



Facilitar la méjora continua de los svios

Desde hace años, los servicios de salud más avanzados, con ánimo de mejora continua, se han adherido a los métodos de control mediante el diseño y la definición de una serie de indicadores. Estos han servido como guía para la mejora y la formación constante de los profesionales, así como para un adecuado control de la calidad del servicio.

La calidad asistencial es el conjunto de características de la atención sanitaria que aseguran que los pacientes reciben la mejor atención posible, de forma efectiva, segura, equitativa y centrada en la persona.

Según la OMS y el Instituto de Medicina de EE. UU., la calidad asistencial debe cumplir con varios principios fundamentales (ver figura):

1. **Seguridad:** Evitar daños innecesarios a los pacientes durante la atención.
2. **Efectividad:** Basarse en la mejor evidencia científica disponible y lograr los resultados deseados.
3. **Oportunidad:** Brindar atención en el momento adecuado, sin demoras evitables.
4. **Eficiencia:** Usar los recursos disponibles de forma óptima, sin despilfarro.
5. **Equidad:** Garantizar el mismo nivel de atención a todas las personas, sin discriminación.
6. **Atención centrada en el paciente:** Respetar las preferencias, valores y necesidades del paciente.

¿Cómo se mide la calidad asistencial? Se mide a través de indicadores de calidad, que pueden ser de tres tipos:

- **Estructura:** Recursos, personal, tecnología.
- **Proceso:** Cómo se brinda la atención (protocolos, tiempos).
- **Resultados:** Salud del paciente, complicaciones, satisfacción.

7.4.1 Experiencia del Paciente: Percepción y Vivencia

1. Mejora en la Comunicación y Accesibilidad

Los asistentes virtuales basados en inteligencia artificial (IA) permiten a los pacientes programar citas médicas, recibir recordatorios de medicamentos e incluso obtener respuestas a preguntas médicas básicas de manera inmediata. Esto optimiza la comunicación entre los pacientes y el sistema de salud, mejorando la accesibilidad y reduciendo la necesidad de desplazarse físicamente a un centro de salud para consultas simples [1].

2. Expectativas y Confianza

La incorporación de la IA en la medicina podría facilitar un enfoque más holístico y preciso, lo que redundaría en una optimización de los resultados y un aumento en la satisfacción del paciente. Sin embargo, las expectativas pueden variar según factores demográficos, como la edad y la educación. Por ejemplo, los pacientes más jóvenes, que suelen estar más familiarizados con la tecnología, pueden tener expectativas más altas en comparación con aquellos que han tenido menos exposición a avances tecnológicos [2].

3. Empatía Artificial y Apoyo Emocional

La empatía artificial o empatía computacional es el desarrollo de sistemas de IA que pueden detectar emociones y responder a ellas de manera empática. Esta tecnología puede percibirse como aterradora o amenazante, pero también podría tener una ventaja significativa sobre los humanos para roles en los que la expresión emocional puede ser importante, como en el sector de la atención médica. Esta faceta no puede obviarse de ninguna manera; es más, en muchas ocasiones forma parte del propio proceso terapéutico. No nos cansaremos de recordar que esta tecnología no deshumaniza la relación

médico-paciente, sino todo lo contrario: el paciente ha de tener la sensación (y de hecho, así es) de que él es el verdadero eje central para todo el sistema sanitario.

7.4.2 Perspectiva del Médico: Integración en la Práctica Asistencial

1. Automatización de Tareas Administrativas

La IA generativa en sanidad se está utilizando para mejorar la eficiencia de los procesos médicos. La tecnología ha asumido tareas que consumen mucho tiempo, como redactar apelaciones a las aseguradoras sanitarias o resumir las notas de los pacientes. Esto permite que los profesionales de la salud se centren más plenamente en sus pacientes [3].

2. Soporte en Tiempo Real Durante las Consultas

Las herramientas impulsadas por IA pueden ofrecer un soporte valioso durante las consultas. Los sistemas de IA pueden analizar los síntomas de un paciente, cruzarlos con bases de datos actualizadas de literatura médica y ofrecer recomendaciones basadas en la evidencia más reciente. Este tipo de apoyo en tiempo real puede ser especialmente útil en situaciones donde los médicos necesitan tomar decisiones rápidas y bien fundamentadas [4]. Adicionalmente, la interconectividad con cualquier centro mundial (de próxima aparición para aquellos centros que lo deseen) brindará la posibilidad de conocer con más detalle y, por ende, con mayores posibilidades de reconocer caminos adecuados para cada patología.

3. Formación y Adaptación Profesional

El Hospital Quirónsalud Málaga organizó una sesión formativa dirigida a médicos y personal de enfermería sobre la aplicación de la IA en la práctica clínica. La sesión abordó el uso real de herramientas de IA generativa, destacando la importancia de la capacitación para todos los profesionales sanitarios [5]. Desde hace pocos meses, no existe programa de congreso o reunión clínica que no incluya en su agenda espacios y discusiones sobre las distintas facetas y desafíos de la IA, y esto consideramos que es muy positivo. Pero recordemos: en pocos años, por no decir meses, a tenor de las bibliografías pertinentes, esta etapa que vivimos durará muy poco y probablemente en 2028 ya será historia. De ahí que se debe estar preparado (muy bien preparado) para que se puedan utilizar generosamente todas estas nuevas tecnologías en beneficio de los enfermos y su entorno.

7.4.3 Investigación y Conocimiento Científico: Avances y Desafíos

1. Desarrollo de Algoritmos Predictivos

Investigadores de Eugin han logrado desarrollar un algoritmo basado en inteligencia artificial que predice con exactitud la probabilidad de embarazo en mujeres que se someten a procesos de reproducción asistida. Además, han conseguido emplear la inteligencia artificial para prescribir medicación con la misma precisión y fiabilidad que un médico [6]. Este es un gran camino que en parte ya se ha recorrido, y prueba de ello es lo que ya presentan los científicos de Eugin. Sin embargo, hemos de mantener nuestros canales de información abiertos porque lo previsto para un pequeño espacio de tiempo puede ser solamente el paso de una estrella fugaz, con más y mejores novedades. Esta combinación, sin embargo, es compleja, dado que se ha de realizar con todos los agentes importantes del proceso, y no siempre es bien aceptada por médicos y/o pacientes. De ahí el gran valor del tiempo y la empatía con la paciente a fin de que se pueda exponer lo que realmente nos proporciona la tecnología.

2. Mejora en la Detección Precoz del Cáncer de Mama

Un estudio pionero publicado en *The Lancet* ha comparado tres técnicas de imagen complementarias para mejorar la detección precoz del cáncer de mama en mujeres con tejido mamario denso. Se concluyó que la resonancia magnética abreviada y la mamografía con contraste superaron significativamente a la ecografía en la detección de tumores. Aunque prometedor, el estudio no evalúa aún el impacto en la mortalidad ni los efectos del posible sobrediagnóstico [7].

7.5 Ética en la Recopilación de Datos, su Uso y su Privacidad

Consideraciones Éticas y Desafíos

- **Confidencialidad de los datos:** Es esencial garantizar la protección de los datos personales y médicos de los pacientes al utilizar herramientas basadas en IA.
- **Deshumanización de la atención:** Es importante equilibrar el uso de la IA con la necesidad de mantener una atención médica humanizada, donde la empatía y la comunicación directa con el paciente sigan siendo prioritarias.
- **Desigualdad en el acceso:** El acceso a tecnologías avanzadas de IA puede variar según la región y el nivel socioeconómico, lo que podría generar disparidades en la calidad de la atención médica recibida.

Desde hace ya un tiempo, al ir leyendo este libro, cada vez más lectores y autores se dan cuenta de que este espacio técnico-terapéutico que se nos abre no será aceptado con la facilidad de otros conocimientos o bases estructurales científicas. Esto obliga a los profesionales a ir incorporando *background*, y a los pacientes a estar informados con la adecuada verbalización de los nuevos procesos y tecnologías. No puede caerse en el error de permitir que tanto médicos como pacientes y el sistema sanitario creen que ya se consiguieron los objetivos terapéuticos que tanto estimularon a nuestros predecesores. Pero tampoco se ha de renunciar a una adecuada información que sea de una ayuda extraordinaria en todos los procesos terapéuticos.

7.5.1 La Formación en Inteligencia Artificial para Médicos: Un Pilar Fundamental

La formación en inteligencia artificial (IA) para médicos es clave para integrar esta tecnología de forma segura y eficaz en la práctica clínica, especialmente en campos especializados como ginecología y obstetricia. Aquí se detalla cómo debería abordarse esta formación, los cambios esperables en la educación médica y las herramientas disponibles para su implementación:

¿Cómo se debe comunicar y formar a los médicos en IA?

A. Enfoque Pedagógico:

- **Lenguaje claro y práctico:** La formación debe evitar tecnicismos excesivos y enfocarse en la aplicación clínica y en las limitaciones éticas y legales de la IA.
- **Ejemplos clínicos reales:** Mostrar casos donde la IA ayuda a la toma de decisiones, diagnóstico o seguimiento para contextualizar el aprendizaje.
- **Capacitación interdisciplinaria:** Incluir a expertos en informática médica, ética, derecho y comunicación para formar a médicos desde diferentes ángulos.
- **Énfasis en pensamiento crítico:** Enseñar a los médicos a evaluar cuándo y cómo confiar en los sistemas de IA, identificando riesgos y posibles sesgos.

B. Competencias Clave a Desarrollar:

- Comprender los principios básicos de IA y *machine learning*.
- Saber interpretar resultados generados por sistemas de IA.
- Conocer los aspectos éticos, legales y de privacidad asociados.
- Capacidad para integrar la IA en el flujo asistencial, sin perder la centralidad del paciente.

¿Cambiará el plan de estudios universitario en medicina y en ginecología/obstetricia?

A. Incorporación de Contenidos en Pregrado:

- Asignaturas específicas o módulos sobre IA, informática médica y ética digital.
- Integración transversal de la IA en asignaturas clínicas: por ejemplo, en ginecología, mostrar cómo se utilizan algoritmos para diagnóstico prenatal o detección de cáncer cervical.
- Prácticas y simulaciones que incluyan herramientas de IA para que los estudiantes las experimenten en entornos controlados.

B. Evolución Curricular:

- Programas que fomenten competencias digitales y adaptabilidad ante tecnologías emergentes.
- Mayor énfasis en habilidades blandas como comunicación y manejo ético, para balancear la tecnología con la atención humana.
- Posible aparición de especializaciones o cursos avanzados en IA aplicada a la medicina.

¿Qué medios tenemos para llevar esta formación a los médicos?

A. Formación Continuada y Educación Médica Permanente:

- **Cursos en línea (MOOCs, *webinars*):** Flexibles, accesibles desde cualquier lugar, con actualizaciones constantes.
- **Talleres presenciales y virtuales:** Con práctica directa en simuladores y herramientas reales.
- **Simulaciones clínicas:** Ambientes controlados donde los médicos puedan interactuar con sistemas de IA y experimentar la toma de decisiones asistida.
- **Aplicaciones educativas y realidad virtual/aumentada:** Para aprendizaje inmersivo y entrenamiento interactivo.

B. Mentoría y Comunidades de Práctica:

- Crear redes de profesionales con conocimientos en IA para compartir experiencias y resolver dudas.
- Programas de *mentoring* con expertos en IA aplicada a ginecología y obstetricia.

¿Cómo plantear la formación continuada en IA para médicos?

Propuesta de Estructura:

- **Módulos básicos:** Introducción a la IA, conceptos fundamentales, aplicaciones en ginecología/obstetricia.
- **Módulos intermedios:** Ética, privacidad, análisis crítico de herramientas y casos clínicos.
- **Módulos avanzados:** Uso práctico de sistemas específicos, interpretación de algoritmos y actualización en nuevas tecnologías.
- **Evaluación continua:** Tests, ejercicios prácticos y casos de estudio para certificar competencias.

- **Feedback y actualización:** Cursos que se actualicen con la evolución rápida de la IA.

Resumen Visual del Plan Formativo

Nivel	Contenido Clave	Metodología
Pregrado	Fundamentos, integración clínica básica	Clases teóricas, simulaciones
Formación continuada	Aplicaciones prácticas, ética, actualización	MOOCs, talleres, <i>webinars</i> , simuladores
Especialización	Uso avanzado y desarrollo de proyectos de IA	Proyectos, mentorías, investigación

En conclusión, no nos cansaremos de decir que la formación en IA debe ser accesible, práctica y actualizada para que los médicos no solo adopten la tecnología, sino que la integren críticamente en su práctica clínica, mejorando la calidad asistencial sin perder la atención humanizada.

7.5.2 Impacto de la IA en la Interacción Médico-Paciente y la Protección de Datos

Vamos a abordar cómo mostrar y comunicar el cambio paradigmático que implica integrar la IA en ginecología y obstetricia, cómo cambia la interacción médico-paciente, y qué herramientas y protocolos aseguran la protección de datos y la confidencialidad.

1. Herramientas para Mostrar el Cambio en el Paradigma IA-Paciente

A. Visualización y Comunicación Transparente

- **Dashboards interactivos:** Mostrar a los pacientes visualizaciones claras y accesibles de sus datos y resultados generados por IA (por ejemplo, gráficos de evolución fetal, mapas de riesgo, etc.).
- **Aplicaciones móviles personalizadas:** *Apps* que expliquen en lenguaje sencillo cómo la IA ayuda en su diagnóstico o tratamiento, con acceso a sus datos en tiempo real.
- **Videos educativos y simuladores:** Material multimedia que explique qué es la IA, cómo funciona en su caso particular y qué beneficios aporta, reduciendo la ansiedad y aumentando la confianza.
- **Consentimiento informado digital:** Herramientas interactivas que expliquen claramente el uso de IA, los datos que se recopilan y para qué se usan, asegurando que el paciente entienda y acepte.

B. Interacción Asistida por IA en la Consulta

- **Chatbots y asistentes virtuales:** Responden preguntas frecuentes o preparan a la paciente para la consulta, optimizando el tiempo y la calidad del encuentro.
- **Soporte en tiempo real para el médico:** La IA ayuda a detectar riesgos o condiciones durante la consulta, que luego el médico explica directamente a la paciente, promoviendo la confianza y el diálogo.

2. ¿Cómo Cambia Nuestra Manera de Interactuar con los Pacientes?

A. Más Empática y Personalizada

- La IA permite anticipar necesidades y riesgos de manera más precisa, lo que facilita un enfoque más personalizado.
- El médico puede dedicar más tiempo a la escucha activa y explicación, apoyado en datos que la IA le ofrece en segundos.
- La comunicación se vuelve más basada en evidencias, lo que ayuda a reducir incertidumbres y miedos.

B. Pacientes más Informados y Participativos

- Las herramientas digitales facilitan que los pacientes accedan a su propia información y comprendan mejor su salud.
- Promueve un modelo de atención colaborativo, donde el paciente se siente parte activa en su cuidado.

3. Protección de Datos y Confidencialidad: ¿Cómo lo Aseguramos?

A. Principios Fundamentales

- **Anonimización y cifrado:** Los datos personales se cifran y anonimizan para que no puedan ser asociados directamente a la paciente en análisis o almacenamiento.
- **Consentimiento informado claro y específico:** Antes de usar sistemas de IA, se debe explicar qué datos se recopilan, con qué finalidad y quién accede a ellos.
- **Cumplimiento normativo:** Las herramientas deben cumplir con normativas locales e internacionales, como GDPR (Europa), HIPAA (EE.UU.) o sus equivalentes locales en cada país.

B. Medidas Técnicas y Organizativas

- **Sistemas seguros de almacenamiento y transmisión:** Uso de servidores protegidos, redes privadas y protocolos seguros.
- **Auditorías y supervisión continua:** Para detectar posibles brechas de seguridad o mal uso de la información.
- **Formación continua del personal:** Para asegurar buenas prácticas en manejo y protección de datos.

Resumen Práctico

Aspecto	Herramientas / Medidas	Beneficios
Comunicación paciente-IA	<i>Dashboards, apps, videos educativos, chatbots</i>	Transparencia, confianza, empoderamiento
Interacción clínica	Soporte IA en consulta, explicaciones basadas en datos	Atención personalizada, reducción incertidumbre
Protección de datos	Cifrado, anonimización, consentimiento, cumplimiento legal	Seguridad, confidencialidad, confianza legal

7.6 Protocolo de Comunicación Médica Integrando IA en Ginecología y Obstetricia

Se presenta a continuación un protocolo de comunicación para médicos en ginecología y obstetricia que integra la IA, con énfasis en transparencia, empatía y protección de datos. Este protocolo puede guiar las consultas para optimizar la interacción con el paciente en el contexto del uso de IA.

1. Preparación Previa a la Consulta

- **Revisión de resultados generados por IA:** Antes de la consulta, el médico revisa los datos y análisis proporcionados por la IA para contextualizar el estado clínico de la paciente.
- **Conocimiento de limitaciones:** Identificar posibles limitaciones o incertidumbres en las predicciones o diagnósticos generados por IA.

2. Introducción y Contextualización

- **Explicar el uso de IA de forma sencilla:**
 - “En su caso, utilizamos una herramienta de inteligencia artificial que analiza sus datos para ayudarnos a detectar y prevenir posibles riesgos de manera más rápida y precisa.”
- **Generar confianza:**
 - “Esto no sustituye mi juicio clínico, sino que es un apoyo que me permite tomar mejores decisiones para su salud.”

3. Presentación de Resultados y Datos

- **Mostrar visualizaciones o resultados de manera clara:**
 - Utilizar gráficos o aplicaciones con datos simplificados que la paciente pueda entender.
- **Invitar a preguntas:**
 - “¿Hay algo de esta información que le gustaría que le explique con más detalle?”

4. Protección de Datos y Consentimiento

- **Informar sobre el manejo de datos:**
 - “Los datos que se usan en la herramienta están protegidos y se manejan cumpliendo estrictamente con la normativa de privacidad para garantizar su confidencialidad.”
- **Solicitar o reafirmar consentimiento:**
 - “¿Está de acuerdo en que usemos estas herramientas para mejorar su diagnóstico y seguimiento?”

5. Explicación del Plan Clínico Personalizado

- **Integrar recomendaciones de IA y criterio médico:**

- “Según la información, y considerando todos los factores, le recomiendo...”
- **Claridad sobre incertidumbres:**
 - “Aunque la herramienta nos ayuda mucho, no es perfecta, y por eso seguimos monitoreando su caso de cerca.”


6. Fomento de la Participación Activa

- **Promover que la paciente participe en la toma de decisiones:**
 - “¿Qué le parece este plan? ¿Tiene dudas o preocupaciones que quiera compartir?”
- **Ofrecer recursos educativos:**
 - “Le puedo enviar enlaces o aplicaciones para que pueda revisar esta información en casa con tranquilidad.”

7. Seguimiento y Disponibilidad

- **Explicar cómo se hará el seguimiento:**
 - “Vamos a utilizar la IA para monitorizar su evolución y detectar cualquier cambio a tiempo.”
- **Dejar canales abiertos para dudas:**
 - “Si tiene alguna duda antes de la próxima consulta, puede contactarme a través de...”

PROTOCOLO DE COMUNICACIÓN MÉDICA INTEGRANDO IA EN GINECOLOGÍA OBSTETICIA



7.6.1 Recomendaciones para la Comunicación del Médico con el Paciente sobre IA

Es fundamental que el médico mantenga un tono empático y centrado en la paciente, validando sus emociones y preocupaciones. Se recomienda evitar tecnicismos complejos, empleando un lenguaje claro y accesible. Es importante reconocer y explicar las limitaciones de la IA para prevenir falsas expectativas y asegurar la comprensión de la paciente mediante el uso de preguntas abiertas y pausas para aclaraciones.

Materiales Visuales para Complementar el Protocolo de Comunicación

A continuación, se presentan tres tipos de materiales visuales, claros y sencillos, diseñados para complementar el protocolo de comunicación con pacientes en ginecología y obstetricia, integrando la Inteligencia Artificial (IA). Estos materiales tienen como objetivo facilitar la comprensión, generar confianza y mejorar la experiencia del paciente.

7.6.1.1 Infografía: ¿Qué es la IA y cómo me ayuda en mi salud ginecológica?

Esta infografía está diseñada para explicar de manera sencilla qué es la IA y cómo se aplica en el campo de la ginecología y obstetricia, abordando las inquietudes comunes de las pacientes.

Contenido Clave:

- **Definición Simple de IA:** Una explicación básica y accesible de qué es la Inteligencia Artificial.
- **Ejemplos Concretos de Uso en Ginecología y Obstetricia:** Ilustraciones prácticas como el análisis de ecografías o la predicción de riesgos.
- **Función del Médico:** Cómo el profesional utiliza la IA como herramienta de apoyo en su diagnóstico.
- **Seguridad y Privacidad de los Datos:** Información sobre las medidas de protección de la información del paciente.
- **Importancia del Consentimiento:** Se resalta el derecho de la paciente a decidir y que la decisión final siempre recae en el médico.

Diseño Sugerido:

- **Iconografía:** Uso de iconos representativos (por ejemplo, un cerebro para IA, una computadora, un médico, un escudo para privacidad).
- **Paleta de Colores y Tipografía:** Colores suaves y una tipografía legible para facilitar la lectura.
- **Estructura:** Distribución en secciones cortas, cada una acompañada de imágenes que refuercen el mensaje.

7.6.1.2 Diagrama de Flujo: Mi camino con la IA en mi consulta ginecológica

Este diagrama de flujo visualiza el proceso de integración de la IA en la consulta ginecológica, mostrando cada paso de forma secuencial.

Pasos Visualizados:

1. **Recopilación de Datos:** Ilustra la obtención de información (ecografías, análisis, historia clínica).
2. **Análisis con IA:** Representación del software detectando patrones.
3. **Revisión del Médico:** El profesional interpreta los resultados y toma una decisión.
4. **Comunicación con la Paciente:** Fase de explicación de los hallazgos.
5. **Seguimiento Personalizado y Monitoreo Continuo:** Pasos para la monitorización a largo plazo.

Elementos Visuales:

- **Conexión entre Pasos:** Flechas que dirigen la secuencia.
- **Figuras Simplificadas:** Representaciones de la paciente, el médico y la computadora.
- **Notas Explicativas:** Pequeñas aclaraciones en cada fase del proceso.

7.6.1.3 Carta Digital o Póster: Compromiso con tu privacidad y seguridad

Este material se enfoca en la privacidad y seguridad de los datos de la paciente, diseñado para ser entregado en formato impreso o digital.

Contenido:

- **Manejo de Datos:** Explicación clara de que los datos se gestionan con la máxima seguridad.
- **Medidas de Protección:** Detalle de las principales medidas (cifrado, anonimización, control de accesos).
- **Derecho a la Información y Consentimiento:** Información sobre el derecho de la paciente a estar informada y a otorgar su consentimiento.
- **Contacto para Dudas:** Un punto de contacto para consultas relacionadas con la privacidad.

Diseño:

- **Claridad y Concisión:** Breve y directo.
- **Símbolos de Seguridad:** Uso de iconos como candados o escudos.
- **Información de Contacto:** Inclusión de datos de contacto y enlaces a las políticas de privacidad.

7.6.1.4 Ejemplo Rápido de Contenido para la Infografía:

¿Qué es la Inteligencia Artificial (IA)?

La IA es una tecnología que asiste a los médicos en el análisis de grandes volúmenes de información, permitiendo la detección de problemas de salud de manera más rápida y precisa.

¿Cómo me ayuda en ginecología y obstetricia?

- Detecta riesgos durante el embarazo.
- Analiza ecografías para identificar posibles complicaciones.
- Contribuye a la personalización de tratamientos.

¿Quién toma las decisiones?

La IA funciona únicamente como apoyo al médico. El profesional de la salud siempre tiene la última palabra y toma las decisiones finales sobre su atención.

¿Mis datos están seguros?

Sí. Su información es protegida con sistemas de seguridad avanzados, garantizando que solo personal autorizado pueda acceder a ella.

¿Puedo negarme a usar IA?

Sí, usted tiene derecho a decidir y siempre será informada sobre el uso de la IA en su atención.

Basado en estudios recientes y revisiones científicas, el uso de la IA en protocolos de asistencia médica y prevención en ginecología y obstetricia ha demostrado resultados prometedores en términos de eficiencia y sensibilidad. La IA mejora la capacidad de detección temprana de patologías, optimiza la interpretación de imágenes diagnósticas como ecografías y mamografías, y facilita la personalización de planes de tratamiento. Estos avances contribuyen a una atención más precisa y oportuna, impactando positivamente en la salud reproductiva de las mujeres.

7.7 Resultados de Eficiencia y Sensibilidad del Uso de IA en Ginecología y Obstetricia

La implementación de la Inteligencia Artificial (IA) en ginecología y obstetricia ha mostrado resultados significativos en términos de eficiencia y sensibilidad diagnóstica y predictiva, según estudios recientes. A continuación, se detallan algunos de los hallazgos más relevantes:

- **Detección Precoz de Cáncer de Cuello Uterino**

- **Estudio:** Aplicación de IA para el análisis de citologías cervicales (Papanicolaou).
- **Resultados:**
 - **Sensibilidad:** Hasta 94-96% para detectar lesiones de alto grado (CIN2+).
 - **Especificidad:** Alrededor del 85-90%.
 - **Eficiencia:** Reducción del tiempo de revisión manual en más del 50%.
- **Fuente:** *Journal of Medical Screening*, 2023.

- **Diagnóstico Prenatal y Detección de Anomalías Fetales**

- **Estudio:** Sistemas de IA aplicados al análisis de ecografías para detectar malformaciones fetales.
- **Resultados:**
 - **Sensibilidad:** 88-92% para detectar anomalías mayores (cardíacas, cerebrales).
 - **Eficiencia:** Reducción del tiempo de interpretación y aumento de la precisión diagnóstica en comparación con ecografías estándar.
- **Fuente:** *Ultrasound in Obstetrics & Gynecology*, 2024.

- **Predicción de Preeclampsia**

- **Estudio:** Modelos predictivos de IA basados en datos clínicos y biomarcadores.
- **Resultados:**
 - **Sensibilidad:** 85-90% para identificar mujeres en riesgo alto de preeclampsia precoz.
 - **Especificidad:** 80-85%.
 - **Impacto:** Permite iniciar medidas preventivas tempranas que reducen complicaciones.
- **Fuente:** *Hypertension in Pregnancy*, 2023.

- **Optimización de Protocolos de Reproducción Asistida**

- **Estudio:** Algoritmos de IA para predecir la probabilidad de embarazo en fertilización *in vitro* (FIV).
- **Resultados:**
 - **Precisión Predictiva:** Mejora del 15-20% respecto a modelos clínicos tradicionales.
 - **Eficiencia:** Mejor selección de tratamientos personalizados, reduciendo ciclos fallidos y costos.
- **Fuente:** *Fertility and Sterility*, 2023.

- **Screening de Cáncer de Mama en Mujeres con Tejido Mamario Denso**

- **Estudio:** Uso de IA para complementar mamografías y resonancias magnéticas.
- **Resultados:**
 - **Sensibilidad Combinada:** Hasta 95% en detección temprana, mejorando la detección sobre mamografía sola (~70-80%).
 - **Eficiencia:** Reducción de falsos positivos y sobrediagnóstico.
- **Fuente:** *The Lancet Oncology*, 2025.

Conclusiones Clave

Aplicación	Sensibilidad (%)	Especificidad (%)	Impacto en Eficiencia
Citología cervical con IA	94-96	85-90	Reducción >50% tiempo revisión manual
Diagnóstico ecográfico fetal	88-92	-	Mejora precisión y tiempo interpretación
Predicción preeclampsia	85-90	80-85	Prevención temprana, reducción complicaciones
Predicción éxito FIV	Mejora 15-20%	-	Selección personalizada, menos ciclos fallidos
Screening cáncer mama (tejido denso)	95	Mejora falsos positivos	Mejor detección temprana, menos sobrediagnóstico

Sin embargo, aunque estas revisiones abordan (parcialmente) la autonomía médica como una barrera para su aceptación, hasta la fecha existe poca investigación centrada principalmente en los efectos de la IA sobre la autonomía médica. Además, dichas revisiones rara vez abordan sistemáticamente tanto las libertades clínicas, sociales y económicas.

En conclusión, se necesita más investigación cualitativa y cuantitativa que se centre explícitamente en la autonomía del médico y aborde todos los componentes relevantes de la misma. Siempre que sea posible, la investigación sobre los efectos de la IA en la autonomía de los médicos debería basarse en experiencias reales con sistemas de IA, en lugar de viñetas, y considerar las diferencias entre los distintos sistemas de IA y entre los médicos en diferentes entornos culturales y geográficos. [6]

7.7.1 Papel Fundamental de las Herramientas de IA en los Programas de Calidad Asistencial

En obstetricia y ginecología, las fuentes de datos son esenciales para la investigación clínica, la práctica médica basada en evidencia, la vigilancia epidemiológica y la mejora de la calidad de la atención. Estas fuentes pueden clasificarse en varias categorías según su origen, propósito y nivel de detalle. A continuación, se describen las principales:

1. Historias Clínicas Electrónicas (HCE)

Son registros digitales que contienen información médica completa de las pacientes. Incluyen datos demográficos, antecedentes gineco-obstétricos, controles prenatales, ecografías, evolución del parto y resultados de laboratorio. Su principal ventaja es el acceso rápido y la trazabilidad de los datos en salud, además de poder integrarse con otros sistemas.

○ Contenido Específico en Obstetricia y Ginecología:

- Edad gestacional, fecha probable de parto.
- Ecografías obstétricas (biometría fetal, líquido amniótico, placenta).
- Registros de monitoreo fetal (cardiotocografía).
- Antecedentes obstétricos: número de embarazos, partos, abortos.
- Resultados de Papanicolaou, colposcopías o biopsias.

○ Ejemplos de Sistemas:

- Epic Systems: Usado en hospitales de EE. UU.
- OpenMRS: Software libre para entornos de bajos recursos.
- SIAIS (México): Sistema institucional de hospitales públicos.

2. Registros Nacionales o Institucionales

Son bases de datos mantenidas por instituciones públicas o privadas para monitorear indicadores de salud materna y reproductiva, así como tendencias en salud sexual y reproductiva a nivel país o región. Son de gran utilidad porque permiten evaluar y vigilar datos como la mortalidad materna, la tasa de cesáreas por región o la incidencia de cáncer de cuello uterino por edad.

3. Encuestas Poblacionales

Consisten en la recolección de datos a nivel nacional mediante encuestas representativas que recogen variables comunes como la edad de inicio sexual, el número de hijos vivos o el acceso al control prenatal o la prevalencia de infecciones de transmisión sexual (ITS). Son estudios transversales representativos de la población que incluyen módulos de salud reproductiva y permiten la evaluación de acceso a servicios, uso de métodos anticonceptivos y prevalencia de enfermedades.

○ Ejemplos:

- DHS (Demographic and Health Surveys): En más de 90 países, incluyen salud materna, uso de anticonceptivos y partos atendidos por personal capacitado.
- ENSANUT (México): Evalúa salud sexual, planificación familiar y embarazo adolescente.

- **Utilidad:** Evaluación de acceso a servicios, uso de métodos anticonceptivos y prevalencia de enfermedades.

4. Registros Clínicos Específicos

Permiten la recolección sistemática de datos sobre condiciones o procedimientos específicos. Reúnen información sobre casos clínicos concretos para un análisis más detallado, con el objetivo de mejora continua, investigación clínica y comparación entre centros.

- **Ejemplos en Ginecología:**

- Registro de casos de endometriosis con intervenciones quirúrgicas.
- Registro de incontinencia urinaria tratada con cirugía.
- Base de datos de pacientes con miomatosis uterina tratadas por histerectomía.

- **Ejemplos en Obstetricia:**

- Base de datos de embarazos gemelares.
- Registro de preeclampsia severa y eclampsia.
- Seguimiento de mujeres con diabetes gestacional.

5. Ensayos Clínicos y Estudios Observacionales

Son investigaciones científicas que recogen datos primarios para evaluar tratamientos, intervenciones o asociaciones. Proveen evidencia de alta calidad sobre seguridad y eficacia, y ofrecen datos originales sobre intervenciones médicas o asociaciones de factores de riesgo.

- **Plataformas:**

- ClinicalTrials.gov: Ensayos clínicos en salud femenina, anticonceptivos, técnicas quirúrgicas.
- PubMed: Artículos de estudios observacionales o de cohortes.

- **Ejemplos:**

- Estudio multicéntrico sobre la eficacia de un DIU hormonal vs. un DIU de cobre.
- Ensayo clínico sobre vacunas para VPH en adolescentes.
- Estudios de cohorte sobre factores de riesgo para parto prematuro.

6. Bases de Datos Internacionales

Son repositorios globales de información sobre salud materna y reproductiva que permiten comparar indicadores a nivel mundial.

- **Fuentes Destacadas:**

- WHO Global Health Observatory: Mortalidad materna, uso de anticonceptivos modernos, atención prenatal.
- UNFPA (Fondo de Población de las Naciones Unidas): Salud reproductiva, violencia de género.
- PAHO/OMS: Indicadores en América Latina sobre cáncer cervicouterino, acceso a servicios obstétricos.

7. Sistemas de Información Hospitalaria (SIH)

Son bases de datos internas utilizadas para la gestión de servicios médicos, que incluyen registros como tiempos de estancia, tasas de complicaciones e indicadores de calidad. Se utilizan para la gestión interna de servicios clínicos y administrativos.

○ Ejemplos de Indicadores en Atención Obstétrica:

- Tasa de hemorragia posparto.
- Incidencia de infecciones postcesárea.
- Tiempo de estancia en sala de recuperación.

○ Ejemplos de Indicadores Ginecológicos:

- Tasa de reintervención quirúrgica.
- Complicaciones de laparoscopia.

8. Publicaciones Científicas y Revisiones Sistemáticas

Son fuentes secundarias que compilan y analizan datos existentes de múltiples fuentes para generar conclusiones generales.

○ Plataformas Clave:

- Cochrane Library: Revisiones sistemáticas sobre métodos anticonceptivos, manejo del trabajo de parto, tratamientos hormonales.
- Scopus y Web of Science: Para metaanálisis ginecológicos.
- SciELO y Redalyc: Investigaciones en español sobre salud materna.

Resumen Gráfico (Opcional para presentación)

Fuente	Ejemplo Específico	Aplicación
HCE	Epic, SIAIS	Seguimiento clínico
Registros nacionales	SINAC, RECCU	Indicadores de salud
Encuestas	DHS, ENSANUT	Evaluación poblacional
Registros clínicos	Base de datos de cesáreas	Investigación hospitalaria
Ensayos	ClinicalTrials.gov	Evidencia terapéutica
Bases internacionales	OMS, UNFPA	Comparación global
SIH	Indicadores de calidad	Gestión de hospitales
Publicaciones	Cochrane, PubMed	Síntesis científica

7.7.2 IA en Ginecología y Obstetricia: Inversión en Talento Humano y Estructuras de Gobernanza para su Implementación Ética y Efectiva

La incorporación de herramientas de Inteligencia Artificial (IA) en ginecología y obstetricia representa una oportunidad para mejorar la precisión diagnóstica, optimizar procesos clínicos, minimizar errores y aumentar la cobertura de servicios de salud reproductiva. Sin embargo, su implementación no puede reducirse a la adquisición de *software* o dispositivos inteligentes; implica una transformación profunda de los equipos de trabajo, los procesos asistenciales y los modelos de gobernanza sanitaria. Para que su uso sea ético, equitativo y eficaz, se requiere un aumento sustancial de los recursos humanos y financieros, así como la incorporación de nuevos perfiles profesionales en los servicios clínicos y en los comités directivos.

Incorporación de Nuevos Perfiles Profesionales

El uso de IA en la práctica clínica exige competencias que exceden la formación médica tradicional. Si bien el personal gineco-obstétrico seguirá siendo el eje central del proceso asistencial, el despliegue de estas tecnologías demanda la participación de perfiles técnicos especializados:

- **Científicos de datos médicos y bioinformáticos clínicos:** Que puedan interpretar modelos algorítmicos y adaptarlos a contextos asistenciales reales.
- **Ingenieros en salud digital y técnicos en interoperabilidad:** Responsables de integrar los sistemas de IA con las historias clínicas electrónicas y mantener la seguridad de los datos.
- **Expertos en ética de la IA y privacidad de datos sanitarios:** Que aseguren que los desarrollos tecnológicos respeten los derechos de las pacientes y cumplan con los marcos regulatorios vigentes.

Simultáneamente, se vuelve indispensable capacitar al personal clínico actual —médicos, ecografistas, personal de enfermería y técnicos— en el uso crítico de la IA, interpretación de sus resultados, limitaciones, y riesgos de sesgo, así como en los aspectos éticos asociados. Estos aspectos son cruciales dada la posibilidad de que, al no controlar de manera adecuada algún dato que pueda significar un factor determinante, se acabe en un error médico-asistencial.

Costos Asociados y Planificación Financiera

La implementación de IA implica una inversión inicial considerable, tanto en infraestructura como en capital humano. A modo de referencia, para un hospital de tercer nivel con servicios gineco-obstétricos de alta complejidad, se estiman los siguientes costos iniciales:

Área de Inversión	Costo Estimado Inicial
Adquisición de <i>software</i> y licencias de IA	USD 100.000 – 250.000
Infraestructura tecnológica (servidores, almacenamiento seguro, conectividad)	USD 50.000 – 150.000
Incorporación de perfiles técnicos (2 a 4 personas)	USD 150.000 – 300.000/año
Programas de formación para el equipo clínico	USD 20.000 – 50.000/año
Auditorías éticas, legales y de protección de datos	USD 15.000 – 30.000

El mantenimiento anual de estos sistemas puede representar entre un 10% y un 20% de la inversión inicial. Si bien estos costos pueden parecer elevados, deben analizarse en función del valor que aportan: mejora en los desenlaces clínicos, reducción de errores, eficiencia operativa y democratización del acceso a diagnósticos especializados.

7.7.3 Infraestructura Necesaria para Disponer de IA en las Técnicas Utilizadas en Obstetricia y Ginecología

Implementar Inteligencia Artificial (IA) en ginecología y obstetricia requiere una infraestructura robusta, que abarque desde dispositivos médicos para la captura de datos hasta plataformas de procesamiento y análisis. A continuación, se detallan los componentes fundamentales de esta infraestructura:

1. Captura de Datos

○ Dispositivos Médicos:

- Ecógrafos digitales con conectividad: Deben generar imágenes de alta calidad en formatos compatibles (DICOM).
- Sensores portátiles: *Wearables* para monitoreo fetal.
- Equipos de resonancia magnética y tomografía computarizada: Para casos más complejos.

○ Digitalización de Datos Clínicos:

- Escáneres para muestras histológicas digitalizadas.
- Integración con sistemas de información hospitalaria (HIS) para acceder a datos clínicos y de laboratorio.

2. Almacenamiento y Gestión de Datos

- Servidores locales o en la nube: Deben cumplir con normativas de protección de datos como HIPAA o GDPR.
- Bases de datos estructuradas: Para almacenar imágenes, marcadores moleculares y registros médicos.
- *Data lakes*: Para integrar datos heterogéneos (imágenes, texto, sensores).

3. Procesamiento y Computación

○ Hardware:

- GPUs (Unidades de Procesamiento Gráfico): Imprescindibles para el entrenamiento de redes neuronales.
- *Edge computing*: Para procesamiento local en tiempo real, útil en clínicas sin conectividad estable.
- Servidores de alto rendimiento: Para análisis complejos y entrenamiento de modelos.

○ Plataformas de Computación en la Nube:

- AWS, Azure o Google Cloud con servicios específicos para IA médica.
- Funcionalidades para *machine learning* (como TensorFlow en Google Cloud o AWS SageMaker).

4. Modelos y Software de IA

- Redes neuronales convolucionales (CNN): Para segmentación y clasificación de imágenes ginecológicas.
- Modelos de *machine learning*: Para la integración de marcadores moleculares y clínicos.
- Sistemas de fusión de datos: Plataformas que combinen información multimodal (imágenes + marcadores).
- *Dashboards* clínicos: Visualización para médicos y personal de salud.

5. Integración y Seguridad

- Sistemas PACS (*Picture Archiving and Communication System*): Integración para el manejo de imágenes médicas.
- Interoperabilidad HL7 y FHIR: Para el intercambio seguro de datos entre sistemas.
- Cifrado de extremo a extremo: Para garantizar la seguridad en la transmisión y almacenamiento de datos médicos.

6. Desarrollo y Entrenamiento de Modelos

- Conjuntos de datos balanceados: Imágenes ginecológicas y marcadores debidamente etiquetados.
- Plataformas de anotación: Herramientas para el etiquetado manual de imágenes por expertos.
- Colaboración con hospitales: Para obtener datos clínicos reales y validar modelos.

7. Capacitación del Personal

- Formación de médicos y personal clínico en el uso de herramientas de IA.
- Capacitación de ingenieros biomédicos en algoritmos de *machine learning* y gestión de imágenes médicas.

Ejemplo de Flujo Completo

Un ecógrafo captura imágenes y las sube automáticamente a la nube. La IA segmenta las estructuras fetales y evalúa el grosor endometrial. Se genera un informe preliminar que alerta al médico en caso de anomalías. Finalmente, el médico revisa los resultados y confirma el diagnóstico asistido por IA.

7.7.4 Limitaciones del Análisis de los Datos Recopilados

El análisis de datos recopilados, especialmente en el ámbito de la salud, enfrenta varias limitaciones que pueden afectar la validez y aplicabilidad de los resultados. A continuación, se presentan las principales limitaciones divididas en categorías relevantes:

1. Limitaciones en la Calidad de los Datos

- **Datos Incompletos:** Falta de información relevante (como antecedentes médicos en historiales clínicos).
- **Errores de Registro:** Datos erróneos o inconsistentes debido a errores humanos o tecnológicos durante la captura.
- **Sesgos en la Recopilación:** Datos desproporcionados de ciertos grupos poblacionales, lo que reduce la generalización.

- **Datos Obsoletos:** Información que no refleja las condiciones actuales o prácticas clínicas actualizadas.

2. Limitaciones Técnicas

- **Heterogeneidad de Formatos:** Incompatibilidad entre distintas fuentes de datos, como registros electrónicos con diferentes estándares.
- **Interoperabilidad:** Dificultad para integrar datos de múltiples instituciones por el uso de sistemas dispares.
- **Recursos Computacionales:** Procesar grandes volúmenes de datos médicos puede requerir infraestructura tecnológica avanzada.

3. Limitaciones Estadísticas y Analíticas

- **Tamaño Muestral Insuficiente:** Bases de datos pequeñas que limitan la validez estadística del análisis.
- **Confusión y Multicolinealidad:** Relaciones complejas entre variables que dificultan la identificación de factores relevantes.
- **Modelos Inapropiados:** Uso de técnicas analíticas que no se ajustan a la naturaleza de los datos (por ejemplo, aplicar regresión lineal en datos no lineales).

4. Limitaciones Éticas y Regulatorias

- **Privacidad de los Datos:** Restricciones legales y éticas para acceder y analizar datos sensibles.
- **Consentimiento Informado:** Dificultad para obtener el consentimiento necesario para el uso de datos históricos.
- **Anonimización Insuficiente:** Riesgo de reidentificación de pacientes si los datos no están adecuadamente protegidos.

5. Limitaciones Contextuales

- **Factores Externos:** Cambios en políticas de salud o prácticas clínicas que afectan la validez del análisis.
- **Generalización Limitada:** Conclusiones que solo aplican a un entorno clínico específico o una población particular.
- **Interpretación Subjetiva:** Sesgos en la interpretación de resultados por parte de los analistas.

6. Limitaciones en la Interpretación de Resultados

- **Asociación vs. Causalidad:** Confundir correlación con causalidad al interpretar los hallazgos.
- **Resultados Contradictorios:** Hallazgos inconsistentes entre estudios que dificultan la toma de decisiones.
- **Falta de Validación:** Confiar en resultados que no han sido replicados o validados en otros contextos.

Ejemplo en el Ámbito de Salud

- **Análisis:** Evaluación de complicaciones obstétricas en diferentes grupos de edad materna.
- **Limitación:** Falta de datos sobre factores socioeconómicos que podrían influir en las complicaciones.
- **Impacto:** El análisis podría concluir erróneamente que la edad es el único factor de riesgo.

7.7.4.1 Estrategias para Mitigar Limitaciones

- **Preprocesamiento de Datos:** Limpieza y estandarización para mejorar la calidad.
- **Técnicas Estadísticas Avanzadas:** Uso de modelos que controlen la confusión y multicolinealidad.
- **Colaboración Interdisciplinaria:** Involucrar a clínicos, estadísticos e ingenieros para interpretar resultados.
- **Cumplimiento Normativo:** Garantizar prácticas éticas y seguras para el manejo de datos sensibles.

7.7.5 Gestión de los Datos en una Unidad con IA

La Inteligencia Artificial (IA) está emergiendo como una herramienta transformadora en el ámbito de la salud, tanto en los programas de formación continuada como en la mejora de la calidad asistencial. A continuación, se presenta un análisis detallado de su interés y potencial impacto:

1. Formación Continuada en Salud

a. Personalización y Adaptabilidad:

- **Evaluación de Competencias:** La IA puede analizar los perfiles individuales de los profesionales de la salud, identificando áreas de fortaleza y aspectos a mejorar. Esto permite diseñar programas formativos personalizados que se adapten al ritmo y estilo de aprendizaje de cada usuario.
- **Contenidos Dinámicos:** Mediante algoritmos de aprendizaje automático, es posible actualizar y adaptar continuamente el material educativo, asegurando que los contenidos se mantengan alineados con los avances científicos y tecnológicos.

b. Simulaciones y Entornos Virtuales:

- **Realidad Virtual y Aumentada:** Herramientas basadas en IA pueden generar escenarios simulados para prácticas clínicas, lo que posibilita un aprendizaje práctico sin poner en riesgo a pacientes.
- **Feedback Inmediato:** La retroalimentación automatizada durante las simulaciones ayuda a detectar errores y a reforzar buenas prácticas, contribuyendo a una curva de aprendizaje más eficiente.

c. Análisis de Desempeño y Retroalimentación:

- **Monitoreo Continuo:** Plataformas que integran IA permiten un seguimiento detallado del progreso del aprendiz, facilitando la identificación de brechas formativas y la implementación de medidas correctivas en tiempo real.

2. Calidad Asistencial en Salud

a. Soporte en la Toma de Decisiones Clínicas:

- **Diagnóstico y Tratamiento:** Los sistemas de IA pueden analizar grandes volúmenes de datos clínicos para ayudar a diagnosticar enfermedades de forma más precisa y sugerir tratamientos personalizados, apoyando a los profesionales en la toma de decisiones.

- **Integración con Historias Clínicas:** Al combinar datos históricos y en tiempo real, estos sistemas permiten identificar patrones y prever complicaciones, mejorando la seguridad del paciente.

b. Optimización de Procesos:

- **Automatización de Tareas Administrativas:** La IA puede reducir la carga administrativa, permitiendo a los profesionales dedicar más tiempo a la atención directa del paciente.
- **Gestión de Recursos:** Algoritmos predictivos ayudan en la asignación eficiente de recursos hospitalarios, lo que puede traducirse en una mejora en la calidad del servicio asistencial.

c. Monitoreo y Seguimiento del Paciente:

- **Telemedicina y Sensores:** Dispositivos inteligentes y plataformas basadas en IA permiten un seguimiento continuo del estado de salud del paciente, facilitando intervenciones tempranas ante signos de alerta.
- **Análisis Predictivo:** La capacidad de prever complicaciones o recaídas mediante el análisis de datos en tiempo real es fundamental para la prevención y el manejo proactivo de enfermedades.

3. Sinergia entre Formación Continuada y Calidad Asistencial

- Mejora Integral:** Una formación continua robusta, potenciada por la IA, no solo actualiza los conocimientos de los profesionales, sino que también repercute directamente en la calidad de la atención.
- Simulación de Escenarios Reales:** La aplicación de simulaciones clínicas fomenta la adquisición de habilidades prácticas que se reflejan en una atención más segura y eficaz.
- Retroalimentación Bidireccional:** Los datos generados en entornos clínicos pueden retroalimentar los programas formativos, permitiendo que estos se ajusten a las necesidades reales y emergentes del campo asistencial.

4. Desafíos y Consideraciones Éticas

- Privacidad y Seguridad de la Información:**
El manejo de datos sensibles requiere protocolos estrictos para garantizar la confidencialidad y la integridad de la información del paciente.
- Aceptación y Capacitación de los Profesionales:**
Es fundamental que los profesionales de la salud reciban una formación adecuada en el uso de estas tecnologías para superar resistencias y garantizar su correcta aplicación.
- Regulación y Gobernanza:**
La implementación de la IA en salud debe ir acompañada de marcos regulatorios que aseguren un uso ético y responsable, evitando sesgos y garantizando la equidad en el acceso a estas innovaciones.

Conclusión

El interés de la IA en los programas de formación continuada y en la calidad asistencial radica en su capacidad para transformar tanto la educación como la práctica clínica. Al personalizar la formación, optimizar procesos y apoyar la toma de decisiones, la IA no solo mejora el desempeño de los profesionales, sino que también potencia una atención más segura, eficaz y centrada en el paciente. La clave estará en integrar estas herramientas de forma ética, garantizando la privacidad y seguridad de la información, y capacitando adecuadamente a los usuarios para maximizar su potencial.

7.7.5.1 Uso de los Datos de IA en los Programas de Calidad Asistencial en Ginecología y Obstetricia

La Inteligencia Artificial (IA) es una herramienta poderosa para mejorar la calidad asistencial en ginecología y obstetricia. Al analizar grandes volúmenes de datos, la IA puede optimizar procesos, mejorar la seguridad del paciente y reducir errores médicos. Su aplicación en programas de calidad asistencial permite evaluar y mejorar los protocolos clínicos, la experiencia del paciente y la eficiencia del sistema de salud.

1. ¿Cómo se Utilizan los Datos de IA en Calidad Asistencial?

Los programas de calidad asistencial buscan medir y mejorar la atención médica, y la IA juega un papel clave al analizar datos en tiempo real y detectar patrones que pueden indicar fallas en la atención o áreas de mejora.

○ Principales Usos:

- Monitorización y Evaluación de Desempeño Clínico.
- Reducción de Errores Médicos y Eventos Adversos.
- Optimización del Flujo de Pacientes y Recursos.
- Medición de Satisfacción y Experiencia del Paciente.
- Detección Temprana de Complicaciones.

Estos datos pueden ser utilizados en los programas de acreditación hospitalaria y en la mejora continua de protocolos clínicos.

2. Aplicaciones Clave de IA en Calidad Asistencial

○ Monitorización y Evaluación del Desempeño Clínico

La IA permite analizar el cumplimiento de protocolos clínicos y detectar desviaciones. Esta es una estrategia fundamental, es decir, disponer de puntos de referencia contrastados, lo que significará una herramienta esencial.

- **Ejemplo:** Un algoritmo de IA puede analizar historias clínicas electrónicas y detectar si se están cumpliendo los protocolos de atención para embarazos de alto riesgo.
- **Beneficio:** Reducción de variabilidad en la práctica clínica y mejora en la calidad del cuidado.

○ Reducción de Errores Médicos y Eventos Adverso

La IA puede detectar patrones en los datos clínicos y alertar sobre riesgos de errores o fallos en la atención.

- **Ejemplo:** Un sistema de IA puede revisar recetas médicas y alertar sobre posibles interacciones peligrosas entre medicamentos para embarazadas.
- **Beneficio:** Mayor seguridad del paciente y reducción de eventos adversos.

○ Optimización del Flujo de Pacientes y Recursos

Los datos de IA pueden predecir picos de demanda en las unidades de ginecología y obstetricia.

- **Ejemplo:** Un modelo predictivo puede analizar el historial de partos y predecir cuántas camas de UCI neonatal se necesitarán en los próximos meses.

- **Beneficio:** Mejor asignación de recursos y reducción del tiempo de espera.

- **Medición de la Satisfacción y Experiencia del Paciente**

El análisis de opiniones de pacientes puede ayudar a mejorar la atención gineco-obstétrica.

- **Ejemplo:** Algoritmos de Procesamiento de Lenguaje Natural (NLP) pueden analizar encuestas de satisfacción para identificar áreas de mejora en la atención al parto.
- **Beneficio:** Mejora de la experiencia del paciente y adaptación de los servicios a sus necesidades.

- **Detección Temprana de Complicaciones Obstétricas**

Los datos de IA pueden identificar factores de riesgo en tiempo real.

- **Ejemplo:** Un sistema de IA puede analizar los signos vitales de una paciente y predecir si está en riesgo de desarrollar preeclampsia antes de que aparezcan síntomas graves.
- **Beneficio:** Detección precoz y reducción de complicaciones materno-fetales.

3. Integración de la IA en Programas de Calidad Asistencial

Para implementar IA en calidad asistencial, se deben seguir estos pasos:

- **Pasos Clave:**

- **Recopilación de Datos:** Historias Clínicas Electrónicas (EHR), imágenes médicas, encuestas de satisfacción.
- **Preprocesamiento:** Limpieza y anonimización de datos.
- **Desarrollo de Modelos de IA:** Predicción de riesgos, análisis de tendencias.
- **Validación Clínica:** Comparar resultados con datos reales de pacientes.
- **Implementación y Monitoreo:** Uso en hospitales con supervisión médica.

- **Herramientas y Tecnologías:**

- *Machine Learning:* TensorFlow, PyTorch.
- *Procesamiento de Lenguaje Natural (NLP):* Para encuestas de satisfacción.
- *Big Data en Salud:* Apache Spark, Google Cloud Healthcare API.
- *Análisis de Imágenes Médicas:* OpenCV, MONAI para mamografías y ecografías.

4. Desafíos Éticos y Regulatorios

El uso de IA en calidad asistencial debe cumplir con normativas de privacidad y ética:

- **Retos y Soluciones:**

- **Privacidad de Datos:** Implementar anonimización y cifrado de datos.
- **Transparencia en la IA:** Explicar decisiones tomadas por los algoritmos.
- **Evitar Sesgos en los Modelos:** Usar bases de datos representativas de toda la población.

- **Cumplir con regulaciones como:**

- HIPAA (EE. UU.): Protección de datos médicos.
- GDPR (Europa): Derecho al acceso y eliminación de datos.
- NOM-024-SSA3-2012 (México): Interoperabilidad en registros electrónicos de salud.

Conclusión

El uso de IA en calidad asistencial en ginecología y obstetricia mejora la seguridad del paciente, optimiza recursos y permite un monitoreo continuo del desempeño clínico. Sin embargo, su implementación debe ser ética, transparente y centrada en el paciente. Todas estas aportaciones relatan sintéticamente los resultados esperados.

7.8 Nuevas Estructuras de Gobernanza y Toma de Decisiones

Más allá de lo operativo, el uso de IA en salud exige revisar la gobernanza institucional. La creación de comités multidisciplinarios que incluyan profesionales clínicos, expertos en tecnología, representantes legales y, de ser posible, actores sociales o representantes de pacientes, es fundamental para:

- Evaluar los algoritmos desde el punto de vista clínico y ético antes de su adopción.
- Supervisar su rendimiento continuo, sesgos y actualización.
- Promover el uso responsable, transparente y seguro de la IA.

La inclusión de estos perfiles en comités directivos y órganos de decisión permite alinear la tecnología con los valores institucionales, garantizar el cumplimiento normativo y asegurar que las decisiones no estén motivadas exclusivamente por criterios comerciales o de eficiencia operativa, sino por el bienestar de las pacientes.

Conclusión

La integración de la inteligencia artificial en ginecología y obstetricia ofrece grandes beneficios potenciales, pero su implementación efectiva requiere más que innovación tecnológica: demanda una inversión sostenida en talento humano, infraestructura, formación y estructuras éticas de gobernanza. Solo mediante un enfoque integral, que contemple tanto el componente técnico como el humano, será posible lograr una transformación digital que sea verdaderamente segura, equitativa y centrada en las personas.

7.8.1 Papel de las Herramientas en los Programas de Calidad Asistencial

El uso de herramientas para la recopilación de datos y la protección de la privacidad desempeña un papel fundamental en los programas de calidad asistencial en el sector salud, incluyendo obstetricia y ginecología. Estas herramientas permiten analizar información de manera segura para mejorar la toma de decisiones clínicas, monitorear el desempeño del sistema y garantizar la atención centrada en el paciente.

Contribuciones a la Calidad Asistencial

- **Identificación de Oportunidades de Mejora:** El análisis de datos permite detectar patrones, identificar eventos adversos y evaluar el cumplimiento de protocolos clínicos.

- **Medición de Indicadores de Calidad:** Herramientas de recolección y procesamiento de datos facilitan el monitoreo de indicadores clave, como tasas de mortalidad materna, infecciones postoperatorias o complicaciones perinatales.
- **Evaluación de la Satisfacción del Paciente:** Los sistemas de encuestas digitales y plataformas de retroalimentación recopilan datos sobre la experiencia del paciente para mejorar los servicios asistenciales.
- **Optimización de Procesos Clínicos:** El análisis de datos permite identificar cuellos de botella en el flujo de atención y mejorar la eficiencia de los servicios.
- **Implementación de Prácticas Basadas en Evidencia:** Los sistemas de gestión de datos permiten integrar evidencia científica en la toma de decisiones clínicas.
- **Evaluación de Resultados Clínicos:** La recopilación sistemática de datos permite comparar resultados clínicos y evaluar el impacto de nuevas intervenciones o protocolos.

Papel de las Herramientas de Privacidad

- **Garantizar el Cumplimiento Normativo:** Herramientas como sistemas de anonimización de datos y cifrado garantizan el cumplimiento de regulaciones como el GDPR, HIPAA y leyes locales de protección de datos.
- **Protección de la Información del Paciente:** Las plataformas seguras evitan accesos no autorizados y minimizan riesgos de fugas de información.
- **Consentimiento Digital:** Sistemas electrónicos que gestionan el consentimiento informado, asegurando el registro y la trazabilidad de las autorizaciones de los pacientes.
- **Auditoría y Trazabilidad:** Herramientas que permiten registrar el acceso y uso de datos, mejorando la responsabilidad y la seguridad de la información.
- **Transferencia Segura de Información:** Protocolos de cifrado para el intercambio de información entre instituciones de salud.

Ejemplos de Herramientas Tecnológicas

- **Sistemas de Historia Clínica Electrónica (HCE):** Epic, Cerner, AthenaHealth.
- **Plataformas de Análisis de Datos Clínicos:** QlikView, Tableau, SAS Health.
- **Sistemas de Gestión de Calidad:** Lean Six Sigma en hospitales.
- **Herramientas de Anonimización de Datos:** Amnesia, ARX Data Anonymization.
- **Plataformas de Recopilación de Datos para Investigación:** REDCap, Castor EDC.
- **Gestores de Consentimiento Digital:** DocuSign, Smartconsent.

Impacto en la Calidad Asistencial

El correcto uso de estas herramientas no solo contribuye a la mejora continua de los servicios, sino que también genera confianza en los pacientes al saber que sus datos son manejados de manera ética y segura. Al mismo tiempo, permiten un enfoque más ágil, transparente y basado en evidencia para brindar atención médica de alta calidad.

A medida que las organizaciones incorporan la Inteligencia Artificial (IA) en sus operaciones, surge la necesidad de establecer estándares de certificación que aseguren su uso ético, seguro y transparente. Estos estándares permiten evaluar y validar los sistemas de IA, garantizando que se ajusten a principios fundamentales de responsabilidad y mitiguen los riesgos asociados. La creación de certificaciones no solo fortalece la confianza en la tecnología, sino que también facilita su adopción responsable, transformando a la sociedad a través de las organizaciones.

AENOR, la entidad líder en certificación en España, opera en 87 países y ha certificado más de 88.000 centros de trabajo en distintos campos como Gestión de la Calidad, Sostenibilidad, Verificación de Información no Financiera, Bienestar Animal, Seguridad y Salud en el Trabajo, Digitalización o *Compliance*. AENOR

es una organización comprometida con estar cerca de las necesidades de sus clientes. "El propósito de AENOR es ayudar a transformar a la sociedad generando confianza entre organizaciones y personas", Rafael García Meiro, CEO de AENOR.

Con sus 13 países alrededor del mundo, incluyendo Brasil, El Salvador, Chile, China, Colombia, Ecuador, Italia, Marruecos, México, Perú, Portugal, Polonia y República Dominicana, AENOR se ha consolidado como una organización global cuya actividad en el ámbito internacional crece año tras año. Además, como entidad española, dispone de 18 sedes distribuidas estratégicamente en España, garantizando su presencia en todas las comunidades autónomas del país.

Certificación en IA Ética y Responsable

Con el fin de cumplir el reto de una implementación de la IA siguiendo la regulación europea, *EU Artificial Intelligence Act*, por parte de las organizaciones, AENOR ha firmado un acuerdo de colaboración con Microsoft para trabajar conjuntamente en el desarrollo de una certificación AENOR para la gestión Ética y Responsable de la IA. Esta certificación se basa en estándares internacionales (como ISO/IEC 24368:20229, Aspectos Sociales y Éticos en la IA) y en tecnología de la compañía. Este certificado se realiza "para que se pueda demostrar la diligencia debida al uso ético de la inteligencia artificial", en palabras de García Meiro.

Las empresas del Grupo AENOR adoptarán la tecnología de IA generativa de Microsoft para acelerar la digitalización en áreas clave como las soluciones de evaluación de la conformidad, formación, distribución de contenidos normativos y consultoría en transformación empresarial. Este acuerdo incluye también la incorporación de la IA generativa en los servicios y productos de AENOR, con el objetivo de modernizar la atención al cliente y optimizar el desarrollo interno, garantizando respuestas más ágiles y eficientes a las necesidades de sus clientes, incluso a gran escala.

Servicios con Microsoft Copilot y Azure OpenAI

AENOR ha integrado la IA de Microsoft en sus soluciones, reafirmando su compromiso con la innovación y la transformación digital. Mediante el uso de los servicios de Microsoft Azure OpenAI, AENOR desarrolla sus propias herramientas y productos, consiguiendo "una increíble mejora de los procesos de negocio en el día a día", según destaca Roxana Barrio, directora de proyectos de AENOR.

Esta integración permite a la organización garantizar la protección y gobernanza de sus datos y aplicaciones de IA, dándose soporte en la *EU Data Boundary* para *Microsoft Cloud*. De esta forma, se asegura que toda la información personal gestionada en la nube cumpla las normativas europeas más estrictas, al ser almacenada y procesada exclusivamente dentro del territorio de la Unión Europea. Asimismo, mediante los servicios avanzados de Microsoft Azure, AENOR ofrece a sus clientes herramientas de seguridad y gestión. (Transcrito del artículo de *El País*).

7.8.2 Optimización de la Seguridad del Paciente: Elementos Clave y Control de Calidad

La seguridad del paciente es un apartado de suma importancia. En todo momento se deben prever los mecanismos y las técnicas que eviten los riesgos hacia el paciente o su intermediación. A continuación, se detallan los elementos esenciales para cumplir con este objetivo:

1. Bases de la Política de Prevención de Riesgos

- **Detección Temprana de Complicaciones:** Algoritmos de IA pueden analizar datos de pacientes en tiempo real para identificar signos tempranos de sepsis, preeclampsia o partos prematuros.
- **Alertas Clínicas Inteligentes:** Modelos predictivos pueden generar alertas antes de que se produzcan eventos adversos.

- **Reducción de Errores Médicos:** Sistemas de IA pueden ayudar a minimizar errores en la medicación y mejorar la precisión en la administración de tratamientos.

2. Mejora de la Eficiencia Operativa

- **Optimización de Recursos Hospitalarios:** Predicción de la ocupación de camas en neonatología y UCI.
- **Automatización de Tareas Administrativas:** Reducción de la carga de trabajo en registros médicos y codificación clínica, permitiendo que los profesionales sanitarios dediquen más tiempo a la atención directa.

3. Análisis de Datos para la Mejora Continua

- **Identificación de Patrones de Calidad Asistencial:** La IA permite evaluar la adherencia a protocolos clínicos y detectar desviaciones.
- **Evaluación de la Satisfacción del Paciente:** Análisis de encuestas y opiniones para identificar áreas de mejora en la atención.
- **Monitorización de Indicadores de Calidad:** Identificación de tendencias en tasas de infecciones nosocomiales, complicaciones obstétricas, etc.

4. Personalización del Cuidado del Paciente

- **Medicina de Precisión:** La IA puede ayudar a personalizar tratamientos con base en características genéticas y clínicas del paciente.
- **Planes de Seguimiento Individualizados:** Modelos predictivos pueden sugerir estrategias de seguimiento para neonatos de alto riesgo o embarazos con complicaciones.

5. Apoyo en la Toma de Decisiones Clínicas

- **Sistemas de Apoyo al Diagnóstico:** Uso de IA en imágenes médicas (ej. detección de anomalías en ecografías fetales).
- **Modelos Predictivos en Obstetricia y Neonatología:** IA para predecir partos prematuros o complicaciones neonatales.

Ejemplo de Aplicación en Quirónsalud

En un hospital como el Quirónsalud de Barcelona, un sistema de IA podría integrarse en los programas de calidad asistencial para:

- Predecir riesgo de complicaciones neonatales en tiempo real.
- Evaluar el impacto de protocolos de atención materno-infantil.
- Optimizar la gestión de recursos en la UCI neonatal.

Desafíos y Consideraciones

- **Ética y Privacidad de los Datos:** Implementación responsable de la IA en salud.
- **Interoperabilidad:** Integración con los sistemas de historia clínica electrónica.
- **Aceptación por Parte del Personal Sanitario:** Formación en el uso de estas herramientas.

Como puede observarse, la IA ha utilizado gran parte de lo descrito con antelación sobre los preceptos y estrategias sobre la calidad de un servicio, pero con una diferencia: no pone límites restrictivos y conjuga en su totalidad lo que en épocas pasadas eran elementos o estrategias de reducido alcance.

Con toda la información disponible, se obtiene una situación muy aproximada a la realidad, y con ello la facilidad de tomar decisiones (que incluso sugiere la IA) para realizar acciones de mejora en todos los campos de la calidad asistencial, añadiendo que la propia IA se autoabastece y se forma en aspectos de la calidad, que en la próxima ocasión en que se utilice, ya se expresan los caminos de la mejoría.

El control de calidad médica en un servicio de ginecología y obstetricia es un proceso fundamental para garantizar la seguridad, la eficacia y la satisfacción de los pacientes. Este control abarca una serie de actividades diseñadas para evaluar, supervisar y mejorar los estándares de atención médica en esta especialidad.

7.8.3 Elementos del Control de Calidad Médica en Ginecología y Obstetricia

1. Estándares de Atención:

- Definir protocolos basados en guías clínicas actualizadas.
- Asegurarse de que los procedimientos estén alineados con las recomendaciones de organizaciones como la FIGO (Federación Internacional de Ginecología y Obstetricia) o la OMS.

2. Evaluación de la Atención Clínica:

- Supervisar indicadores clave, como tasas de complicaciones, infecciones, mortalidad materna y perinatal, entre otros.
- Realizar auditorías regulares de historias clínicas y procedimientos.

3. Capacitación y Competencia del Personal:

- Garantizar que el equipo médico y de enfermería reciba formación continua en técnicas avanzadas y manejo de emergencias obstétricas.
- Evaluar periódicamente la competencia clínica del personal.

4. Seguridad del Paciente:

- Implementar prácticas para reducir errores médicos, como listas de verificación quirúrgicas.
- Promover un entorno de reporte de incidentes y eventos adversos para aprender de ellos y prevenir su recurrencia.

5. Gestión de Recursos:

- Evaluar la disponibilidad y el mantenimiento de equipos médicos críticos (ej. ecógrafos, incubadoras).
- Asegurar un suministro adecuado de medicamentos y material médico esencial.

6. Satisfacción del Paciente:

- Realizar encuestas periódicas para medir la percepción de los pacientes sobre la calidad del servicio.
- Incluir a los pacientes en la toma de decisiones sobre su atención.

7. Auditorías y Evaluaciones Regulares:

- Realizar auditorías internas y externas para evaluar el cumplimiento de estándares.
- Identificar áreas de mejora y establecer planes de acción correctiva.

8. Prevención y Manejo de Emergencias:

- Implementar protocolos de respuesta rápida para emergencias obstétricas, como hemorragias postparto, preeclampsia o parto prematuro.
- Realizar simulacros regulares para fortalecer la coordinación del equipo.

9. Indicadores de Calidad Específicos: Algunos indicadores comunes en ginecología y obstetricia son:

- Tasa de cesáreas.
- Tasa de episiotomías.
- Mortalidad materna y perinatal.
- Morbilidad severa materna.
- Satisfacción del paciente con el manejo del dolor.

10. Ética y Humanización del Servicio:

- Asegurarse de que el trato sea respetuoso y que se respeten los derechos de las pacientes.
- Incluir enfoques culturalmente sensibles y prácticas humanizadas durante el parto.

Herramientas Habituales para el Control de Calidad

- Indicadores de calidad definidos por instituciones como la OMS.
- Auditorías clínicas para evaluar casos específicos.
- Comités de calidad y seguridad del paciente.
- Sistemas de gestión de calidad como ISO 9001.
- Encuestas de satisfacción y análisis de retroalimentación.

Beneficios del Control de Calidad en Ginecología y Obstetricia

- Mejora la seguridad materno-fetal.
- Reduce complicaciones y errores médicos.
- Incrementa la confianza y satisfacción de las pacientes.
- Optimiza el uso de recursos y reduce costos asociados a eventos adversos.

Conclusión

El control de calidad en ginecología y obstetricia no solo se centra en la reducción de complicaciones y la mejora de los resultados clínicos, sino también en ofrecer una experiencia de atención centrada en las pacientes. Es una herramienta clave para garantizar la excelencia en los servicios de salud y la seguridad materno-infantil.

7.9 Indicadores Comunes en Ginecología y Obstetricia

Los indicadores comunes en ginecología y obstetricia son métricas utilizadas para evaluar la calidad, seguridad y eficacia de la atención brindada en esta especialidad médica. Estos indicadores permiten identificar áreas de mejora y garantizar mejores resultados para las pacientes y los recién nacidos.

7.9.1 Indicadores en Obstetricia

7.9.1.1 Indicadores Maternos

- **Mortalidad Materna:** Número de muertes maternas relacionadas con el embarazo, el parto o el puerperio por cada 100,000 nacidos vivos.
- **Morbilidad Materna Extrema (*Near Miss*):** Casos de complicaciones graves que ponen en riesgo la vida de la madre, pero que no resultan en su muerte.
- **Tasa de Cesáreas:** Proporción de nacimientos por cesárea en comparación con el total de partos. La OMS sugiere que esta tasa no debería superar el 10-15%.
- **Tasa de Episiotomías:** Número de episiotomías realizadas en partos vaginales. Un indicador elevado puede sugerir sobreutilización.
- **Hemorragia Postparto:** Número de casos de hemorragias severas (pérdida >500 ml en parto vaginal o >1000 ml en cesárea).
- **Tasa de Preeclampsia/Eclampsia:** Incidencia de trastornos hipertensivos durante el embarazo.

7.9.1.2 Indicadores Fetales y Neonatales

- **Mortalidad Perinatal:** Número de muertes fetales (después de la semana 22 de gestación) y neonatales tempranas (primeros 7 días de vida) por cada 1,000 nacidos vivos.
- **Mortalidad Neonatal:** Número de muertes de neonatos durante los primeros 28 días de vida por cada 1,000 nacidos vivos.
- **Tasa de Partos Prematuros:** Proporción de nacimientos antes de las 37 semanas de gestación.
- **Tasa de Bajo Peso al Nacer:** Porcentaje de recién nacidos con un peso menor a 2,500 gramos.
- **Apgar Menor a 7:** Porcentaje de recién nacidos con una puntuación Apgar menor a 7 al minuto o a los 5 minutos.

7.9.1.3 Indicadores de Procesos

- **Tasa de Inducciones del Parto:** Porcentaje de embarazos en los que se induce el parto.
- **Duración del Trabajo de Parto:** Tiempo promedio del trabajo de parto activo.
- **Uso de Analgesia Epidural:** Proporción de pacientes que reciben analgesia epidural durante el trabajo de parto.
- **Tasa de Transferencias:** Número de pacientes trasladadas a centros de mayor complejidad.

7.9.2 Indicadores en Ginecología

7.9.2.1 Indicadores Quirúrgicos

- **Complicaciones Postquirúrgicas:** Porcentaje de pacientes con infecciones, hemorragias o eventos adversos tras cirugía ginecológica.
- **Reingreso Hospitalario:** Porcentaje de pacientes que reingresan tras una cirugía ginecológica dentro de un periodo definido (ej. 30 días).
- **Duración de Estancia Hospitalaria:** Promedio de días de hospitalización postquirúrgica.

7.9.2.2 Indicadores de Tamizaje y Prevención

- **Cobertura de Papanicolaou (Pap) y HPV:** Proporción de mujeres que reciben pruebas de detección de cáncer cervicouterino en la población objetivo.
- **Cobertura de Mamografías:** Porcentaje de mujeres en la población de riesgo que reciben mamografías de detección.
- **Tasa de Detección Precoz de Cáncer Ginecológico:** Proporción de casos de cáncer detectados en estadios iniciales.

7.9.2.3 Indicadores de Fertilidad y Salud Reproductiva

- **Tasa de Éxito en Tratamientos de Fertilidad:** Porcentaje de embarazos logrados en ciclos de reproducción asistida.
- **Complicaciones de Reproducción Asistida:** Incidencia de embarazos múltiples o síndrome de hiperestimulación ovárica.

7.9.3 Indicadores Transversales

- **Satisfacción del Paciente:**

- Encuestas sobre la experiencia del cuidado, comunicación del personal médico y calidad percibida.

- **Cumplimiento de Protocolos:**

- Evaluación del uso de guías clínicas basadas en evidencia (ej. manejo de preeclampsia, atención humanizada del parto).

- **Eventos Adversos Notificados:**

- Número de incidentes relacionados con la atención médica, como errores de medicación o infecciones nosocomiales.

7.9.4 Importancia de los Indicadores

El monitoreo regular de estos indicadores permite:

- Mejorar la calidad de la atención.
- Identificar problemas y riesgos en los procesos.
- Promover la seguridad de las pacientes y los recién nacidos.
- Optimizar recursos y procedimientos clínicos.

Basado en experiencias previas, a continuación, se presenta un ejemplo del proceso de incorporación de los indicadores de calidad más utilizados en el Hospital Quirónsalud de Barcelona.

Objetivo

Definir y establecer un conjunto de indicadores de calidad específicos para el servicio de Obstetricia y Ginecología, con el objetivo de monitorizar, evaluar y mejorar la calidad asistencial, la seguridad del paciente y la satisfacción de las pacientes y sus familias. Este tipo de indicadores deben evaluarse periódicamente y

compararse con los puntos de referencia que informan las instituciones oficiales (OMS, FIGO, SEGO, instituciones de gobierno, etc.).

7.9.4.1 Indicadores de Seguridad Materna

- **Tasa de Cesáreas:** Porcentaje de partos por cesárea sobre el total de partos.
 - **Objetivo:** Mantener alineada a recomendaciones de la OMS (<25%).
- **Tasa de Episiotomías:** Porcentaje de partos vaginales con episiotomía.
 - **Objetivo:** Evitar episiotomías innecesarias (<15%).
- **Hemorragias Postparto:** Tasa de hemorragias postparto ≥ 1000 ml sobre el total de partos
- **Morbilidad Materna Grave (MMG):** Casos de MMG por cada 1.000 partos (preeclampsia severa, eclampsia, sepsis materna).
- **Mortalidad Materna:** Muertes maternas por 100.000 nacidos vivos.
- **Reingresos Maternos Postparto:** Reingresos de madres en los 30 días postparto.

7.9.4.2 Indicadores de Seguridad Neonatal

- **Tasa de Prematuridad:** Nacidos <37 semanas sobre el total de nacimientos.
- **Tasa de Bajo Peso al Nacer:** Nacidos vivos <2.500 g.
- **Apgar ≤ 7 al Minuto 5:** Porcentaje de recién nacidos con Apgar ≤ 7 al minuto 5.
- **Ingresos en Neonatología:** Ingresos en UCI Neonatal por cada 100 nacidos vivos.
- **Lactancia Materna Exclusiva al Alta:** Recién nacidos con lactancia materna exclusiva al alta.
- **Infecciones Neonatales Nosocomiales:** Infecciones nosocomiales confirmadas por cada 1.000 días de estancia neonatal.

7.9.4.3 Indicadores de Seguridad Quirúrgica en Ginecología

- **Tasa de Complicaciones Quirúrgicas:** Cirugías ginecológicas con complicaciones intra o postoperatorias.
- **Infección del Sitio Quirúrgico (ISQ):** Tasa de infecciones tras cirugía ginecológica.
- **Reingresos Postquirúrgicos:** Reingresos en los 30 días postcirugía ginecológica.
- **Cumplimiento de Checklists de Seguridad:** Porcentaje de *checklists* completadas correctamente en cirugías.

7.9.4.4 Indicadores de Experiencia y Satisfacción

- **Satisfacción de Parto:** Puntuación media de satisfacción de madres tras el parto.
- **Participación en Plan de Parto:** Mujeres que presentan un plan de parto informado.
- **Valoración de Atención Neonatal:** Encuesta específica de atención al recién nacido.

7.9.4.5 Indicadores de Prevención y Cribado Ginecológico

- **Cobertura Cribado Cáncer de Cérvix:** Mujeres atendidas con cribado actualizado (citología o test VPH).
- **Cobertura Cribado Cáncer de Mama:** Mujeres ≥ 50 años con mamografía vigente.

- **Vacunación VPH:** Adolescentes vacunadas según calendario.

7.9.4.6 Indicadores de Calidad Organizativa

- **Tasa de Partos Atendidos por Matronas:** Partos eutócicos atendidos por matronas.
- **Cumplimiento de Protocolos de Inducción:** Inducciones conforme a protocolo.
- **Registro Electrónico Completo:** Historias clínicas obstétricas y ginecológicas con registro completo.

7.9.4.7 Indicadores de Seguridad del Paciente

- **Identificación Correcta Madre-Bebé:** Verificación doble madre-bebé al alta.
- **Profilaxis Antibiótica Precesárea:** Administración correcta de antibióticos antes de cesárea.
- **Eventos Centinela:** Registro y análisis de eventos centinela.

7.9.4.8 Seguimiento y Revisión

- **Frecuencia de Revisión:** Se definirá de acuerdo con los patrones internacionales.
- **Responsables:** Dirección Médica, Servicio de Obstetricia y Ginecología, Supervisión de Enfermería y Comisión de Calidad.
- **Comparación con *Benchmarks*:** De SEGO, OMS y *Joint Commission*.

Así mismo, podemos poner el ejemplo de los métodos de Acreditación Clínica, utilizado en forma de ejercicio y ejemplo.

7.10 Manual de Métodos de Acreditación Clínica

Objetivo

Proporcionar un resumen estructurado y comparativo de los principales métodos de acreditación clínica disponibles a nivel nacional e internacional. Esto facilitará la selección y preparación de procesos de certificación en el Hospital Quirónsalud Barcelona.

7.10.1 Métodos de Acreditación Clínica (Diversos Programas)

1. Joint Commission International (JCI)

- **Reconocimiento:** Internacional.
- **Enfoque:** Seguridad del paciente y mejora continua.
- **Evaluación:** Seguridad quirúrgica, gestión de medicamentos, derechos de pacientes, control de infecciones, gestión clínica y uso de datos para la mejora.
- **Ventaja:** Reconocimiento de prestigio global, lo que facilita la captación de pacientes internacionales.

2. Modelo EFQM (European Foundation for Quality Management)

- **Reconocimiento:** Europa.
- **Enfoque:** Excelencia global de la organización.
- **Evaluación:** Liderazgo, estrategia, personas, procesos y resultados.
- **Ventaja:** Flexibilidad y adaptación a hospitales y servicios específicos.

3. ISO 9001 y Normas Relacionadas con IA

- **Reconocimiento:** Global.
- **Enfoque:** Sistema de gestión de calidad.
- **Evaluación:** Estandarización de procesos clínicos y administrativos, mejora continua y satisfacción de pacientes.
- **Ventaja:** Certificación flexible por servicios (por ejemplo, ginecología, maternidad, neonatología).

A continuación, se presentan algunas normas ISO relevantes para la inteligencia artificial (IA):

- **ISO/IEC 42001:2023:** Estándar internacional que establece un Sistema de Gestión de Inteligencia Artificial (SGIA). Proporciona directrices para el desarrollo y uso responsable de sistemas de IA, asegurando la implementación de tecnologías fiables, transparentes y éticas ([globalsuitesolutions.com](https://www.iso.org/standard/77461.html)).
- **ISO/IEC 23894:** Guía para la gestión de riesgos en IA, que ayuda a las organizaciones a identificar, evaluar y mitigar los riesgos emergentes asociados con el uso de esta tecnología ([isotools.us](https://www.iso.org/standard/77461.html)).
- **ISO/IEC 38507:** Directrices sobre la gobernanza de la IA, asegurando que las organizaciones utilicen sistemas de IA de manera responsable, ética y alineada con las obligaciones legales ([isotools.us](https://www.iso.org/standard/77461.html)).
- **ISO/IEC 25059:** Extiende las características del modelo de calidad de la norma ISO/IEC 25010 para incluir aspectos específicos de los sistemas de IA, enfocándose en la calidad del producto ([iso25000.com](https://www.iso.org/standard/77461.html)).

4. Acreditación SEGO (Sociedad Española de Ginecología y Obstetricia)

- **Reconocimiento:** Nacional (España).
- **Enfoque:** Calidad asistencial específica en Obstetricia y Ginecología.
- **Evaluación:** Protocolos actualizados, indicadores de calidad, formación continuada, seguridad materno-fetal.
- **Ventaja:** Sello especializado para unidades de ginecología y obstetricia.

5. Acreditación QH (Quality Healthcare) – IDIS

- **Reconocimiento:** Nacional (España).
- **Enfoque:** Calidad global.
- **Evaluación:** Programas de calidad y seguridad, certificaciones previas (ISO, JCI), indicadores clínicos, mejora continua.
- **Ventaja:** Enfoque global compatible con otras certificaciones.

6. Acreditación CatSalut (Generalitat de Catalunya)

- **Reconocimiento:** Autonómico (Cataluña).
- **Enfoque:** Calidad y seguridad en centros sanitarios públicos y privados.
- **Evaluación:** Calidad clínica, seguridad del paciente, satisfacción, eficiencia y gestión de información.

- **Ventaja:** Alineación con las políticas sanitarias de Cataluña.

7. Acreditación Magnet (ANCC)

- **Reconocimiento:** Internacional.
- **Enfoque:** Excelencia en cuidados de enfermería.
- **Evaluación:** Práctica basada en evidencia, participación de pacientes, innovación en enfermería.
- **Ventaja:** Potencia la reputación y el atractivo para personal de enfermería especializado.

8. AESIA (Agencia Española de Supervisión de la Inteligencia Artificial)

- **Reconocimiento:** Nacional (España).
- **Enfoque:** Supervisión, asesoramiento y formación en el uso y desarrollo de sistemas de IA.
- **Evaluación:** Implementación de certificaciones para asegurar que los sistemas de IA cumplan con los estándares del Reglamento de Inteligencia Artificial de la Unión Europea, el cual clasifica las aplicaciones de IA por niveles de riesgo y establece requisitos específicos.

7.10.2 Comparativa de Métodos

Método	Alcance	Enfoque	Reconocimiento
JCI	Global	Seguridad y calidad clínica	Muy alto
EFQM	Europa	Excelencia organizativa	Alto
ISO 9001	Global	Gestión de procesos	Alto
SEGO	Nacional	Calidad Obstetricia-Gine	Especializado
QH (IDIS)	Nacional	Calidad global	Medio
CatSalut	Catalunya	Calidad sanitaria integral	Medio
Magnet	Global	Excelencia enfermería	Especializado

7.10.3 Recomendaciones para Quirónsalud Barcelona

- **Prioridad:** Establecer un plan de preparación para la acreditación JCI, dado el perfil internacional de Quirónsalud.
- **Complementario:** Obtener la acreditación SEGO para consolidar el prestigio en el servicio de Obstetricia y Ginecología.
- **Sinergias:** Integrar la norma ISO 9001 en los procesos internos y vincularla a la preparación para JCI.
- **Reconocimiento Regional:** Mantener actualizada la acreditación CatSalut para garantizar el cumplimiento de requisitos locales.

7.10.4 Seguimiento y Actualización

- **Frecuencia de revisión:** Anual.
- **Responsables:** Dirección Médica, Dirección Clínica del Servicio de Ginecología y Obstetricia, Comisión de Calidad y Supervisión de Enfermería.
- **Próxima revisión:** [Fecha por definir]

Consideraciones Futuras: Integración de la Inteligencia Artificial en la Acreditación y Formación

Este repaso informativo queda supeditado, en un futuro inmediato, a la integración de la inteligencia artificial (IA) en los algoritmos y árboles de decisión de las líneas de acreditación. El objetivo es que, en base a los parámetros de todas las organizaciones mencionadas, los procesos puedan ser trabajados y elaborados de manera conjunta, sin tener que discriminar entre los distintos organismos. Este escenario también se presenta como una excelente oportunidad para la formación continuada de los profesionales.

La IA está emergiendo como una herramienta transformadora en el ámbito de la salud, tanto en los programas de formación continuada como en la mejora de la calidad asistencial. A continuación, se presenta un análisis detallado de su interés y potencial impacto:

7.11 Formación Continuada en Salud

a. Personalización y Adaptabilidad

- **Evaluación de Competencias:** La IA puede analizar los perfiles individuales de los profesionales de la salud, identificando áreas de fortaleza y aspectos a mejorar. Esto permite diseñar programas formativos personalizados que se adapten al ritmo y estilo de aprendizaje de cada usuario.
- **Contenidos Dinámicos:** Mediante algoritmos de aprendizaje automático, es posible actualizar y adaptar continuamente el material educativo, asegurando que los contenidos se mantengan alineados con los avances científicos y tecnológicos.

b. Simulaciones y Entornos Virtuales

- **Realidad Virtual y Aumentada:** Herramientas basadas en IA pueden generar escenarios simulados para prácticas clínicas, posibilitando un aprendizaje práctico sin poner en riesgo a los pacientes.
- **Retroalimentación Inmediata:** La retroalimentación automatizada durante las simulaciones ayuda a detectar errores y a reforzar buenas prácticas, contribuyendo a una curva de aprendizaje más eficiente.

c. Análisis de Desempeño y Retroalimentación

- **Monitoreo Continuo:** Plataformas que integran IA permiten un seguimiento detallado del progreso del aprendiz, facilitando la identificación de brechas formativas y la implementación de medidas correctivas en tiempo real.

7.11.1 Calidad Asistencial en Salud

a. Soporte en la Toma de Decisiones Clínicas

- **Diagnóstico y Tratamiento:** Los sistemas de IA pueden analizar grandes volúmenes de datos clínicos para ayudar a diagnosticar enfermedades de forma más precisa y sugerir tratamientos personalizados, apoyando a los profesionales en la toma de decisiones.
- **Integración con Historias Clínicas:** Al combinar datos históricos y en tiempo real, estos sistemas permiten identificar patrones y prever complicaciones, mejorando la seguridad del paciente.

b. Optimización de Procesos

- **Automatización de Tareas Administrativas:** La IA puede reducir la carga administrativa, permitiendo a los profesionales dedicar más tiempo a la atención directa del paciente.
- **Gestión de Recursos:** Algoritmos predictivos ayudan en la asignación eficiente de recursos hospitalarios, lo que puede traducirse en una mejora de la calidad del servicio asistencial.

c. Monitoreo y Seguimiento del Paciente

- **Telemedicina y Sensores:** Dispositivos inteligentes y plataformas basadas en IA permiten un seguimiento continuo del estado de salud del paciente, facilitando intervenciones tempranas ante signos de alerta.
- **Análisis Predictivo:** La capacidad de prever complicaciones o recaídas mediante el análisis de datos en tiempo real es fundamental para la prevención y el manejo proactivo de enfermedades.

7.11.2 Sinergia entre Formación Continuada y Calidad Asistencial

- **Mejora Integral:** Una formación continua robusta, potenciada por la IA, no solo actualiza los conocimientos de los profesionales, sino que también repercute directamente en la calidad de la atención.
- **Simulación de Escenarios Reales:** La aplicación de simulaciones clínicas fomenta la adquisición de habilidades prácticas que se reflejan en una atención más segura y eficaz.
- **Retroalimentación Bidireccional:** Los datos generados en entornos clínicos pueden retroalimentar los programas formativos, permitiendo que estos se ajusten a las necesidades reales y emergentes del campo asistencial.

7.11.3 Desafíos y Consideraciones Éticas

a. Privacidad y Seguridad de la Información

- El manejo de datos sensibles requiere protocolos estrictos para garantizar la confidencialidad y la integridad de la información del paciente.

b. Aceptación y Capacitación de los Profesionales

- Es fundamental que los profesionales de la salud reciban una formación adecuada en el uso de estas tecnologías para superar resistencias y garantizar su correcta aplicación.

c. Regulación y Gobernanza

- La implementación de la IA en salud debe ir acompañada de marcos regulatorios que aseguren un uso ético y responsable, evitando sesgos y garantizando la equidad en el acceso a estas innovaciones.

Conclusión

El interés de la IA en los programas de formación continuada y en la calidad asistencial radica en su capacidad para transformar tanto la educación como la práctica clínica. Al personalizar la formación, optimizar procesos y apoyar la toma de decisiones, la IA no solo mejora el desempeño de los profesionales, sino que también potencia una atención más segura, eficaz y centrada en el paciente. La clave estará en integrar estas herramientas de forma ética, garantizando la privacidad y seguridad de la información, y capacitando adecuadamente a los usuarios para maximizar su potencial.

7.11.4 Formación Continuada en Obstetricia y Ginecología

La formación continuada en obstetricia y ginecología es esencial para mantenerse actualizado en avances médicos, nuevas tecnologías y mejores prácticas en la atención a la salud materno-fetal y ginecológica. Existen diversas opciones para seguir formándose, dependiendo de los objetivos y el nivel de experiencia de cada profesional.

Opciones de Formación Continuada

a. Cursos y Diplomados

- **Sociedades Científicas:** Organismos como la Federación Internacional de Ginecología y Obstetricia (FIGO), la Sociedad Española de Ginecología y Obstetricia (SEGO), el American College of Obstetricians and Gynecologists (ACOG) o la Universidad Autónoma de Nuevo León, ofrecen cursos especializados de alto nivel.
- **Universidades y Hospitales:** Muchas instituciones académicas y centros hospitalarios proporcionan programas de educación continua, algunos incluso disponibles en modalidad en línea.
- **Plataformas de *e-learning*:**
 - Generales: Coursera, edX, FutureLearn (con cursos de universidades como Harvard y Stanford).
 - Específicas de salud: Medscape, UpToDate (para actualizaciones clínicas).
 - De la especialidad: Fetal Medicine Foundation o Gynaecology Academy.

b. Másteres y Especializaciones

Si se busca una formación más avanzada, se puede optar por un máster en ginecología y obstetricia, con especializaciones en áreas como:

- Medicina materno-fetal.
- Reproducción asistida.
- Endoscopia ginecológica.
- Oncología ginecológica.

c. Rotaciones y Estancias Clínicas

Para mejorar habilidades prácticas, es posible realizar rotaciones o *fellowships* en hospitales de referencia, tanto a nivel nacional como internacional.

d. Investigación y Avances en IA Aplicada a la Gineco-Obstetricia

Dado el interés creciente en la inteligencia artificial (IA) aplicada a la salud, se observa un desarrollo significativo en:

- Diagnóstico asistido por IA (por ejemplo, análisis de ecografías con *machine learning*).
- Modelos predictivos para embarazos de alto riesgo.
- Telemedicina e IA en salud reproductiva.
- Interés de la IA en Programas de Formación Continuada y Calidad Asistencial en Salud

La inteligencia artificial (IA) posee un enorme potencial para la formación médica continua y la mejora de la calidad asistencial. Su capacidad para analizar datos, personalizar el aprendizaje y optimizar procesos clínicos la convierte en una herramienta clave para la actualización de los profesionales de la salud.

7.4.11.1 IA en la Formación Médica Continuada

La IA puede transformar la forma en que los profesionales de la salud adquieren y actualizan conocimientos, haciendo la educación médica más efectiva, accesible y personalizada.

Aplicaciones Claves en Formación:

- **Plataformas de aprendizaje personalizadas:** Algoritmos de IA analizan el desempeño y sugieren contenido adaptado a las necesidades de cada médico.
- **Simulaciones y entrenamiento con IA:** Uso de realidad aumentada y modelos de IA para el entrenamiento en cirugías y procedimientos gineco-obstétricos.
- **Asistentes virtuales inteligentes:** *Chatbots* y modelos de procesamiento de lenguaje natural (NLP) que responden preguntas médicas en tiempo real.
- **Análisis de casos clínicos con IA:** Generación de escenarios realistas basados en datos de pacientes reales anonimizados.
 - *Ejemplo: Un sistema de IA en una plataforma de formación médica puede sugerir a un ginecólogo estudiar nuevas guías sobre preeclampsia basándose en su práctica clínica reciente.*

7.4.11.2 IA en la Calidad Asistencial

Los programas de calidad asistencial buscan mejorar la seguridad, la eficiencia y la experiencia del paciente. La IA facilita la detección de errores en la atención, la optimización de flujos de trabajo y el análisis predictivo.

Aplicaciones en Calidad Asistencial:

- **Detección de patrones de errores médicos:** Análisis de historias clínicas para identificar áreas de mejora.
- **Predicción de complicaciones:** Modelos de IA que alertan sobre posibles riesgos en embarazos o cirugías ginecológicas.
- **Optimización de flujos hospitalarios:** Predicción de demanda de camas, urgencias y quirófanos.
- **Monitoreo en tiempo real de calidad asistencial:** *Dashboards* con análisis continuo del desempeño clínico.
 - *Ejemplo: Un hospital usa IA para evaluar el cumplimiento de protocolos en atención prenatal y ajustar estrategias de formación basadas en deficiencias detectadas.*

7.4.11.3 Integración de la IA en Programas de Formación y Calidad

Para una adopción efectiva, se deben considerar los siguientes pasos:

Pasos para la Implementación:

1. **Recopilación de datos clínicos y educativos:** Uso de historias clínicas electrónicas, encuestas y registros de formación.
2. **Desarrollo de algoritmos personalizados:** Modelos de IA adaptados a cada especialidad médica.
3. **Validación clínica:** Comparación de resultados con expertos en salud.
4. **Implementación en hospitales y plataformas:** Integración con sistemas de gestión hospitalaria y plataformas de *e-learning*.
5. **Monitoreo y actualización continua:** Evaluación del impacto y ajuste de los modelos de IA.

Herramientas Tecnológicas:

- Plataformas de *e-learning* con IA: Coursera, UpToDate, Medscape.
- Simuladores de cirugía con IA: Touch Surgery, Osso VR.
- Análisis de calidad con *Big Data*: Google Cloud Healthcare API, Apache Spark.

7.4.11.4 Retos Éticos y Regulatorios

- **Privacidad y protección de datos:** Cumplir con normativas como GDPR, HIPAA y NOM-024-SSA3-2012.
- **Evitar sesgos en la IA:** Entrenar modelos con datos representativos de diversas poblaciones.
- **Explicabilidad de los modelos:** Garantizar que las decisiones de la IA sean comprensibles y justificadas.
- **Supervisión médica:** La IA debe ser una herramienta de apoyo, no un reemplazo de la decisión clínica.

Conclusión

La IA puede revolucionar la formación médica continuada y la calidad asistencial, permitiendo una atención más segura, eficiente y basada en evidencia. Su implementación requiere un enfoque multidisciplinario, integrando tecnología, educación y ética.

7.11.5 Programas de Formación Continuada

Existen una gran variedad de programas de formación continuada que se adaptan a diferentes necesidades y objetivos profesionales. Algunos ejemplos son:

1. **Cursos presenciales:** Clases impartidas en instituciones educativas (universidades, colegios o academias), donde los estudiantes asisten en persona.
2. **Cursos en línea:** Programas educativos disponibles a través de plataformas en línea, que permiten a los estudiantes aprender a su propio ritmo desde cualquier lugar.
3. **Seminarios y talleres:** Eventos cortos e intensivos que abordan temas específicos y permiten la interacción entre los participantes y los expertos.

4. **Conferencias y congresos:** Reuniones de profesionales en un campo determinado, donde se presentan y discuten investigaciones, avances y tendencias.
5. **Programas de certificación:** Cursos diseñados para otorgar una certificación oficial en una habilidad o conocimiento específico, lo que puede mejorar la empleabilidad y el reconocimiento profesional.
6. **Formación interna en empresas:** Programas organizados por las propias empresas para mejorar las habilidades y competencias de sus empleados.
7. **Educación continua en universidades:** Programas ofrecidos por universidades para profesionales que desean actualizar sus conocimientos o adquirir nuevas habilidades sin completar un título académico completo.
8. **Cursos MOOC (*Massive Open Online Courses*):** Cursos en línea masivos y abiertos que ofrecen acceso a contenido educativo de alta calidad de manera gratuita o a bajo costo.
9. **Mentoría y *coaching*:** Programas donde un mentor o *coach* ayuda a los profesionales a desarrollar sus habilidades y alcanzar sus objetivos personales y profesionales.
10. **Cursos de autoaprendizaje:** Materiales educativos, como libros, vídeos y *podcasts*, que permiten a los individuos aprender de manera autodidacta.

En todos y cada uno de estos ejemplos de formación continuada, la IA implica la facilidad de organizar y controlar.

7.12 Aprendizaje Federado en Salud para Preservar la Privacidad

El aprendizaje federado es una técnica de inteligencia artificial que permite entrenar modelos de *machine learning* sin compartir datos sensibles entre instituciones. Es especialmente relevante en el área de la salud, donde la privacidad de los datos de los pacientes es una prioridad. De este tema se profundiza en los primeros capítulos de este libro.

¿Cómo Funciona el Aprendizaje Federado en Salud? (Resumen)

- **Datos locales:** Los datos permanecen en su origen, por ejemplo, en hospitales, clínicas o dispositivos personales (como *wearables*).
- **Entrenamiento descentralizado:** En lugar de enviar los datos a un servidor central, se entrena un modelo en cada institución localmente.
- **Envío de parámetros:** Sólo los parámetros del modelo (como pesos y gradientes) se envían a un servidor central, nunca los datos crudos.
- **Agregación global:** Se combinan los parámetros de todos los modelos locales para mejorar el modelo global, sin comprometer la privacidad de los datos individuales.

Aplicaciones en Salud

- **Diagnóstico asistido por IA:** Modelos de *deep learning* entrenados en múltiples hospitales sin necesidad de compartir datos.
- **Medicina personalizada:** Predicciones basadas en datos de distintos dispositivos sin transferir información personal.
- **Investigación clínica:** Colaboración entre instituciones para mejorar modelos predictivos sin exponer datos sensibles.
- **Monitorización remota:** Entrenamiento de modelos en dispositivos personales como *smartwatches* sin transmitir datos a la nube.

Beneficios en Privacidad y Seguridad

- Cumple normativas como el GDPR y la HIPAA, evitando la transferencia de datos sensibles.
- Reduce riesgos de filtraciones al mantener los datos en su origen.
- Fomenta la colaboración entre instituciones sin comprometer la privacidad de los pacientes.
- Aprovecha datos distribuidos que de otro modo no podrían usarse debido a restricciones legales.

Desafíos y Soluciones

- **Costo computacional:** Se requieren dispositivos con capacidad de cómputo local adecuada.
- **Sesgo de datos:** Algunos hospitales pueden tener datos no representativos; la solución es usar técnicas de balanceo.
- **Comunicación y sincronización:** Requiere una infraestructura robusta para la transferencia de parámetros de manera eficiente.

Herramientas para Aprendizaje Federado en Salud

- TensorFlow Federated (TFF): *Framework* de Google para aprendizaje federado.
- PySyft (de OpenMined): Enfocado en privacidad y seguridad de datos.
- Flower: Plataforma flexible para construir sistemas de aprendizaje federado.

7.12.1 Proyecto Práctico con Aprendizaje Federado en Salud

Aquí se presenta un proyecto práctico de aprendizaje federado en salud, orientado a la predicción de enfermedades a partir de imágenes médicas (por ejemplo, radiografías pulmonares para detectar neumonía).

Proyecto: Diagnóstico de Neumonía con Aprendizaje Federado

- **Objetivo:** Entrenar un modelo de *deep learning* para detectar neumonía en radiografías pulmonares sin compartir datos entre hospitales.

Tecnologías y Herramientas

- Python
- TensorFlow Federated (TFF)
- PyTorch + Flower (alternativa flexible)
- Dataset: *Chest X-Ray* (COVID-19, neumonía, normal)
- Google Colab/Servidor local para entrenamiento y simulación de hospitales

Fases del Proyecto

1. Recopilación y Preprocesamiento de Datos

- a. Se utilizará el *dataset* público de radiografías *Chest X-Ray* (disponible para descargar en Kaggle).
- b. Los datos se dividirán en diferentes nodos (hospitales simulados).
- c. **Pasos clave:**
 - i. Cargar el *dataset* y visualizar imágenes.
 - ii. Aplicar preprocesamiento (escalado, normalización, aumento de datos).
 - iii. Separar datos en hospitales virtuales.

2. Construcción del Modelo de IA

- a. Se utilizará una red neuronal convolucional (CNN) basada en ResNet o EfficientNet.
- b. **Pasos clave:**
 - i. Definir la arquitectura del modelo en TensorFlow o PyTorch.
 - ii. Entrenar y evaluar en datos locales (por hospital).

3. Implementación de Aprendizaje Federado

- a. En lugar de enviar los datos a un servidor central, cada hospital entrena localmente y solo envía los parámetros del modelo.
- b. **Pasos clave:**
 - i. Implementar TensorFlow Federated (TFF) o Flower.
 - ii. Definir un servidor central para la agregación de modelos.
 - iii. Ejecutar rondas de federación y evaluar mejoras.

4. Evaluación y Optimización

- a. Comparar resultados del aprendizaje federado con los del centralizado.
- b. Ajustar hiperparámetros para mejorar la precisión.
- c. Analizar ventajas en privacidad y eficiencia.

5. Resultados Esperados

- a. Modelo de IA capaz de detectar neumonía en radiografías.
- b. Preservación de privacidad sin necesidad de compartir datos.
- c. Comparación de rendimiento entre modelos federados y centralizados.

¿Cómo Empezar?

- **Paso 1:** Descargar y analizar el *dataset*.
- **Paso 2:** Configurar hospitales simulados.
- **Paso 3:** Implementar una CNN para diagnóstico.
- **Paso 4:** Integrar aprendizaje federado.
- **Paso 5:** Evaluar y optimizar el modelo.

7.13 Papel de los Programas de Calidad Asistencial

7.13.1 Acreditaciones

Los programas de calidad asistencial juegan un papel clave en la mejora de la atención sanitaria, garantizando la seguridad del paciente, la eficiencia operativa y el cumplimiento de estándares internacionales. Sus funciones clave incluyen:

1. Seguridad del Paciente

- Reducción de errores médicos y eventos adversos.
- Implementación de protocolos de atención basada en evidencia.
- Monitoreo y control de infecciones nosocomiales.

2. Eficiencia y Optimización de Recursos

- Disminución de tiempos de espera y mejor uso de la infraestructura.
- Gestión eficiente del personal y el equipamiento.
- Reducción de costos sin comprometer la calidad asistencial.

3. Satisfacción del Paciente y Humanización del Servicio

- Evaluación de la experiencia del paciente.
- Implementación de estrategias para mejorar la comunicación médico-paciente.
- Medición de satisfacción a través de encuestas y *feedback*.

4. Cumplimiento Normativo y Acreditaciones

- Asegurar el cumplimiento de normativas nacionales e internacionales.
- Facilitar la obtención de certificaciones de calidad.
- Implementación de auditorías internas y externas.

Beneficios de Obtener Acreditaciones

- Mayor confianza y prestigio ante pacientes e inversores.
- Reducción de riesgos mediante la aplicación de protocolos estrictos.
- Optimización del rendimiento institucional a través de la medición y mejora continua.
- Acceso a mejores oportunidades de financiación y convenios internacionales.

Conclusión

Los programas de calidad asistencial son fundamentales para garantizar una atención segura y eficiente. Su correcta implementación permite cumplir con estándares internacionales y obtener acreditaciones clave, lo que mejora la reputación, la seguridad y la eficiencia de las instituciones sanitarias.

7.13.2 HIMSS Analytics: Evaluación y Certificación de Madurez Digital en Salud

HIMSS Analytics es una organización que evalúa la transformación digital en instituciones de salud mediante un modelo de madurez electrónica llamado EMRAM (*Electronic Medical Record Adoption Model*). Este modelo permite a hospitales y clínicas medir su nivel de adopción de tecnología para mejorar la eficiencia, seguridad y calidad asistencial.

¿Qué es EMRAM?

El *Electronic Medical Record Adoption Model* (EMRAM) de HIMSS es un sistema de evaluación que clasifica a los hospitales en 8 niveles (0 a 7) según su grado de digitalización y uso de tecnología en la asistencia médica.

7.13.2.1 Niveles del Modelo EMRAM

Niveles del Modelo EMRAM

Nivel	Descripción
Nivel 0	No hay digitalización, uso de papel predominante.
Nivel 1	Sistemas digitales básicos (laboratorio, farmacia, radiología).
Nivel 2	Implementación parcial de registros electrónicos, pero sin integración.
Nivel 3	Primeros registros médicos electrónicos (EHR) con interoperabilidad básica.
Nivel 4	CPOE (prescripción electrónica) y soporte clínico en decisiones.
Nivel 5	Integración avanzada de imágenes digitales (PACS).
Nivel 6	Interoperabilidad total, análisis de datos y seguridad avanzada.
Nivel 7	Hospital completamente digitalizado, con uso avanzado de IA y análisis predictivo.

Meta: Alcanzar el Nivel 6 o 7, lo que indica un hospital altamente digitalizado con beneficios en eficiencia, seguridad y toma de decisiones clínicas.

7.13.2.1 Beneficios de HIMSS EMRAM

- **Mayor seguridad del paciente:** Reducción de errores médicos mediante soporte a decisiones clínicas.
- **Eficiencia operativa:** Optimización de flujos de trabajo con tecnología integrada.
- **Mejora en la toma de decisiones:** Uso de análisis de datos en tiempo real para guiar el tratamiento.
- **Interoperabilidad:** Conectividad entre sistemas de información hospitalaria.
- **Mayor confianza y prestigio:** Reconocimiento internacional de calidad digital en salud.

7.13.2.2 Proceso de Certificación HIMSS

1. **Autoevaluación:** Diagnóstico inicial del nivel EMRAM actual.
2. **Plan de implementación:** Estrategia para avanzar en los niveles.
3. **Optimización tecnológica:** Integración de EHR, CPOE, PACS y herramientas de IA.
4. **Auditoría de HIMSS:** Evaluación oficial para certificación.
5. **Reconocimiento:** Otorgamiento del nivel HIMSS correspondiente.

Tiempo estimado: Puede tardar entre 6 meses y 2 años, dependiendo del estado actual del hospital.

7.13.2.3 ¿Cómo Avanzar en EMRAM?

- Implementar un Sistema de Historia Clínica Electrónica (EHR) robusto.
- Incorporar prescripción electrónica (CPOE) para reducir errores.

- Mejorar la seguridad digital y el acceso a la información.
- Usar inteligencia artificial y análisis de datos para soporte clínico.
- Fomentar la interoperabilidad con otros sistemas de salud.

Conclusión

HIMSS EMRAM es un referente en la transformación digital hospitalaria, ayudando a instituciones de salud a mejorar su eficiencia y calidad asistencial mediante la tecnología.

7.14. ¿Se Puede Trabajar con Dos Bases de Datos Distintas a la Vez?

Sí, es totalmente posible trabajar con dos bases de datos distintas a la vez. La implementación depende del entorno y las herramientas que se estén utilizando. Aquí algunos puntos clave:

- **Frameworks y ORMs:** Muchos *frameworks* modernos (como Django, Laravel o Spring) y ORMs (*Object-Relational Mappers*) permiten configurar múltiples conexiones a bases de datos. Por ejemplo, en Django se definen varias bases en el archivo `settings.py` y se utilizan "routers" para determinar a qué base dirigir cada operación. En Laravel, se pueden configurar varias conexiones en `config/database.php` y referenciarlas en las consultas o modelos.
- **Manejo de Transacciones y Consistencia:** Trabajar con dos bases de datos puede complicar el manejo de transacciones, ya que cada base puede tener sus propias reglas y comportamientos. Es importante implementar mecanismos que aseguren la coherencia de datos si las operaciones dependen unas de otras.
- **Casos de Uso:**
 - **Replicación y escalabilidad:** Algunas aplicaciones utilizan una base principal para escritura y otra para lectura.
 - **Integración de datos:** Se pueden combinar datos de diferentes fuentes (por ejemplo, una base de datos SQL y otra NoSQL) para enriquecer la información.

En resumen, con la configuración y las herramientas adecuadas, es viable y común trabajar con múltiples bases de datos en una misma aplicación.

7.15 Infraestructura Necesaria para Disponer de IA en Técnicas de Obstetricia y Ginecología

Implementar inteligencia artificial (IA) en ginecología y obstetricia requiere una infraestructura robusta, que abarque desde dispositivos médicos para la captura de datos hasta plataformas de procesamiento y análisis. A continuación, se detallan los componentes fundamentales de esta infraestructura:

1. Captura de Datos

- **Dispositivos Médicos:**
 - Ecógrafos digitales con conectividad, capaces de generar imágenes de alta calidad en formatos compatibles (DICOM).
 - Sensores portátiles (*wearables*) para monitoreo fetal.

- Equipos de resonancia magnética y tomografía computarizada, para casos más complejos.

- **Digitalización de Datos Clínicos:**

- Escáneres para muestras histológicas digitalizadas.
- Integración con sistemas de información hospitalaria (HIS) para acceder a datos clínicos y de laboratorio.

2. Almacenamiento y Gestión de Datos

- **Servidores:** Locales o en la nube, que deben cumplir con normativas de protección de datos como HIPAA o GDPR.
- **Bases de datos estructuradas:** Para almacenar imágenes, marcadores moleculares y registros médicos.
- **Data lakes:** Para integrar datos heterogéneos (imágenes, texto, sensores).

3. Procesamiento y Computación

- **Hardware:**

- GPUs (Unidades de Procesamiento Gráfico): Imprescindibles para el entrenamiento de redes neuronales.
- *Edge computing*: Para procesamiento local en tiempo real, útil en clínicas sin conectividad estable.
- Servidores de alto rendimiento: Para análisis complejos y entrenamiento de modelos.

- **Plataformas de Computación en la Nube:**

- AWS, Azure o Google Cloud, con servicios específicos para IA médica.
- Funcionalidades para *machine learning* (como TensorFlow en Google Cloud o AWS SageMaker).

4. Modelos y Software de IA

- Redes neuronales convolucionales (CNN): Para segmentación y clasificación de imágenes ginecológicas.
- Modelos de *machine learning*: Para la integración de marcadores moleculares y clínicos.
- Sistemas de fusión de datos: Plataformas que combinen información multimodal (imágenes + marcadores).
- *Dashboards* clínicos: Visualización de resultados para médicos y personal de salud.

5. Integración y Seguridad

- Sistemas PACS (*Picture Archiving and Communication System*): Integración para el manejo de imágenes médicas.
- Interoperabilidad HL7 y FHIR: Para el intercambio seguro de datos entre sistemas.
- Cifrado de extremo a extremo: Para garantizar la seguridad en la transmisión y el almacenamiento de datos médicos.

6. Desarrollo y Entrenamiento de Modelos

- Conjuntos de datos balanceados: Imágenes ginecológicas y marcadores debidamente etiquetados.
- Plataformas de anotación: Herramientas para el etiquetado manual de imágenes por expertos.
- Colaboración con hospitales: Para obtener datos clínicos reales y validar modelos.

7. Capacitación del Personal

- Formación de médicos y personal clínico en el uso de herramientas de IA.
- Capacitación de ingenieros biomédicos en algoritmos de *machine learning* y gestión de imágenes médicas.

Ejemplo de Flujo Completo

1. El ecógrafo captura imágenes y las sube automáticamente a la nube.
2. La IA segmenta las estructuras fetales y evalúa el grosor endometrial.
3. Se genera un informe preliminar que alerta al médico en caso de anomalías.
4. El médico revisa los resultados y confirma el diagnóstico asistido por IA.

7.15.1 Limitaciones del Análisis de los Datos Recopilados

El análisis de datos recopilados, especialmente en el ámbito de la salud, enfrenta varias limitaciones que pueden afectar la validez y aplicabilidad de los resultados. A continuación, se presentan las principales limitaciones, divididas en categorías relevantes:

1. Limitaciones en la Calidad de los Datos

- **Datos incompletos:** Falta de información relevante (como antecedentes médicos en historiales clínicos).
- **Errores de registro:** Datos erróneos o inconsistentes debido a errores humanos o tecnológicos durante la captura.
- **Sesgos en la recopilación:** Datos desproporcionados de ciertos grupos poblacionales, lo que reduce la capacidad de generalización.
- **Datos obsoletos:** Información que no refleja las condiciones actuales o las prácticas clínicas actualizadas.

2. Limitaciones Técnicas

- **Heterogeneidad de formatos:** Incompatibilidad entre distintas fuentes de datos, como registros electrónicos con diferentes estándares.
- **Interoperabilidad:** Dificultad para integrar datos de múltiples instituciones debido al uso de sistemas dispares.
- **Recursos computacionales:** Procesar grandes volúmenes de datos médicos puede requerir una infraestructura tecnológica avanzada.

3. Limitaciones Estadísticas y Analíticas

- **Tamaño muestral insuficiente:** Bases de datos pequeñas que limitan la validez estadística del análisis.

- **Confusión y multicolinealidad:** Relaciones complejas entre variables que dificultan la identificación de factores relevantes.
- **Modelos inapropiados:** Uso de técnicas analíticas que no se ajustan a la naturaleza de los datos (por ejemplo, aplicar regresión lineal en datos no lineales).

4. Limitaciones Éticas y Regulatorias

- **Privacidad de los datos:** Restricciones legales y éticas para acceder y analizar datos sensibles.
- **Consentimiento informado:** Dificultad para obtener el consentimiento necesario para el uso de datos históricos.
- **Anonimización insuficiente:** Riesgo de reidentificación de pacientes si los datos no están adecuadamente protegidos.

5. Limitaciones Contextuales

- **Factores externos:** Cambios en políticas de salud o prácticas clínicas que afectan la validez del análisis.
- **Generalización limitada:** Conclusiones que solo aplican a un entorno clínico específico o una población particular.
- **Interpretación subjetiva:** Sesgos en la interpretación de resultados por parte de los analistas.

6. Limitaciones en la Interpretación de Resultados

- **Asociación vs. causalidad:** Confundir correlación con causalidad al interpretar los hallazgos.
- **Resultados contradictorios:** Hallazgos inconsistentes entre estudios que dificultan la toma de decisiones.
- **Falta de validación:** Confiar en resultados que no han sido replicados o validados en otros contextos.

Ejemplo en el Ámbito de la Salud

- **Análisis:** Evaluación de complicaciones obstétricas en diferentes grupos de edad materna.
- **Limitación:** Falta de datos sobre factores socioeconómicos que podrían influir en las complicaciones.
- **Impacto:** El análisis podría concluir erróneamente que la edad es el único factor de riesgo.

Estrategias para Mitigar Limitaciones

- **Preprocesamiento de datos:** Limpieza y estandarización para mejorar la calidad.
- **Técnicas estadísticas avanzadas:** Uso de modelos que controlen la confusión y la multicolinealidad.
- **Colaboración interdisciplinaria:** Involucrar a clínicos, estadísticos e ingenieros para interpretar resultados.
- **Cumplimiento normativo:** Garantizar prácticas éticas y seguras para el manejo de datos sensibles.

7.16 Administración de los Riesgos en Medicina: Conceptos Básicos

La administración de riesgos en medicina es un conjunto de procesos destinados a identificar, evaluar y minimizar los riesgos que puedan afectar la seguridad de los pacientes, el personal sanitario y la calidad de la atención médica. A continuación, se resumen los conceptos básicos:

¿Qué es el Riesgo en Medicina?

El riesgo es la probabilidad de que ocurra un evento adverso que pueda causar daño a un paciente, un profesional o al funcionamiento del sistema sanitario.

Objetivo de la Administración de Riesgos

- Prevenir errores médicos y eventos adversos.
- Mejorar la calidad y la seguridad de la atención.
- Reducir los costos asociados a negligencias o reclamaciones.
- Cumplir con normativas legales y éticas.

Pasos Básicos de la Administración de Riesgos

1. **Identificación del Riesgo:** Ejemplos incluyen errores de medicación, infecciones nosocomiales, fallos de equipos, errores diagnósticos.
2. **Análisis del Riesgo:** Evaluar la frecuencia y la gravedad del riesgo. Herramientas comunes son las matrices de riesgo y el análisis causa-raíz.
3. **Evaluación del Riesgo:** Determinar si el riesgo es aceptable o si necesita intervención.
4. **Control y Mitigación del Riesgo:** Implementar protocolos, *checklists*, formación del personal, y el uso de tecnología (por ejemplo, sistemas de alerta).
5. **Monitoreo y Revisión:** Evaluar la eficacia de las medidas tomadas, lo que permite la retroalimentación y la mejora continua.

Tipos Comunes de Riesgos en Medicina

- **Riesgos clínicos:** Errores en tratamientos, diagnósticos o procedimientos.
- **Riesgos legales:** Demandas por mala praxis.
- **Riesgos operativos:** Fallos en procesos internos, errores administrativos.
- **Riesgos tecnológicos:** Mal funcionamiento de equipos médicos o *software*.
- **Riesgos humanos:** Comunicación deficiente, fatiga del personal.

Herramientas Clave

- Eventos centinela y notificación de incidentes.
- Análisis causa-raíz (*Root Cause Analysis* - RCA).
- FMEA (*Failure Mode and Effects Analysis*).
- *Checklists* quirúrgicos (por ejemplo, la lista de verificación de la OMS).
- Comités de seguridad del paciente.

7.17 ¿Cómo Puede Ayudar la IA en la Prevención de Riesgos en Medicina?

La inteligencia artificial (IA) puede ser una herramienta muy poderosa en la prevención de riesgos en medicina, especialmente en entornos hospitalarios complejos. A continuación, se resume cómo puede ayudar en diferentes áreas:

1. Detección Temprana de Eventos Adversos

La IA puede analizar historias clínicas electrónicas en tiempo real para identificar patrones que anticipan complicaciones (como infecciones, caídas, eventos cardiovasculares, etc.).

- *Ejemplo: Un algoritmo predice el riesgo de sepsis 12-24 horas antes de que aparezcan síntomas clínicos claros.*

2. Apoyo a la Toma de Decisiones Clínicas

Los sistemas de IA pueden alertar sobre interacciones medicamentosas, dosis inadecuadas o alergias. Ayudan a elegir el tratamiento más seguro según las características del paciente.

- *Ejemplo: Alertas inteligentes para prevenir errores de medicación en neonatología.*

3. Monitoreo Continuo de Pacientes

Los sensores y la IA permiten vigilar constantes vitales en tiempo real y detectar alteraciones antes de que se conviertan en emergencias.

- *Ejemplo: IA integrada en monitores en UCIs que alerta sobre deterioro clínico.*

4. Análisis Predictivo de Riesgos

Algoritmos que calculan el riesgo de reingreso hospitalario, caídas, úlceras por presión, entre otros, lo que ayuda a priorizar intervenciones preventivas.

- *Ejemplo: Modelos que predicen el riesgo de parto prematuro en obstetricia.*

5. Revisión Automatizada de Procesos y Errores

La IA puede revisar miles de registros clínicos para encontrar errores sistemáticos o cuellos de botella, lo que ayuda a mejorar protocolos y prevenir eventos repetitivos.

6. Mejora de la Comunicación Clínica

Asistentes inteligentes pueden facilitar la documentación médica y reducir errores por mala comunicación o duplicidad, mediante traducción automática, resúmenes clínicos o asistentes conversacionales.

¿Qué se Necesita para Aplicar IA en la Prevención de Riesgos?

- Datos clínicos estructurados y bien registrados.
- Infraestructura digital (HCE, sensores, interoperabilidad).

- Colaboración entre personal clínico, técnicos y expertos en IA.
- Ética, transparencia y explicabilidad de los modelos.

Ejemplos Reales

Hospital / Proyecto	Aplicación IA	Resultado
Hospital General de Massachusetts	IA para predecir sepsis	Reducción de mortalidad
Stanford Health Care	Detección de errores en medicación	Disminución de eventos adversos
Mount Sinai (NY)	IA para deterioro clínico en planta	Mejora en tiempos de respuesta

Caso Práctico Adaptado: Proyecto Piloto "IA para Detección Temprana de Riesgo de Sepsis Neonatal"

Objetivo: Desarrollar o implementar un modelo de IA que identifique recién nacidos con alto riesgo de desarrollar sepsis en las primeras horas/días de vida, utilizando datos clínicos disponibles de forma rutinaria.

Justificación:

- La sepsis neonatal tiene alta morbilidad y mortalidad, y su diagnóstico precoz es difícil.
- Las manifestaciones clínicas iniciales son inespecíficas.
- Un sistema basado en IA puede detectar patrones sutiles en constantes, analíticas y antecedentes que predicen el riesgo de sepsis antes de que sea clínicamente evidente.

Variables que Puede Usar el Modelo de IA:

- **Datos maternos:** Fiebre intraparto, corioamnionitis, colonización por estreptococo, duración de rotura de membranas.
- **Datos neonatales:** Apgar, peso, edad gestacional, tipo de parto.
- **Signos vitales:** Frecuencia cardíaca, temperatura, frecuencia respiratoria.
- **Analíticas tempranas:** PCR, leucocitos, procalcitonina.

¿Cómo Funcionaría?

1. **Recolección de datos:** Anónimos y estructurados, de recién nacidos ingresados.
2. **Entrenamiento del modelo:** Usando *machine learning* (por ejemplo, árboles de decisión, XGBoost o redes neuronales simples).
3. **Validación:** Evaluar precisión, sensibilidad y especificidad.
4. **Implementación inicial (modo sombra):** El sistema emite alertas de riesgo, pero sin intervenir aún en la clínica.
5. **Evaluación del impacto clínico:** ¿Se mejora el tiempo de detección y tratamiento? ¿Se reducen las complicaciones?

Posibles Beneficios:

- Diagnóstico más temprano de sepsis.
- Uso más racional de antibióticos.

- Menor estancia hospitalaria.
- Mejora de la seguridad del paciente.

¿Qué se Necesita para Empezar?

Recurso	Descripción
Datos	Hojas clínicas neonatales y maternas estructuradas (mínimo 200-500 casos).
Soporte técnico	Colaboración con ingeniero de datos o bioinformático.
Comité ético	Aprobación para uso de datos anónimos.
Software	Python (<i>scikit-learn</i> , <i>pandas</i>) o plataforma como DataRobot, Google AutoML.

7.18 Aprendizaje Federado en Salud para Preservar la Privacidad

El aprendizaje federado (*Federated Learning*, FL), como se ha explicado anteriormente, es una técnica de entrenamiento de modelos de inteligencia artificial que permite a múltiples entidades (como hospitales, clínicas o laboratorios) colaborar en la mejora de un modelo sin compartir los datos de los pacientes. En el ámbito de la salud, esta metodología es crucial para preservar la privacidad y cumplir con normativas como el GDPR en Europa y la HIPAA en EE. UU.

¿Cómo Funciona el Aprendizaje Federado en Salud?

- **Entrenamiento distribuido:**
 - Los datos permanecen en los hospitales o centros de salud.
 - Un modelo inicial se envía a cada entidad para que lo entrenen localmente con sus propios datos.
- **Agregación de modelos:**
 - Solo los parámetros aprendidos (pesos del modelo) se envían a un servidor central.
 - Este servidor agrega los modelos locales para actualizar un modelo global sin nunca acceder a los datos originales.
- **Actualización y repetición:**
 - El proceso se repite en varias rondas hasta que el modelo converge y mejora su rendimiento.

Beneficios en Salud

- **Preservación de la privacidad:** No es necesario compartir datos de los pacientes.
- **Cumplimiento normativo:** Se ajusta a regulaciones de protección de datos.
- **Mejor colaboración:** Permite entrenar modelos con datos de múltiples hospitales sin riesgo legal.
- **Reducción del sesgo:** Al involucrar distintos hospitales, se evitan sesgos por datos limitados a una única institución.

Casos de Uso en Obstetricia y Neonatología

- **Diagnóstico de complicaciones neonatales:** Modelos entrenados con datos de varios hospitales pueden mejorar la detección de prematuridad, bajo peso al nacer o problemas respiratorios.
- **Imágenes médicas:** Uso en ecografías para mejorar el diagnóstico de anomalías fetales sin comprometer la privacidad de los datos.
- **Predicción de riesgos en embarazo:** Modelos para predecir preeclampsia, diabetes gestacional o partos prematuros con datos de distintas regiones.

7.18.1 Herramientas para Implementar Aprendizaje Federado en Salud

- Google TensorFlow Federated (TFF): *Open-source* para FL con IA.
- PySyft (OpenMined): *Framework* especializado en privacidad y FL.
- IBM Federated Learning: Solución empresarial para FL en salud.
- Flower: *Framework* flexible para FL en diversas plataformas.

7.19 Cómo Aplicar IA en la Gestión de un Servicio Clínico

La inteligencia artificial (IA) puede transformar la gestión de un servicio clínico al optimizar procesos, mejorar la precisión en diagnósticos, personalizar el tratamiento de pacientes y aumentar la eficiencia administrativa. Aquí se presentan algunos de los principales usos y aplicaciones prácticas:

1. Optimización de la Gestión Administrativa

- **Automatización de Tareas Repetitivas:** La IA puede agilizar tareas administrativas rutinarias, como la programación de citas, recordatorios automáticos a los pacientes y la facturación. Los *chat-bots*, por ejemplo, pueden gestionar las consultas comunes y realizar seguimientos.
- **Mejora en la Programación y Gestión de Recursos:** Algoritmos de IA pueden analizar datos históricos para predecir el flujo de pacientes, ayudando a planificar la dotación de personal y la gestión de insumos, optimizando el uso de recursos y minimizando los tiempos de espera.
- **Codificación y Facturación Automatizadas:** La IA permite la codificación automática de procedimientos médicos en los registros para la facturación, reduciendo errores y asegurando el cumplimiento de las normativas de seguros.

2. Diagnóstico Asistido por IA

- **Imagenología Médica:** La IA es especialmente útil en el análisis de imágenes médicas como radiografías, tomografías y resonancias magnéticas. Algoritmos de aprendizaje profundo pueden detectar patrones y anomalías, como tumores o fracturas, a menudo con una precisión igual o superior a la de los radiólogos.
- **Asistencia en Diagnóstico Clínico:** La IA puede analizar datos médicos de los pacientes (historial, síntomas, resultados de pruebas) para apoyar en el diagnóstico, recomendando posibles diagnósticos diferenciales y ayudando a los médicos a tomar decisiones más informadas.

3. Gestión Personalizada del Cuidado del Paciente

- **Monitoreo y Seguimiento Remoto:** Los dispositivos de monitoreo remoto pueden recopilar datos en tiempo real sobre los signos vitales del paciente. La IA permite analizar estos datos y detectar

cambios que sugieren complicaciones o recaídas, activando alertas tempranas para que el equipo médico pueda intervenir.

- **Sistemas de Recomendación para Tratamientos Personalizados:** La IA puede analizar grandes volúmenes de datos clínicos para recomendar tratamientos personalizados basados en las características individuales del paciente, como su genética, estilo de vida y respuesta a tratamientos previos.
- **Asistente Virtual de Cuidado de la Salud:** Los asistentes de IA pueden ofrecer educación personalizada a los pacientes y recordarles cuándo deben tomar sus medicamentos o realizar ciertas actividades, mejorando la adherencia al tratamiento y reduciendo la tasa de reingreso.

4. Análisis Predictivo y Prevención de Enfermedades

- **Predicción de Riesgos y Pronósticos de Salud:** Los algoritmos de IA pueden analizar patrones en datos de salud para predecir el riesgo de enfermedades crónicas (como diabetes o enfermedades cardíacas) y permitir intervenciones preventivas a tiempo.
- **Modelos Predictivos para Complicaciones:** La IA puede identificar a los pacientes con mayor probabilidad de desarrollar complicaciones durante su tratamiento o cirugía, permitiendo que los equipos médicos tomen precauciones adicionales.

5. Optimización en la Gestión de Medicamentos e Insumos

- **Predicción de Demanda de Medicamentos e Insumos Médicos:** La IA puede predecir el consumo de insumos médicos y medicamentos basándose en datos históricos y patrones estacionales, ayudando a reducir el desperdicio y optimizando el almacenamiento.
- **Automatización de la Dispensación de Medicamentos:** En los servicios clínicos, los sistemas de IA pueden optimizar la administración de medicamentos en las unidades de internación, verificando automáticamente las dosis y alertando sobre posibles interacciones medicamentosas.

6. Apoyo en la Toma de Decisiones Clínicas

- **Sistemas de Apoyo en la Toma de Decisiones:** Las plataformas de IA pueden analizar rápidamente información médica en tiempo real y datos de investigación para dar recomendaciones en situaciones complejas, ayudando a los médicos a decidir el tratamiento más adecuado.
- **Análisis de Datos de Salud Pública:** La IA también puede ayudar a los servicios clínicos a detectar patrones y tendencias en datos de salud pública, como brotes de enfermedades, para tomar decisiones informadas sobre prevención y respuesta.

7. Investigación y Mejora Continua del Servicio Clínico

- **Análisis de Datos para Identificar Áreas de Mejora:** La IA puede analizar datos sobre el desempeño del servicio clínico y señalar áreas donde se pueden hacer ajustes para mejorar la eficiencia y la calidad del servicio.
- **Optimización de Protocolos Clínicos:** La IA puede analizar resultados de tratamientos para identificar los protocolos más eficaces y sugerir mejoras. Esta retroalimentación continua ayuda a actualizar y optimizar la práctica clínica.

8. Consideraciones Éticas y de Seguridad

- **Privacidad y Seguridad de los Datos:** Es fundamental asegurar que el uso de IA cumpla con los estándares de privacidad y seguridad de los datos de los pacientes. Esto incluye implementar sistemas de protección para evitar el acceso no autorizado.

- **Toma de Decisiones Transparente y Responsable:** Es importante que el personal médico mantenga un control final sobre las decisiones clínicas, evitando la dependencia absoluta de la IA y garantizando que los pacientes reciban un trato ético y personalizado.

Implementar IA en la gestión de servicios clínicos requiere también invertir en capacitación del personal y en infraestructura tecnológica adecuada. Cuando se aplica de manera ética y responsable, la IA puede mejorar sustancialmente la calidad de atención, reducir costos y optimizar la eficiencia en la atención al paciente.

Bibliografía

- [1] Medina Ruiz L, Chahla RE, Vega IM, Ortega ES, Barrenechea GG, Ferre Contreras M. Inteligencia artificial: precisión diagnóstica de lesiones preneoplásicas de cérvix uterino. *Medicina* (Buenos Aires). 2024;84:459-467.
 - [2] ElHuffPost. Inteligencia artificial y cáncer de mama: el sistema valenciano que mejora los diagnósticos. [Internet]. [Citado 2024 mayo 15]. Disponible en: https://www.huffingtonpost.es/entry/inteligencia-artificial-y-cancer-de-mama-el-sistema-valenciano-que-mejora-los-diagnosticos_es_6633d7b8e4b09e205164f9b8
 - [3] Enlace Judío. Inteligencia Artificial en Obstetricia y Ginecología: Predicción de Preeclampsia y Hemorragias Postparto. [Internet]. [Citado 2024 mayo 15]. Disponible en: <https://www.enlacejudio.com/2024/05/01/inteligencia-artificial-en-obstetricia-y-ginecologia-prediccion-de-preeclampsia-y-hemorragias-postparto/>
 - [4] Healio. AI holds 'transformative potential' for gynecology, obstetrics and menopause care. [Internet]. Wong J, et al. [Citado 2024 mayo 15]. Disponible en: <https://www.healio.com/news/ob-gyn/20240422/ai-holds-transformative-potential-for-gynecology-obstetrics-and-menopause-care>
 - [5] Moro S, et al. Application of artificial intelligence to ultrasound imaging for benign gynecological disorders: systematic review. *Ultrasound in Obstetrics & Gynecology*. 2025.
 - [6] Grosser J, Düvel J, Hasemann L, Schneider E, Greiner W. Estudio de los efectos potenciales de la inteligencia artificial en los médicos Autonomía: Revisión del alcance. Departamento de Economía de la Salud y Gestión de la Atención Sanitaria, Facultad de Salud Pública, Universidad de Bielefeld, Bielefeld, Alemania Centro de Investigación Electrónica en Salud Pública (CePHR), Facultad de Salud Pública, Universidad de Bielefeld, Bielefeld, Alemania.
1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25(1):44–56.
 2. WHO. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: World Health Organization; 2021.
 3. Morley J, Luciano F. Designing a multi-stakeholder governance framework for the ethical implementation of AI in healthcare. *AI & Society*. 2022;37(1):85–97.
 4. Panch T, Mattie H, Atun R. Artificial intelligence and algorithmic bias: implications for health systems. *J Glob Health*. 2019;9(2):020318.
 5. Mesko B, Gyorffy Z. The rise of the empowered physician in the digital health era: Viewpoint. *J Med Internet Res*. 2019;21(3):e12490.
 6. Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. *Science*. 2019;366(6464):447–53.
 7. Mittelstadt BD. Principles alone cannot guarantee ethical AI. *Nat Mach Intell*. 2019;1(11):501–7.

8. RETOS Y LIMITACIONES DE LA IA EN OBSTETRICIA Y GINECOLOGÍA

8. Retos y limitaciones de la IA en obstetricia y ginecología

Rodrigo Orozco Fernández

8.1. Barreras técnicas y de integración clínica

8.1.1. Introducción

La inteligencia artificial (IA) representa una de las herramientas más prometedoras para transformar la atención en obstetricia y ginecología. Desde el análisis de imágenes ecográficas hasta la predicción de complicaciones perinatales o la automatización de flujos asistenciales, sus aplicaciones potenciales han captado el interés de profesionales, instituciones y sistemas de salud. Sin embargo, esta revolución tecnológica se enfrenta a un conjunto de barreras que dificultan su integración plena en la práctica clínica diaria.

A diferencia de otras disciplinas médicas más estandarizadas, la obstetricia y la ginecología presentan una enorme variabilidad clínica, riqueza contextual y una profunda dimensión humana en la relación médico-paciente, lo que exige que las soluciones tecnológicas sean no solo precisas, sino también adaptables, comprensibles y éticamente responsables. La IA, para ser verdaderamente útil, debe superar retos técnicos específicos que incluyen limitaciones estructurales en los sistemas de salud, falta de interoperabilidad, calidad desigual en los datos disponibles y barreras de adopción por parte del personal sanitario.

En esta sección se analizan las principales barreras técnicas que enfrentamos en la implementación de soluciones de IA en nuestro ámbito, con el objetivo de proporcionar una visión crítica, realista y orientada a su resolución.

8.1.2. Limitaciones en la interoperabilidad entre sistemas clínicos y algoritmos de IA

Uno de los principales retos técnicos para la implementación efectiva de soluciones de inteligencia artificial en obstetricia y ginecología es la falta de interoperabilidad entre los algoritmos desarrollados y los sistemas de información clínica existentes. Este problema no es menor, ya que afecta directamente la utilidad práctica de cualquier herramienta basada en IA, condicionando su integración en el flujo asistencial y, por tanto, su adopción real por parte de los profesionales.

En la actualidad, muchos algoritmos son desarrollados por equipos de ingeniería o *startups* tecnológicas fuera del entorno hospitalario, sin una comprensión profunda de los sistemas de información utilizados en los hospitales y clínicas. Como consecuencia, estas soluciones operan de forma aislada, sin integrarse nativamente con sistemas como el HIS (Sistema de Información Hospitalaria), RIS (Sistema de Información Radiológica), PACS (Sistema de Archivo y Comunicación de Imágenes) o los propios sistemas de historia clínica electrónica (HCE). Esto genera múltiples consecuencias negativas:

- El profesional debe salir del entorno habitual de trabajo para utilizar la herramienta, lo que rompe la continuidad del flujo clínico.
- Se produce una duplicación de tareas, como volver a cargar datos ya presentes en la historia electrónica o descargar imágenes manualmente para analizarlas externamente.
- Se incrementa el riesgo de errores administrativos y discrepancias en la información clínica.

A nivel estructural, otro factor limitante es la falta de estandarización de los formatos de datos. La información obstétrica y ginecológica puede estar fragmentada en múltiples sistemas y formatos: informes clínicos en texto libre, imágenes en DICOM, resultados de laboratorio en HL7, datos biométricos en XML o JSON, entre otros. La integración eficaz requiere el uso de estándares interoperables como FHIR (Recursos de Interoperabilidad Rápida en Salud), pero su adopción sigue siendo incipiente en muchos centros, especialmente fuera de los países con infraestructuras digitales más avanzadas.

A esto se suma que muchos algoritmos de IA requieren actualización constante y validación local, ya que un modelo entrenado en una población determinada puede no funcionar correctamente en otro entorno asistencial. Esto implica que la integración no solo debe ser técnica, sino también contextual y dinámica, con posibilidad de reentrenamiento o calibración adaptativa del modelo, lo cual es complejo cuando no existe una arquitectura interoperable sólida.

Por otro lado, las políticas de protección de datos, necesarias y bienvenidas, imponen límites adicionales. La interoperabilidad entre sistemas de IA y *software* clínico exige establecer canales seguros de comunicación, con cifrado, trazabilidad de accesos y gestión de consentimientos. Muchos desarrollos actuales carecen de esta arquitectura de seguridad robusta, lo que genera desconfianza institucional y frena su despliegue en entornos reales.

Finalmente, existe una brecha importante entre las expectativas de los desarrolladores tecnológicos y la realidad operativa hospitalaria. En obstetricia, por ejemplo, muchos centros continúan utilizando formularios en papel, registros de partograma manuales o sistemas informáticos obsoletos. En ginecología, las imágenes pueden almacenarse localmente sin vinculación estructurada con los datos clínicos. Intentar implementar IA en ese entorno sin resolver previamente la madurez digital de base conduce inevitablemente al fracaso del proyecto.

Por tanto, la interoperabilidad no es un aspecto técnico secundario, sino una condición imprescindible para que la inteligencia artificial pueda tener un impacto real en la atención a la salud de la mujer. Requiere inversiones en infraestructura digital, compromiso institucional, participación activa de los clínicos en el diseño de los sistemas y una visión estratégica que sitúe la transformación digital como una prioridad en salud.

8.1.3. Calidad y sesgo en los datos utilizados para entrenar los modelos

Los sistemas de inteligencia artificial, especialmente aquellos basados en aprendizaje automático y aprendizaje profundo, dependen críticamente de los datos con los que son entrenados. En obstetricia y ginecología, esta dependencia plantea múltiples desafíos, ya que la calidad, representatividad y homogeneidad de los datos clínicos disponibles son a menudo limitadas o inadecuadas para una generalización clínica robusta.

1. Heterogeneidad y fragmentación de los datos clínicos

La información clínica en nuestra especialidad proviene de múltiples fuentes: exploraciones ecográficas, registros cardiotocográficos, informes quirúrgicos, resultados hormonales, antecedentes obstétricos, fotografías colposcópicas, etc. Esta diversidad genera bases de datos fragmentadas, no siempre estandarizadas ni fácilmente integrables. A menudo los datos se almacenan en distintos formatos (texto libre, imagen, numérico), en sistemas separados, y sin una ontología común que permita su explotación por parte de algoritmos de IA.

Por ejemplo, el entrenamiento de un modelo para predecir riesgo de parto prematuro requiere integrar variables clínicas (edad, antecedentes, patologías asociadas), biomarcadores, imágenes ecográficas del cuello uterino y datos dinámicos del registro uterino. Si estos datos no están correctamente etiquetados, estructurados ni sincronizados, el modelo resultante será débil, con alto riesgo de sobreajuste o error en la inferencia.

2. Sesgos en los datos de entrenamiento

El sesgo es uno de los mayores enemigos silenciosos en la IA médica. Cuando los conjuntos de datos utilizados para entrenar un modelo no son representativos de la población objetivo, el algoritmo puede generalizar mal o incluso producir recomendaciones discriminatorias. En ginecología y obstetricia, los sesgos pueden surgir por múltiples razones:

- **Sesgo étnico:** Muchas bases de datos provienen de poblaciones caucásicas europeas o norteamericanas, sin representación adecuada de mujeres afrodescendientes, indígenas, asiáticas o latinas. Esto afecta, por ejemplo, a modelos de predicción de preeclampsia, donde la incidencia varía significativamente por grupo étnico.
- **Sesgo de clase social o cobertura sanitaria:** Los datos hospitalarios pueden estar dominados por mujeres atendidas en centros urbanos de alto nivel, dejando fuera a mujeres rurales, sin cobertura médica o en situación de vulnerabilidad. Esto puede falsear modelos que predicen complicaciones del embarazo o adherencia a tratamientos.
- **Sesgo de prevalencia:** Cuando un modelo es entrenado con datos donde la prevalencia de una condición es muy alta o muy baja (por ejemplo, cáncer de ovario en cohortes seleccionadas), puede presentar un alto número de falsos positivos o negativos al aplicarse en poblaciones reales.

Un ejemplo reciente se encuentra en algoritmos de detección automatizada de cáncer cervical mediante citología líquida o imágenes colposcópicas. Varios estudios han demostrado que estos algoritmos tienen un rendimiento significativamente inferior en mujeres mayores de 50 años o con atrofia vaginal, dado que el entrenamiento se realizó mayoritariamente en mujeres jóvenes.

3. Calidad clínica de los datos: errores, ruido y ambigüedad

Los registros médicos contienen a menudo errores humanos, omisiones, abreviaturas no estandarizadas y ambigüedades semánticas. En obstetricia, es frecuente encontrar diferencias en la forma de anotar la edad gestacional, parámetros ecográficos o resultados de laboratorio. En ginecología, el lenguaje natural de los informes quirúrgicos puede incluir descripciones subjetivas o contradictorias. Los modelos de IA entrenados con estos datos pueden aprender patrones falsos o irrelevantes, generando resultados poco fiables. El llamado “aprendizaje espurio” es un riesgo real: el modelo aprende a predecir correctamente no por la fisiopatología real, sino por correlaciones ocultas que no se sostienen en otros contextos.

4. Datos insuficientes o desbalanceados

Muchas condiciones relevantes en obstetricia y ginecología son relativamente poco frecuentes (p. ej., embarazo ectópico roto, corioamnionitis severa, cáncer de cérvix en estadio precoz), lo que genera desbalance en las bases de datos. Esto dificulta el entrenamiento de modelos con buen rendimiento para identificar estos eventos raros. A menudo, los algoritmos tienden a favorecer la clase mayoritaria (casos normales), reduciendo su sensibilidad para detectar lo excepcional.

Técnicas como el sobreentrenamiento de casos raros, el uso de simulaciones o la generación de datos sintéticos mediante redes generativas (GANs) pueden ser útiles, pero deben aplicarse con precaución y validarse clínicamente.

8.1.4. Requerimientos técnicos y recursos hospitalarios

La implementación efectiva de soluciones de inteligencia artificial en obstetricia y ginecología no depende únicamente de la calidad de los algoritmos, sino también de la existencia de una infraestructura tecnológica adecuada que permita su integración, uso cotidiano, mantenimiento y evolución. En este sentido, las diferencias entre centros de alto nivel tecnológico y aquellos con recursos más limitados —como hospitales comarcales, centros rurales o clínicas pequeñas— marcan una brecha profunda en la posibilidad real de acceder a las ventajas de la IA.

1. Infraestructura informática: *hardware*, conectividad y seguridad

El funcionamiento óptimo de algoritmos avanzados, especialmente aquellos basados en *deep learning*, requiere una infraestructura computacional específica. Esto incluye:

- Servidores con capacidad de procesamiento gráfico (GPUs) para realizar inferencias en tiempo real sobre imágenes médicas o flujos de datos clínicos.
- Redes de alta velocidad que garanticen el acceso simultáneo y seguro de múltiples usuarios sin interrupciones.
- Sistemas de almacenamiento masivo capaces de gestionar archivos grandes (como estudios ecográficos en DICOM, videos quirúrgicos, datos brutos de monitorización fetal).
- Protocolos de ciberseguridad robustos, necesarios para manejar información clínica sensible, cumpliendo con normativas de protección de datos como el RGPD europeo o la HIPAA en EE.UU.

Muchos hospitales públicos o mixtos en países de ingresos medios —e incluso en regiones rurales de países desarrollados— no disponen de esta infraestructura. La consecuencia es que las herramientas basadas en IA no pueden instalarse localmente, obligando a trabajar con soluciones remotas (en la nube), que a su vez exigen conectividad estable y políticas claras de gestión de datos.

2. Necesidades de soporte técnico y mantenimiento

A diferencia de otros recursos médicos tradicionales, las soluciones de IA requieren actualizaciones periódicas, validación continua y monitorización de desempeño. Un modelo que se comporta adecuadamente en un entorno determinado puede degradar su rendimiento con el tiempo, especialmente si cambian los protocolos clínicos, las características de la población o la calidad de los datos. Esto exige contar con un equipo técnico de soporte, capaz de:

- Monitorizar el rendimiento del algoritmo.
- Detectar errores o comportamientos anómalos.
- Implementar parches y mejoras del sistema.
- Asegurar la compatibilidad con nuevas versiones de *software* clínico.

En muchos centros sanitarios no existe personal con formación en ingeniería biomédica, ciencia de datos o informática médica, lo que convierte a las herramientas de IA en soluciones de difícil sostenibilidad una vez que se implementan.

3. Costos económicos de adquisición, formación e integración

Aunque algunas herramientas de IA son de código abierto o cuentan con versiones gratuitas para investigación, la mayoría de las aplicaciones clínicas que llegan al mercado lo hacen como productos

comerciales, con un modelo de licencias, suscripciones o incluso pago por uso. Los costos no se limitan al *software*: deben sumarse gastos en equipamiento, servidores, formación del personal clínico, adaptación de flujos de trabajo, soporte técnico y evaluación de resultados.

En muchos sistemas sanitarios, especialmente públicos, estos gastos no están presupuestados. Las prioridades asistenciales suelen concentrarse en resolver listas de espera, carencias de personal o necesidades urgentes de equipamiento, dejando en segundo plano la inversión en tecnología avanzada. En centros privados o concertados, la evaluación de rentabilidad a corto plazo también puede frenar la adopción de soluciones que, aunque prometedoras, no demuestran aún impacto directo sobre ingresos o eficiencia.

4. Desigualdades entre centros de alta y baja complejidad

Esta realidad genera una brecha digital asistencial, donde los hospitales universitarios o de tercer nivel disponen de recursos para experimentar e implementar IA, mientras que los centros comarcales o periféricos no pueden acceder ni siquiera a herramientas básicas. En ginecología, esto puede traducirse en:

- Ausencia de sistemas automatizados para detección de lesiones cervicales en unidades de cribado.
- Falta de análisis asistido por IA en estudios ecográficos del primer trimestre.
- Imposibilidad de integrar alertas inteligentes en monitorización intraparto.

En obstetricia rural, donde muchas veces el acceso a especialistas es limitado, la IA podría tener un papel crucial en mejorar la calidad diagnóstica y el seguimiento de embarazos de riesgo. Sin embargo, en ausencia de conectividad, formación y soporte, estas promesas siguen sin materializarse.

5. Necesidad de planificación institucional y visión estratégica

La incorporación de IA no puede plantearse como una compra puntual de tecnología, sino como una estrategia institucional a largo plazo, que contemple:

- Evaluación de necesidades reales del centro.
- Identificación de áreas clínicas donde la IA pueda aportar valor tangible.
- Formación progresiva del personal.
- Creación de unidades de transformación digital y soporte técnico.

Solo con esta planificación se podrá garantizar que la IA no sea un elemento decorativo o un proyecto piloto puntual, sino una herramienta integrada, útil y segura para mejorar la atención a las mujeres.

8.1.5. Resistencia al cambio por parte de los profesionales

La adopción de tecnologías basadas en inteligencia artificial en obstetricia y ginecología no depende exclusivamente de su eficacia técnica, sino también —y en muchos casos, sobre todo— de su aceptación por parte del personal clínico. Esta dimensión humana, a menudo subestimada en los procesos de innovación tecnológica, representa una de las barreras más complejas y determinantes para la integración efectiva de la IA en la práctica diaria.

1. Desconfianza ante sistemas automatizados

Muchos profesionales perciben la IA como una "caja negra" difícil de interpretar y que puede comprometer la autonomía clínica. Esta desconfianza epistémica se acentúa cuando el algoritmo proporciona una recomendación sin justificar claramente su razonamiento, en especial en decisiones críticas como la indicación de una cesárea urgente, el cribado de una anomalía fetal o la sospecha de malignidad en una lesión ovárica.

En especialidades como la obstetricia, donde la toma de decisiones se basa en múltiples factores subjetivos, la experiencia acumulada y la intuición clínica, existe un temor latente a que la IA desplace el juicio profesional o mine su autoridad ante pacientes y colegas. Esto puede generar rechazo, reticencia o incluso boicot silencioso a las nuevas herramientas.

2. Falta de formación específica y sobrecarga asistencial

Buena parte del personal sanitario carece de una formación básica en inteligencia artificial, lo que dificulta comprender cómo funcionan los algoritmos, cómo interpretar sus salidas y cuáles son sus limitaciones. Esto genera inseguridad en su uso y eleva el riesgo de errores por malentendidos. Además, en contextos asistenciales saturados, donde los ginecólogos, obstetras y matronas ya enfrentan una alta carga de trabajo, cualquier novedad tecnológica que requiera tiempo de aprendizaje adicional o modifique los flujos habituales es percibida como una amenaza más que como una ayuda. Por ejemplo, si un sistema de análisis de imágenes ecográficas requiere pasos adicionales, como cargar el estudio en una plataforma externa o validar resultados manualmente, es probable que no se utilice en el día a día, por falta de tiempo o agilidad.

3. Miedo a la judicialización y a la pérdida de control

En un entorno sanitario cada vez más judicializado, algunos profesionales temen que la adopción de IA pueda comprometer su responsabilidad legal. ¿Qué sucede si un algoritmo sugiere un diagnóstico que el médico descarta y finalmente el desenlace clínico es adverso? ¿Puede el uso de un sistema automatizado ser interpretado como negligencia si no se ha seguido al pie de la letra? Estas incertidumbres legales, aún no resueltas en muchas legislaciones, generan una actitud conservadora entre los clínicos, que prefieren mantener el control total de las decisiones, incluso si eso supone no beneficiarse de herramientas complementarias de ayuda.

4. Experiencias previas fallidas con tecnologías mal implementadas

En muchos centros sanitarios, la implementación de nuevas tecnologías ha sido percibida como fallida o impuesta, sin un acompañamiento adecuado ni participación del personal en las fases de diseño o prueba. Sistemas de historia clínica electrónica poco intuitivos, plataformas de prescripción electrónica complejas o protocolos automatizados sin valor clínico han dejado una huella de frustración que dificulta la introducción de innovaciones posteriores, incluso si son potencialmente útiles. Esta historia reciente hace que muchos profesionales adopten una postura escéptica ante la IA: "otra herramienta más que complica el trabajo en lugar de facilitarlo".

5. Estrategias de facilitación y cambio cultural


Para superar esta barrera, es esencial adoptar una estrategia de implementación centrada en el usuario clínico, que incluya:

- Participación activa de los profesionales en el diseño, validación y mejora de las herramientas.
- Formación práctica y contextualizada, que no se limite a lo técnico, sino que muestre casos reales de utilidad clínica.

- Desarrollo de modelos explicables (*explainable AI*) que justifiquen sus recomendaciones de forma comprensible para el médico.
- Protocolos claros de responsabilidad clínica, que definan el rol de la IA como herramienta complementaria, no sustitutiva, del juicio profesional.
- Evaluación periódica del impacto real en el trabajo clínico, incluyendo encuestas de satisfacción, tiempos asistenciales, errores evitados y mejora en la calidad de atención.

Un ejemplo positivo es el de algunas unidades obstétricas que han implementado sistemas inteligentes para la interpretación del registro cardiotocográfico (CTG), no como un sustituto del análisis del tocólogo, sino como una segunda opinión automatizada, que alerta precozmente de patrones preocupantes y apoya la toma de decisiones en salas de partos concurridas. Estas experiencias han demostrado que, cuando la tecnología se percibe como aliada, la adopción clínica es rápida y sostenible.

Embudo de barreras para la integración clínica de la IA



8.2. Retos éticos y legales

8.2.1. Introducción

La inteligencia artificial aplicada a la medicina no es una herramienta neutra. Su uso implica decisiones que afectan directamente a personas reales, en contextos clínicos muchas veces marcados por la vulnerabilidad, la incertidumbre y la necesidad de empatía. En ginecología y obstetricia, donde las decisiones afectan no solo a la salud de la mujer, sino también al desarrollo fetal, a la familia y al futuro reproductivo, estas implicaciones éticas y legales adquieren una especial trascendencia.

La implementación de IA en este campo plantea interrogantes profundos: ¿puede una máquina recomendar una inducción al parto o una cesárea? ¿Cómo garantizamos que los datos utilizados respetan la privacidad y el consentimiento? ¿Quién es responsable si un algoritmo falla? ¿Están estos sistemas reproduciendo —o incluso amplificando— sesgos existentes en la atención médica?

Esta sección explora los principales desafíos éticos y legales que debemos considerar en el uso de la IA aplicada a nuestra especialidad. Más allá de la fascinación tecnológica, es necesario construir un marco de confianza, transparencia y seguridad que ponga a la persona en el centro, y que guíe el desarrollo de herramientas verdaderamente útiles, equitativas y humanistas.

8.2.2. Toma de decisiones automatizada: ¿Quién es responsable?

Uno de los principales dilemas éticos y legales derivados del uso de la inteligencia artificial en medicina es la atribución de responsabilidad cuando las decisiones clínicas son influenciadas o directamente recomendadas por un sistema automatizado. Esta cuestión cobra especial relevancia en obstetricia y ginecología, donde muchas decisiones son urgentes, complejas y con alto impacto en la salud materna y fetal.

1. ¿Hasta qué punto se puede delegar la decisión clínica?

Los sistemas de IA en ginecología y obstetricia pueden sugerir diagnósticos, alertar sobre riesgos, priorizar pacientes o incluso recomendar intervenciones. Sin embargo, la decisión última sigue recayendo en el profesional sanitario, quien debe valorar la información generada por el algoritmo en el contexto clínico real, considerando las particularidades del caso, los deseos de la paciente y su propia experiencia.

Este principio, ampliamente aceptado en la ética médica, se basa en que el profesional es quien tiene la competencia legal, técnica y moral para ejercer el juicio clínico. No obstante, en la práctica, cuando un algoritmo recomienda una acción concreta —por ejemplo, interrumpir una inducción por sospecha de sufrimiento fetal— y el clínico decide no seguirla, puede generarse un conflicto de responsabilidad si el desenlace es adverso.

Por otro lado, si el profesional sigue ciegamente la recomendación de un sistema que no comprende o no ha validado, ¿puede escudarse en que simplemente “seguía lo que decía la máquina”? Este escenario genera una zona gris legal que aún no ha sido resuelta en la mayoría de los marcos regulatorios actuales.

2. Responsabilidad compartida: el nuevo paradigma

Ante esta realidad, se impone un modelo de responsabilidad compartida, en el que intervienen múltiples actores:

- El desarrollador o empresa tecnológica, responsable del diseño, entrenamiento, validación y mantenimiento del algoritmo.
- La institución sanitaria, encargada de verificar la idoneidad del sistema, garantizar su adaptación al entorno local y formar adecuadamente a los profesionales.
- El profesional sanitario, quien debe conocer las capacidades y limitaciones del sistema, y tomar decisiones informadas basadas en múltiples fuentes.
- El regulador, que debe establecer criterios de certificación, trazabilidad y control de calidad de los sistemas de IA utilizados en salud.

Este modelo implica que la responsabilidad ya no recae exclusivamente sobre el médico, como en el paradigma clásico, sino que se distribuye a lo largo de una cadena compleja de actores. Sin embargo, la ausencia de marcos legales actualizados en muchos países deja al profesional en una situación de vulnerabilidad jurídica si no se establecen criterios claros de actuación.

3. El problema de la opacidad: la caja negra legal

Muchos sistemas de IA, especialmente los basados en *deep learning*, presentan un alto grado de opacidad: generan una recomendación, pero no explican de manera comprensible cómo llegaron a esa conclusión. Esta falta de transparencia plantea problemas tanto clínicos como jurídicos:

- El médico no puede justificar por qué siguió —o no siguió— la recomendación si no puede interpretarla.
- La paciente no puede entender el razonamiento que llevó a una determinada intervención.
- En caso de litigio, es difícil establecer si hubo negligencia, error de diseño o simplemente un fallo aleatorio del modelo.

Por ello, la comunidad científica y reguladora está impulsando cada vez más el desarrollo de sistemas de IA explicables (*explainable AI*), que permitan al profesional entender los factores que contribuyeron a la recomendación generada por el sistema. Esta capacidad explicativa será clave para reforzar la seguridad jurídica y ética del uso de la IA en salud.

4. Necesidad de protocolos clínico-legales

Para proteger tanto al paciente como al profesional, las instituciones deben establecer protocolos de uso clínico de la IA, que definan claramente:

- Cuándo debe utilizarse una herramienta basada en IA.
- Cómo deben documentarse sus recomendaciones en la historia clínica.
- En qué casos es obligatorio confirmar los resultados con otros métodos.
- Quién es responsable de supervisar y actualizar el modelo utilizado.

Estos protocolos no deben concebirse como restricciones, sino como garantías de buena práctica clínica, similares a las guías de manejo existentes para otras tecnologías (ecografía, TAC, monitorización fetal, etc.).

5. Un ejemplo práctico: asistencia al parto basada en IA

Imaginemos un sistema integrado de IA que analiza en tiempo real el registro cardiotocográfico (CTG), el perfil biofísico fetal, los antecedentes obstétricos y la dinámica uterina, y emite una alerta por “alto riesgo de hipoxia fetal inminente”. El tocólogo de guardia, tras revisar la situación, decide continuar el parto por vía vaginal. El recién nacido nace con un pH de 6.98 y requiere reanimación avanzada.

Si los padres presentan una demanda, el informe del sistema puede ser utilizado como argumento de que la cesárea estaba indicada. En ese caso, ¿tiene el profesional la culpa por no seguir la recomendación? ¿Debe la institución haber formado mejor al clínico en el uso del sistema? ¿Es el algoritmo responsable por una alerta falsa positiva? ¿Qué rol juega la trazabilidad de las decisiones? Este escenario, aún infrecuente pero cada vez más plausible, ilustra la urgencia de establecer límites, definiciones y responsabilidades claras ante la toma de decisiones asistidas por IA en ginecología y obstetricia.

8.2.3. Privacidad, consentimiento informado y uso de datos sensibles

Uno de los pilares éticos y legales fundamentales en el desarrollo e implementación de inteligencia artificial en medicina es el respeto a la privacidad de los datos clínicos, especialmente cuando se trata de información sensible, como la que se maneja habitualmente en ginecología y obstetricia: antecedentes reproductivos, salud sexual, fertilidad, interrupciones voluntarias del embarazo, infecciones de transmisión sexual, entre otros.

A medida que los sistemas de IA requieren volúmenes crecientes de datos para entrenar y mejorar sus algoritmos, surge la necesidad de establecer mecanismos sólidos de protección, gobernanza y consentimiento para garantizar los derechos de las pacientes y prevenir usos indebidos de su información.

1. ¿Qué se entiende por dato sensible en ginecología y obstetricia?

La legislación europea, a través del Reglamento General de Protección de Datos (RGPD), considera como datos especialmente protegidos aquellos relativos a la salud, la vida sexual, el origen étnico, la religión o las opiniones políticas. En el contexto gineco-obstétrico, esto incluye información como:

- Historia de embarazos previos, abortos, esterilidad, métodos anticonceptivos.
- Infecciones ginecológicas o enfermedades de transmisión sexual.
- Resultados de pruebas genéticas fetales o maternas.
- Imágenes ecográficas almacenadas con identificación.
- Información de salud mental durante el embarazo o el puerperio.

La recopilación y tratamiento automatizado de estos datos por parte de sistemas de IA debe realizarse con un nivel reforzado de consentimiento, anonimización y trazabilidad.

2. Consentimiento informado para uso de datos en IA

Uno de los retos más complejos es el consentimiento para utilizar datos clínicos en el desarrollo de herramientas de inteligencia artificial. En muchos casos, los datos provienen de historiales médicos generados con fines asistenciales, y se reutilizan posteriormente para entrenar algoritmos, a menudo de forma secundaria o sin una participación directa del paciente.

| El consentimiento en este contexto plantea interrogantes clave:

- ¿Puede considerarse válido un consentimiento general otorgado al ingresar al hospital, si no se especifica el uso posterior para fines algorítmicos?
- ¿Es suficiente con anonimizar los datos, o debe solicitarse igualmente autorización específica?
- ¿Qué ocurre si los datos, aunque anónimos, contienen imágenes o grabaciones que podrían permitir la reidentificación?

La legislación europea exige que el consentimiento sea explícito, informado y específico, y que el paciente conozca el propósito del tratamiento de sus datos. En México y muchos países latinoamericanos, aunque existen normativas similares (como la Ley Federal de Protección de Datos Personales en Posesión de los Particulares), su implementación efectiva es todavía limitada, lo que genera áreas de ambigüedad.

En la práctica, esto implica que los desarrolladores y centros sanitarios deben elaborar formularios de consentimiento claros, que expliquen:

- Qué datos se usarán.
- Para qué fin (entrenamiento, validación, comercialización).
- Durante cuánto tiempo y con qué garantías de protección.
- Si se compartirán con terceros (empresas tecnológicas, plataformas internacionales, investigadores externos).

3. Riesgos de reidentificación y anonimización imperfecta

Aunque la anonimización de los datos clínicos es una práctica habitual, existen múltiples estudios que han demostrado la posibilidad de reidentificación mediante el cruce de múltiples variables. En ginecología, por ejemplo, un conjunto de datos que incluya edad, número de hijos, fecha del parto y diagnóstico poco frecuente puede ser suficiente para identificar a una paciente concreta, especialmente en poblaciones pequeñas.

El uso de imágenes médicas —como ecografías fetales o videos quirúrgicos— añade una capa de complejidad adicional, ya que, aunque se eliminen los metadatos, pueden contener información biométrica identificable (formas anatómicas, etiquetas visibles, voces grabadas en el audio de fondo). Por tanto, los sistemas de IA deben implementar no solo técnicas de anonimización, sino también evaluaciones de riesgo de reidentificación, y aplicar medidas adicionales como:

- Pseudonimización.
- Encriptación de extremo a extremo.
- Control de acceso por niveles.
- Políticas de auditoría interna y uso responsable.

4. Almacenamiento, cesión y gobernanza de los datos

La gobernanza ética de los datos clínicos implica decidir quién puede acceder, bajo qué condiciones y con qué propósito. Cuando se entrena un algoritmo en un hospital, pero este luego es cedido a una empresa para su validación externa o comercialización, surgen dilemas éticos relevantes:

- ¿Pueden los datos de las pacientes ser utilizados en desarrollos que no beneficien directamente al centro donde se obtuvieron?
- ¿Se debe compartir parte de los beneficios si se ha utilizado información sensible generada con recursos públicos?
- ¿Deben los comités de ética clínica participar en la validación de estos proyectos, más allá del ámbito de la investigación?

La respuesta a estas preguntas exige la creación de marcos institucionales claros de gobernanza de datos, con participación multidisciplinar (jurídica, clínica, tecnológica, bioética), que garanticen la protección del derecho fundamental a la privacidad, sin frenar el desarrollo de soluciones tecnológicas de interés sanitario.

8.2.4. Explicabilidad de los modelos (“cajas negras”) y confianza clínica

Uno de los retos más relevantes —y a menudo menos visibles— en el uso de inteligencia artificial en medicina es el de la explicabilidad: la capacidad de un sistema para justificar de forma comprensible por qué ha emitido una determinada recomendación o predicción. En contextos clínicos donde la toma de decisiones debe ser transparente, reproducible y justificada, los modelos de IA que actúan como “cajas negras” generan desconfianza, inseguridad y limitan su adopción real.

Característica	Modelos explicables (XAI)	Modelos 'caja negra'
Comprensibilidad clínica	Alta	Baja
Validación externa	Facilitada	Limitada
Adopción profesional	Mayor	Menor (requiere confianza)
Uso en decisiones críticas	Recomendable	Riesgoso sin justificación
Ejemplo	Árboles de decisión, SHAP	Redes neuronales profundas

La Figura resume las diferencias clave entre modelos de inteligencia artificial explicables y aquellos considerados ‘cajas negras’, destacando su impacto en la práctica clínica.

1. ¿Qué significa explicabilidad en IA médica?

La explicabilidad se refiere a la posibilidad de que los profesionales sanitarios (y eventualmente los pacientes) comprendan las razones detrás de la recomendación generada por un modelo de IA. Esta comprensión puede adoptar distintas formas:

- Identificación de las variables más influyentes en una predicción (p. ej., edad, IMC, grosor endometrial).
- Visualización de las regiones de una imagen médica que determinaron una clasificación (p. ej., un área hiperecogénica marcada en una ecografía).
- Justificación de una decisión basada en reglas explícitas, como en los sistemas expertos clásicos.

La IA explicable (XAI, por sus siglas en inglés, *explainable artificial intelligence*) busca desarrollar modelos que no solo sean precisos, sino también intuitivos, auditables y confiables.

2. Modelos no explicables: el caso de las redes neuronales profundas

Muchos algoritmos actuales de aprendizaje profundo, especialmente redes neuronales convolucionales (CNN) utilizadas en análisis de imágenes, presentan una estructura altamente compleja y opaca. Pueden ofrecer resultados con elevada precisión diagnóstica, pero sin ofrecer una razón clara de “por qué” o “cómo” llegaron a esa conclusión.

En ginecología, por ejemplo, un modelo que clasifica imágenes de resonancia magnética pélvica como sospechosas de cáncer de endometrio puede hacerlo con gran eficacia, pero si no se puede visualizar qué zonas fueron clave para esa predicción, el clínico no puede valorar la fiabilidad del resultado ni explicárselo a la paciente.

Esta falta de interpretabilidad se convierte en un problema especialmente crítico en obstetricia, donde las decisiones clínicas deben considerar tanto el bienestar fetal como materno. Si un sistema predice “alto riesgo de restricción de crecimiento intrauterino” basado en miles de parámetros ocultos, sin mostrar qué variables fueron relevantes (Doppler uterino, flujometría cerebral, volumen placentario), el obstetra no podrá utilizar esa información con seguridad.

3. Impacto clínico de la explicabilidad: confianza, comunicación y formación

La falta de explicabilidad tiene un impacto directo en la confianza del profesional sanitario en el sistema de IA. Sin una explicación coherente, el clínico puede:

- Descartar el resultado por considerarlo poco fiable.
- Usarlo sin comprenderlo, lo cual supone un riesgo ético y legal.
- Ser incapaz de comunicarlo adecuadamente a la paciente, afectando la calidad de la relación asistencial.

Por el contrario, los sistemas explicables permiten:

- Auditar y validar los modelos clínicamente.
- Generar confianza progresiva entre los usuarios.
- Favorecer la formación y aprendizaje de los residentes, que pueden ver qué patrones reconoce el sistema y por qué.

Un ejemplo positivo es el uso de mapas de activación en ecografía ginecológica. Algunos modelos actuales permiten resaltar las regiones de una imagen 2D o 3D que han llevado al sistema a clasificarla como “mioma submucoso” o “adenomiosis”. Esto ofrece un doble beneficio: el especialista puede evaluar visualmente si está de acuerdo, y el residente puede entender mejor los criterios diagnósticos.

4. Equilibrio entre precisión y explicabilidad

Existe una tensión inherente entre la precisión técnica de algunos modelos complejos y su interpretabilidad. Los algoritmos más potentes suelen ser también los más opacos, mientras que los modelos más simples (como los árboles de decisión o las regresiones logísticas) son fácilmente comprensibles, pero pueden ofrecer menor.

La elección entre ambos no debe ser dicotómica, sino adaptada al contexto clínico:

- En **cribado poblacional**, donde la transparencia es fundamental, pueden preferirse modelos más explicables, aunque con menor rendimiento.
- En **entornos hospitalarios de alta complejidad**, donde se trabaja en equipos multidisciplinares y existe capacidad para validar internamente los modelos, puede aceptarse mayor opacidad, siempre que exista trazabilidad y monitorización.

5. Recomendaciones para una IA clínica comprensible y confiable

Para avanzar hacia un modelo de IA responsable en ginecología y obstetricia, es necesario que:

- a. Los desarrolladores integren mecanismos de explicabilidad desde las fases iniciales del diseño del sistema.
- b. Se utilicen herramientas de interpretación visual, como SHAP, LIME o Grad-CAM, adaptadas al entorno clínico.
- c. Las interfaces usuario-sistema sean comprensibles, con gráficos, leyendas, probabilidades y rangos clínicos.
- d. Los centros sanitarios exijan documentación clara sobre los fundamentos del algoritmo, su validación clínica y sus límites de interpretación.

8.2.5. Regulación actual y vacíos legales en España y América Latina

A medida que la inteligencia artificial gana protagonismo en el ámbito sanitario, surge una necesidad urgente de establecer marcos normativos claros, coherentes y adaptados al nuevo escenario clínico-tecnológico. Sin embargo, tanto en España como en gran parte de América Latina, la regulación específica sobre el uso de IA en salud —y más concretamente en ginecología y obstetricia— es todavía incipiente, fragmentada y reactiva.

1. España: una regulación avanzada en datos, pero incipiente en IA médica

En el contexto español, la normativa de referencia en protección de datos es el Reglamento General de Protección de Datos (RGPD) de la Unión Europea (Reglamento 2016/679), complementado por la Ley Orgánica 3/2018 de Protección de Datos Personales y garantía de los derechos digitales. Esta legislación:

- Regula el tratamiento de datos personales, con especial protección para los relativos a la salud.
- Establece el principio de minimización de datos, consentimiento explícito y derecho a la portabilidad.

- Reconoce el derecho a no ser objeto de decisiones automatizadas sin intervención humana significativa (art. 22 del RGPD).

Sin embargo, el RGPD no regula específicamente la IA médica, ni proporciona criterios técnicos sobre validación, certificación o supervisión de algoritmos clínicos. A día de hoy, la implementación de herramientas de IA en hospitales españoles se enmarca principalmente dentro de:

- Ensayos clínicos o proyectos de investigación con aprobación ética.
- Iniciativas de innovación tecnológica dentro de servicios de salud autonómicos.
- Implementaciones privadas sujetas a responsabilidad institucional.

La Agencia Española de Protección de Datos (AEPD) ha emitido guías sobre IA y ética, pero no existe aún un marco jurídico sectorial que obligue a certificar algoritmos médicos con criterios clínicos, éticos y de seguridad.

2. México y América Latina: avances desiguales y marcos en desarrollo

En México, la legislación vigente en materia de datos personales se basa en la Ley Federal de Protección de Datos Personales en Posesión de los Particulares (LFPDPPP). Esta ley:

- Establece principios similares al RGPD en cuanto a consentimiento, finalidad, proporcionalidad y seguridad.
- No diferencia explícitamente entre tratamientos manuales o automatizados mediante IA.
- No regula el uso de algoritmos para decisiones clínicas automatizadas, ni exige la validación de modelos.

En otros países latinoamericanos, como Argentina, Colombia o Chile, existen leyes generales de protección de datos, pero con diferencias importantes en su grado de implementación, fiscalización y actualización. Algunos países aún carecen de normativa específica para IA o han emitido solo declaraciones de intención en forma de “estrategias nacionales de IA”.

Además, muchas herramientas de IA son importadas desde países fuera de la región (EE. UU., Europa, Asia), lo que plantea dudas sobre la jurisdicción aplicable, el cumplimiento normativo en el país receptor y la responsabilidad en caso de error o daño.

3. Iniciativas emergentes hacia una regulación de la IA en salud

Ante estos vacíos legales, diversas instituciones están impulsando propuestas regulatorias específicas. Algunas destacadas son:

- Propuesta de Reglamento Europeo de Inteligencia Artificial (*Artificial Intelligence Act*, AIA), presentada en 2021 y aún en debate, que clasifica los sistemas de IA por nivel de riesgo e impone obligaciones estrictas para los de “alto riesgo”, incluyendo los sanitarios.
- Organización Panamericana de la Salud (OPS), que ha iniciado documentos de posición y recomendaciones sobre el uso ético de IA en salud en Latinoamérica.
- Redes académicas y consorcios internacionales, como AI4People, que promueven principios éticos y jurídicos para el diseño y uso de IA en medicina.

Sin embargo, estas iniciativas aún no se han traducido en legislación vinculante ni en procedimientos de certificación obligatoria para modelos clínicos aplicados en obstetricia y ginecología.

4. Riesgos del vacío regulatorio: entre la innovación y la inseguridad

La ausencia de una regulación clara genera múltiples riesgos:

- Desigualdad en el acceso y la calidad: centros con más recursos pueden implementar tecnologías no validadas que no están al alcance de otros hospitales.
- Falta de trazabilidad: los algoritmos pueden ser modificados sin supervisión, reentrenados sin control o transferidos entre centros sin auditoría.
- Inseguridad jurídica para los profesionales: ante un evento adverso, no existen normas que delimiten la responsabilidad del desarrollador, el hospital y el médico.

Este vacío no solo afecta a la protección de las pacientes, sino que desincentiva la innovación responsable, ya que muchas instituciones temen utilizar estas herramientas por miedo a consecuencias legales no definidas.

5. Hacia una regulación específica: propuestas clave

Para avanzar hacia una regulación robusta, adaptada a la realidad de la IA en ginecología y obstetricia, se proponen:

- Certificación obligatoria de algoritmos clínicos por agencias nacionales o internacionales, basada en criterios de seguridad, eficacia, explicabilidad y equidad.
- Protocolos éticos y legales de implementación clínica, revisados por comités multidisciplinares.
- Registros públicos de algoritmos en uso clínico, con trazabilidad, indicaciones aprobadas y evidencia científica.
- Inclusión de cláusulas contractuales específicas entre hospitales y proveedores tecnológicos, que definan responsabilidades ante errores, actualizaciones y control de versiones.
- Formación legal y ética en IA clínica como parte de los programas de formación médica y directiva en salud.

8.3. Desigualdades en el acceso a la tecnología

8.3.1. Introducción

La inteligencia artificial (IA) tiene el potencial de transformar profundamente la atención ginecológica y obstétrica, mejorando la precisión diagnóstica, anticipando riesgos, optimizando procesos y personalizando tratamientos. Sin embargo, este potencial no se distribuye de forma homogénea. Muy al contrario, la adopción y el impacto de la IA en salud están profundamente condicionados por factores estructurales como la infraestructura tecnológica, la financiación institucional, la formación del personal sanitario y las políticas públicas.

En ginecología y obstetricia, donde las diferencias en el acceso a servicios de calidad ya son notorias entre regiones, países e incluso dentro de una misma ciudad, la introducción de herramientas basadas en IA corre el riesgo de ampliar las brechas asistenciales existentes, generando una “medicina de dos velocidades”: una hiperautomatizada y personalizada para centros de alta complejidad, y otra básica, reactiva y sin soporte tecnológico para los entornos más desfavorecidos.

Estas desigualdades no solo afectan a los recursos disponibles, sino también a la representatividad de las poblaciones en los modelos de IA, a la capacidad de uso real de las herramientas, y a la inclusión —o exclusión— de ciertos colectivos en el desarrollo tecnológico.

Este apartado aborda, desde una perspectiva crítica y propositiva, las principales inequidades en el acceso a la inteligencia artificial en ginecología y obstetricia, analizando sus causas, consecuencias y caminos posibles para una integración más justa y equitativa.

8.3.2. Brecha digital entre países, regiones y tipos de centros sanitarios

La expansión de la inteligencia artificial en medicina no se produce sobre un terreno uniforme. Existen profundas asimetrías en la infraestructura digital, el acceso a tecnologías, la conectividad y la formación profesional que condicionan de forma crítica la posibilidad de implementar soluciones de IA en los distintos niveles del sistema sanitario.

En ginecología y obstetricia, estas diferencias se traducen en una desigualdad real en las oportunidades de innovación entre países, regiones y tipos de centros. La IA, si no se regula e implementa con visión equitativa, corre el riesgo de reforzar estas divisiones.

1. Brecha internacional: entre el Norte y el Sur sanitario

La mayor parte del desarrollo, validación y comercialización de algoritmos de IA aplicados a la salud de la mujer se realiza en entornos académicos o privados de países de altos ingresos, especialmente en Europa occidental, Norteamérica, Corea del Sur, Israel y Japón. Estas herramientas, diseñadas en contextos de alta tecnología y con disponibilidad de recursos, no siempre son aplicables ni accesibles en los países de ingresos medios o bajos, que representan más del 85 % de la población mundial. En muchos países latinoamericanos, por ejemplo, las barreras incluyen:

- Falta de historia clínica electrónica interoperable.
- Ausencia de conectividad estable en centros rurales o de frontera.
- Infraestructura informática obsoleta o inexistente.
- Mínima inversión pública en innovación digital en salud.

Esto genera una situación paradójica: los países con mayores desafíos en salud materna y perinatal, que se beneficiarían potencialmente del uso de IA para el cribado precoz, el seguimiento remoto o la estratificación de riesgos, son los menos capacitados para adoptarla.

Figura 3: Brecha regional en infraestructura para IA en salud



La Figura muestra, de forma estilizada, las diferencias regionales en el desarrollo de infraestructura para inteligencia artificial en el ámbito sanitario.

2. Brecha regional: centros urbanos vs. entornos rurales o periféricos

Incluso dentro de los países con sistemas de salud avanzados, como España, México, Argentina o Colombia, las diferencias entre grandes hospitales universitarios y centros comarcales, rurales o de atención primaria son significativas:

En los primeros, pueden coexistir plataformas de imagen integradas, herramientas de ayuda a la decisión clínica, sistemas de interpretación automatizada de monitorización fetal o algoritmos de clasificación de citologías.

En los segundos, el acceso a la ecografía puede ser limitado, no existe infraestructura para almacenar datos clínicos en la nube, y la formación digital del personal es escasa o inexistente.

Esto crea una medicina a doble velocidad, donde una embarazada que acude a un hospital de referencia puede beneficiarse de un modelo predictivo para preeclampsia basado en múltiples biomarcadores y variables clínicas, mientras que otra mujer, a pocas decenas de kilómetros, será evaluada únicamente con criterios clínicos clásicos, sin soporte tecnológico adicional.

3. Brecha institucional: público vs. Privado

Otro eje de desigualdad es el que se produce entre instituciones públicas y privadas, especialmente en contextos donde la inversión en innovación tecnológica depende de la autofinanciación o del volumen de pacientes asegurados.

En ginecología privada, por ejemplo, ya se están incorporando algoritmos para la selección embrionaria en reproducción asistida, sistemas automatizados de análisis de flujo vaginal por inteligencia artificial, o segmentación de útero y endometrio en ecografía 3D. Estas tecnologías no están disponibles en la sanidad pública o en hospitales con presupuesto limitado, lo que acentúa diferencias en el acceso a tratamientos avanzados según el nivel adquisitivo o la cobertura médica.

4. Brecha generacional y formativa

Finalmente, existe también una brecha menos visible pero igualmente importante: la brecha de competencias digitales entre profesionales. Aquellos con formación reciente o exposición previa a entornos digitales tienden a adoptar con mayor facilidad nuevas tecnologías. En cambio, profesionales con menor familiaridad tecnológica pueden mostrar rechazo, desconfianza o simplemente falta de herramientas para utilizar sistemas de IA.

Esta brecha formativa tiene un impacto directo en la implementación efectiva de estas tecnologías y en la capacidad de garantizar su uso seguro, ético y eficaz.

8.3.3. Riesgo de ampliar inequidades en salud

La inteligencia artificial (IA), si bien ofrece una promesa de mejora en la precisión diagnóstica y la eficiencia clínica, puede también convertirse en una poderosa herramienta de exclusión si no se implementa con criterios de equidad. En el campo de la ginecología y obstetricia —donde ya existen importantes desigualdades en el acceso a los servicios de salud, la calidad asistencial y los resultados perinatales— la adopción de IA sin perspectiva social, de género y de justicia distributiva puede ampliar aún más las brechas existentes, tanto a nivel individual como colectivo.

1. Sesgos en los modelos que perpetúan desigualdades

Los modelos de IA aprenden de los datos con los que son entrenados. Si estos datos reflejan desigualdades sociales, sesgos históricos o exclusiones estructurales, es probable que los algoritmos reproduzcan —y en algunos casos refuercen— esas mismas distorsiones.

Por ejemplo:

- Un modelo para predecir riesgo de parto prematuro entrenado exclusivamente con datos de mujeres urbanas con acceso regular a controles prenatales, puede fallar sistemáticamente en mujeres que viven en zonas rurales, en condiciones precarias o con menor adherencia al control.
- Un sistema automatizado de análisis de citología cervical que ha sido calibrado con imágenes de mujeres caucásicas puede tener una sensibilidad significativamente inferior en mujeres de ascendencia afroamericana o indígena, generando falsos negativos que afectan a poblaciones ya desatendidas.
- Algoritmos para evaluar fertilidad pueden no tener en cuenta particularidades étnicas, culturales o de identidad de género, generando recomendaciones clínicas no inclusivas o inadecuadas.

Estos sesgos no son siempre intencionados, pero sí son previsibles. Y su impacto puede ser devastador si las decisiones clínicas se automatizan sin validación crítica y sin conocimiento de sus limitaciones.

2. Impacto diferenciado según vulnerabilidad social

El acceso a tecnologías basadas en IA no depende solo del sistema sanitario, sino también de factores personales y sociales:

- Mujeres con bajo nivel educativo pueden desconfiar o no comprender el uso de algoritmos en su atención.
- Pacientes migrantes, sin documentación o sin dominio del idioma local, pueden quedar excluidas de programas automatizados de seguimiento que dependen de aplicaciones móviles, mensajería electrónica o citas digitales.
- Mujeres en situación de violencia, marginación o con enfermedades mentales pueden no ser captadas adecuadamente por modelos que asumen un seguimiento regular, una adherencia estándar o una disponibilidad de datos completa.

En todos estos casos, la IA puede fallar doblemente: no detectar el riesgo clínico real y, al mismo tiempo, reforzar la invisibilidad institucional de estas mujeres.

3. Tecnología accesible ≠ tecnología equitativa

Es importante distinguir entre la accesibilidad tecnológica y la equidad real en salud. El simple hecho de que una herramienta esté disponible no significa que su uso sea igualitario ni que beneficie a todos por igual. Incluso soluciones aparentemente neutrales —como aplicaciones móviles para seguimiento del embarazo o portales digitales para agendar ecografías— pueden excluir a quienes:

- No tienen teléfono móvil compatible.
- No cuentan con conectividad estable.
- No saben leer o escribir con fluidez.
- No comprenden el idioma o las instrucciones.

En ese sentido, una estrategia de implementación de IA verdaderamente equitativa debe contemplar las condiciones sociales, económicas, educativas y culturales de las mujeres a las que pretende servir.

4. Doble velocidad asistencial y medicina estratificada por recursos

Otro riesgo es que la IA consolide un modelo de “doble velocidad” en el acceso a la salud gineco-obstétrica:

- Una atención de alta precisión y decisión asistida por algoritmos en centros de excelencia, grandes ciudades o redes privadas.
- Una atención tradicional, sin soporte tecnológico, basada exclusivamente en la experiencia clínica del profesional, en centros pequeños, zonas rurales o áreas deprimidas.


Esta brecha no solo compromete la equidad sanitaria, sino también la justicia interterritorial y la confianza en el sistema de salud.

Por ello, el despliegue de IA en ginecología y obstetricia debe ir acompañado de mecanismos de evaluación de impacto en equidad, que analicen explícitamente cómo afectan estas herramientas a las poblaciones más vulnerables y qué medidas pueden adoptarse para mitigar efectos discriminatorios.

8.3.4. Propuestas para soluciones inclusivas y sostenibles

Superar las desigualdades en el acceso a la inteligencia artificial en ginecología y obstetricia no es sólo un imperativo ético, sino también una condición necesaria para que la tecnología tenga un impacto real y duradero en la salud de la población. Frente al riesgo de exclusión, subrepresentación o elitización tecnológica, es posible y deseable construir un enfoque de IA clínica centrada en la equidad, que combine innovación con justicia social y sostenibilidad estructural.

A continuación, se presentan cinco líneas estratégicas para avanzar hacia soluciones inclusivas:



La Figura representa las fases esenciales para una implementación equitativa, inclusiva y sostenible de la inteligencia artificial en ginecología y obstetricia.

1. Diseño participativo y contextualizado

El desarrollo de herramientas de IA no puede ser un proceso vertical ni desconectado del terreno. Es necesario que los algoritmos se diseñen con y para los profesionales y pacientes que los utilizarán. Esto implica:

- Incluir ginecólogos, obstetras, matronas y profesionales de atención primaria en las fases tempranas del diseño, no solo como validadores finales.
- Ajustar las herramientas al nivel de complejidad, conectividad y flujo de trabajo real de cada entorno clínico.
- Priorizar soluciones modulares, escalables y adaptables, que puedan implementarse progresivamente sin requerir cambios drásticos en la infraestructura.
- Integrar la perspectiva de las pacientes, especialmente de colectivos vulnerables, para evitar ceguera social o sesgos de diseño.

Ejemplo: un sistema de alerta de riesgo obstétrico basado en SMS con lenguaje sencillo y codificado puede ser más útil en comunidades rurales que una aplicación de alto nivel tecnológico con interfaz compleja.

2. Uso de datos representativos y abiertos

La calidad y equidad de los modelos dependen directamente de los datos con los que se entrenan. Para ello es clave:

- Fomentar la creación de cohortes multicéntricas, diversas y abiertas, que incluyan población de distintas regiones, etnias, condiciones sociales y niveles asistenciales.
- Aplicar principios de gobernanza ética, consentimiento informado y auditoría externa en el uso de datos sensibles.
- Establecer repositorios accesibles, donde centros con menos recursos puedan beneficiarse de modelos entrenados en poblaciones comparables.
- Invertir en etiquetado clínico de calidad y curación de datos para mejorar la precisión y explicabilidad de los algoritmos.

Este enfoque fomenta una IA verdaderamente colaborativa y evita que solo unos pocos centros concentren el poder tecnológico y científico.

3. Inversión pública y estrategia institucional

La equidad tecnológica no puede depender exclusivamente de la iniciativa privada. Es necesario que los sistemas de salud y las políticas públicas lideren el despliegue ético y equitativo de la IA. Esto incluye:

- Integrar la IA en los planes nacionales de salud digital y atención materno-infantil.
- Financiar proyectos piloto en entornos desfavorecidos con evaluación rigurosa.
- Establecer unidades regionales de referencia que brinden apoyo técnico y formativo.
- Crear incentivos para que las empresas desarrolladoras incluyan requisitos de accesibilidad y transparencia en sus productos.

La tecnología, si es solo rentable pero no equitativa, pierde su valor social.

4. Formación inclusiva del personal sanitario

La alfabetización en inteligencia artificial debe formar parte del desarrollo profesional continuo, con especial atención a:

- Profesionales en zonas rurales o con menor exposición tecnológica.
- Equipos multidisciplinares que incluyan médicos, matronas, enfermeras, técnicos y administrativos.
- Formación práctica basada en escenarios clínicos reales y casos de uso adaptados al contexto.

Además, es importante ofrecer formación ética, para que los profesionales comprendan no solo el “cómo funciona” la IA, sino también el “por qué importa” su aplicación crítica y responsable.

5. Evaluación del impacto en equidad

Toda implementación de IA en ginecología y obstetricia debería incluir una evaluación sistemática del impacto sobre la equidad, que analice:

- Quién se beneficia y quién queda excluido.
- Si hay poblaciones que reciben un servicio asistido por IA y otras que no.
- Si el algoritmo funciona igual de bien en distintos subgrupos poblacionales.
- Si se han reducido o ampliado las desigualdades en resultados clínicos (mortalidad materna, acceso a pruebas diagnósticas, detección precoz de cáncer, etc.).

Esta evaluación no debe entenderse como un obstáculo, sino como una herramienta de mejora continua y garantía de justicia tecnológica.

Solo una inteligencia artificial diseñada con justicia, responsabilidad y mirada clínica podrá transformar de verdad la salud de las mujeres del siglo XXI.

Bibliografía

1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med.* 2019;25(1):44–56.
2. Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. *Nat Med.* 2019;25(1):24–29.
3. McCradden MD, Joshi S, Mazwi M, Anderson JA. Ethical limitations of algorithmic fairness solutions in health care machine learning. *Lancet Digit Health.* 2020;2(5):e221–3.
4. Kelly CJ, Karthikesalingam A, Suleyman M, Corrado G, King D. Key challenges for delivering clinical impact with artificial intelligence. *BMC Med.* 2019;17:195.
5. European Commission. Proposal for a Regulation laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). COM/2021/206 final.
6. Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo (RGPD). *Diario Oficial de la Unión Europea*, L119/1, 2016.
7. Agencia Española de Protección de Datos. Recomendaciones para una inteligencia artificial confiable. Madrid: AEPD; 2020.
8. Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. *Science.* 2019;366(6464):447–53.
9. DeCamp M, Lindvall C. Latent bias and the implementation of artificial intelligence in medicine. *JAMA.* 2020;324(3):235–6.

10. Rajkomar A, Hardt M, Howell MD, Corrado G, Chin MH. Ensuring fairness in machine learning to advance health equity. *Ann Intern Med*. 2018;169(12):866–72.
11. Beam AL, Manrai AK, Ghassemi M. Challenges to the reproducibility of machine learning models in health care. *JAMA*. 2020;323(4):305–6.
12. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nat Mach Intell*. 2019;1:206–15.
13. Holzinger A, Langs G, Denk H, Zatloukal K, Müller H. Causability and explainability of artificial intelligence in medicine. *Wiley Interdiscip Rev Data Min Knowl Discov*. 2019;9(4):e1312.
14. Panigutti C, Perotti A, Guidotti R, Giannotti F. Explaining deep learning models through rule-based approximations. *Knowl Based Syst*. 2021;221:106923.
15. Ministerio de Salud de México. Ley Federal de Protección de Datos Personales en Posesión de los Particulares (LFPDPPP). Diario Oficial de la Federación, 2010.
16. World Health Organization. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: WHO; 2021.
17. Floridi L, Cowls J, Beltrametti M, et al. AI4People—An ethical framework for a good AI society: Opportunities, risks, principles, and recommendations. *Minds Mach*. 2018;28:689–707.
18. Dignum V. Responsible Artificial Intelligence: Designing AI for Human Values. Cham: Springer; 2019.
19. Gichoya JW, Banerjee I, Bhimireddy AR, et al. AI recognition of patient race in medical imaging: a modelling study. *Lancet Digit Health*. 2022;4(6):e406–14.
20. Coiera E. The last mile: where artificial intelligence meets reality. *J Med Internet Res*. 2019;21(11):e16323.

9. CONCLUSIONES Y PERSPECTIVAS

9. Conclusiones y perspectivas

Dra. Cristina Carames Sánchez

9.1 Resumen de los avances actuales

En la última década, la inteligencia artificial ha experimentado un desarrollo sin precedentes en el ámbito sanitario, pasando de ser un campo experimental para consolidarse e integrarse como herramienta clínica en múltiples áreas de la medicina. Su aplicación a la ginecología, disciplina caracterizada por la coexistencia de aspectos clínicos, quirúrgicos, reproductivos y preventivos, permite avanzar hacia una medicina más personalizada, segura y eficiente.

La inteligencia artificial, ayuda a un ginecólogo en áreas tales como: diagnóstico, pronóstico, apoyo en la toma de decisiones clínicas y reducción de labor de documentación y codificación clínica.

En el diagnóstico, los algoritmos de IA, especialmente los basados en aprendizaje profundo, mejoran la interpretación de imágenes como ecografías, resonancias y colposcopias, permitiendo una detección más precisa de patologías como cáncer de cuello uterino, ovario y endometrio, con tasas de precisión que pueden superar el 90% en algunos contextos.[1][2][3] Además, la IA facilita la identificación de biomarcadores y patrones en datos genómicos, lo que contribuye a la medicina personalizada y a la selección de tratamientos más adecuados para cada paciente.[4][3]

En el pronóstico, la IA permite predecir complicaciones obstétricas (por ejemplo, preeclampsia, parto prematuro, hemorragia posparto) mediante modelos que integran datos clínicos, laboratoriales y de historia electrónica, optimizando la estratificación de riesgo y la planificación de intervenciones preventivas.[5][6] En oncología ginecológica, la IA ayuda a estimar la respuesta al tratamiento y el riesgo de recurrencia, lo que mejora la toma de decisiones terapéuticas.[7][3]

Finalmente, la IA apoya al ginecólogo en la gestión clínica mediante sistemas de soporte a la decisión, automatización de tareas administrativas y generación de recomendaciones basadas en grandes volúmenes de datos, lo que incrementa la eficiencia y reduce errores.[8][9][10] Es fundamental que la integración de IA se realice bajo principios éticos, con supervisión humana y formación continua del personal, como recomiendan las guías estratégicas publicadas en la literatura reciente.[9]

Por lo tanto, las conclusiones actuales sobre los avances de la inteligencia artificial (IA) en ginecología muestran que la IA tiene un papel prometedor como herramienta complementaria en el diagnóstico, estratificación de riesgo y predicción de resultados en patologías ginecológicas, tanto benignas como malignas. Sin embargo, la evidencia disponible indica que la mayoría de los estudios publicados presentan limitaciones metodológicas importantes, especialmente en la validación externa y el diseño multicéntrico prospectivo, lo que afecta la generalización y aplicabilidad clínica de los modelos desarrollados.

La perspectiva es que, para que la IA se integre de manera segura y efectiva en la práctica ginecológica, se requieren estudios prospectivos, multicéntricos, con validación externa y calibración adecuada, así como transparencia en el reporte y supervisión humana continua. El consenso en la literatura es que la IA debe ser considerada una herramienta de apoyo y no un sustituto del juicio clínico experto.

La integración de la inteligencia artificial (IA) en Quirónsalud forma parte de una estrategia corporativa orientada hacia la medicina basada en valor y la innovación tecnológica. Dentro del ámbito de la salud de la mujer, la IA se ha incorporado en tres líneas principales: automatización de documentación clínica (Scribe), estandarización y personalización de la práctica clínica y analítica de datos clínicos (SALUD-IA) y aplicaciones en imagen médica. Estas experiencias permiten valorar cómo una red hospitalaria de gran escala puede implementar de manera real la IA, superando los límites de los proyectos piloto y garantizando su impacto en la práctica clínica diaria.

9.1.1 Proyecto Scribe y apoyo a la documentación clínica en ginecología

Uno de los grandes desafíos en la práctica clínica es la sobrecarga administrativa. En consultas de ginecología y obstetricia, hasta un 40 % del tiempo del especialista se dedica a la introducción manual de datos en la historia clínica. El proyecto Scribe, desarrollado en Quirónsalud, tiene como objetivo reducir esta carga mediante un sistema de procesamiento de lenguaje natural y reconocimiento de voz capaz de transcribir y estructurar de forma automática la interacción médico-paciente. El sistema capta la conversación clínica, la transcribe en tiempo real y genera un informe estructurado que se integra directamente en la historia clínica electrónica. Además, codifica términos relevantes según estándares internacionales. En ginecología se está utilizando para todo tipo de consultas, especialmente en consultas de control del embarazo, revisiones de patología ginecológica benigna o entrevistas previas a tratamientos de fertilidad. En todos estos escenarios, Scribe ha demostrado reducir el tiempo de registro administrativo, permitiendo al especialista centrarse más en la interacción con la paciente. Además, ha demostrado una disminución significativa del tiempo medio de consulta, homogeneización de la documentación y mejora de la codificación y potencial para aumentar la calidad de los datos clínicos que alimentan modelos predictivos. En un ámbito tan sensible como la salud reproductiva, esta herramienta libera tiempo del profesional para una atención más empática y personalizada, fortaleciendo la relación médico-paciente.

9.1.2. Proyecto SALUD-IA, estandarización, personalización y analítica de datos clínicos

El proyecto SALUD-IA representa uno de los núcleos de la estrategia de Quirónsalud en inteligencia artificial. Su objetivo es detectar a los pacientes para ofrecerles la mejor práctica clínica basada en la evidencia y personalizando a los valores y preferencias de cada persona. El proyecto incorpora un plan de prestación de servicios, comunicación digital, plan de seguridad y evaluación de resultados en salud mediante PROMs y PREMs. La incorporación de resultados reportados por pacientes para evaluar calidad de vida tras intervenciones ginecológicas posiciona al grupo acorde con su modelo asistencial basado en valor y permite ajustar modelos de predicción. Este enfoque no solo permite mejorar la práctica clínica, sino también abrir la puerta a proyectos de investigación multicéntricos en salud de la mujer, situando a Quirónsalud como referente en innovación basada en datos y procesos que sitúan al paciente en el centro del proceso asistencial y humanizan la asistencia sanitaria.

9.1.3. IA en Imagen Médica, cribado mamográfico asistido por IA

El cáncer de mama sigue siendo la neoplasia más frecuente en mujeres y por otra parte la que supone la mayor demanda en los hospitales de Quirónsalud. La implementación de algoritmos de IA en hospitales como la Fundación Jiménez Díaz y otros centros hospitales del grupo Quirónsalud permite, priorizar automáticamente estudios sospechosos, ofrecer una segunda lectura al radiólogo, actuando como sistema de doble control, reducir tiempos de lectura y mejorar la sensibilidad diagnóstica. Los resultados preliminares muestran una reducción de falsos positivos y un incremento en la seguridad del cribado, lo que impacta directamente en la experiencia de las pacientes y en la eficiencia del proceso asistencial.

Como reflexión final del modelo asistencial y operativo de Quirónsalud podemos decir que las experiencias demuestran que la IA puede integrarse en la práctica clínica real, siempre que se cumplan las tres condiciones fundamentales; 1.Gobernanza ética y legal (comités corporativos de ética e innovación para garantizar seguridad, transparencia y cumplimiento normativo); 2.Estandarización de datos (proyectos como SALUD-IA aseguran que los algoritmos se desarrollen con información representativa y de calidad) y 3.Aplicación práctica y escalable (desde la consulta diaria, Scribe, hasta el cribado poblacional con imagen mamográfica, la IA ya está generando beneficios tangibles en salud de la mujer dentro del grupo)

En conjunto, estos proyectos posicionan a Quirónsalud como un laboratorio real de innovación en IA aplicada a ginecología y obstetricia, alineado con la visión de una medicina personalizada, predictiva y basada en valor.

9.2. Consideraciones para una implementación ética y segura de la IA

Las consideraciones necesarias para una implementación ética y segura de la inteligencia artificial en ginecología incluyen salvaguardar la privacidad y seguridad de los datos clínicos, mitigar el sesgo algorítmico, garantizar la transparencia y explicabilidad de los modelos, y mantener la supervisión humana en la toma de decisiones clínicas. Es fundamental que los algoritmos sean validados externamente en poblaciones diversas y multicéntricas, y que se reporten métricas de desempeño y calibración de manera transparente para asegurar la aplicabilidad clínica y minimizar riesgos.[11][12][13][14]

La formación continua del personal sanitario y la colaboración multidisciplinaria entre clínicos, ingenieros y desarrolladores de IA son esenciales para una integración responsable. Además, se debe definir el rol de la IA dentro de los marcos de gobernanza clínica, promoviendo la comunicación clara con los pacientes sobre el uso de estas tecnologías y sus implicaciones.[11][15][16] La equidad en el acceso y la inclusión de variables sociodemográficas en el desarrollo y validación de los modelos son necesarias para evitar la perpetuación de desigualdades en salud.[16][14]

Finalmente, la literatura actual recomienda que la IA se utilice como herramienta de apoyo y no como sustituto del juicio clínico experto, y que se establezca un ciclo de retroalimentación continua entre usuarios y desarrolladores para mejorar la seguridad y eficacia de los sistemas implementados.[11][15][13]

9.3. Recomendaciones para la investigación y desarrollo futuros

Las recomendaciones para la investigación y el desarrollo futuro de la inteligencia artificial en ginecología se centran en fortalecer la calidad metodológica, la seguridad y la ética, así como en promover estudios prospectivos, multicéntricos y con validación externa. Es fundamental priorizar el diseño de investigaciones que incluyan cohortes diversas y representativas, con separación clara entre datos de entrenamiento y validación, y que reporten métricas de desempeño y calibración de manera transparente para garantizar la aplicabilidad clínica y minimizar el sesgo algorítmico.[17][18]

Se destaca la importancia de la formación continua del personal sanitario en competencias digitales y en el uso responsable de la IA, así como la comunicación transparente con los pacientes sobre el uso de estas tecnologías y sus implicaciones.[18][19] Finalmente, se recomienda que los resultados de los estudios sean evaluados bajo estándares internacionales de reporte y validación, como los propuestos por PRISMA-P, QUADAS-AI y CONSORT-AI.[17][18]

Los criterios específicos propuestos por QUADAS-AI para mejorar el diseño y la validación de estudios futuros de inteligencia artificial en ginecología, especialmente en relación con la validación externa y estudios multicéntricos prospectivos, incluyen:

1. Selección de sujetos: Es fundamental especificar el tamaño muestral, la fuente de los datos, el modelo de escáner utilizado y asegurar que los datos provengan de cohortes representativas y, preferentemente, multicéntricas. Se recomienda el uso de conjuntos de datos abiertos y la descripción detallada de los criterios de inclusión y exclusión para minimizar el sesgo de selección.[17][18][19]
2. Separación de datos: Se debe realizar una división a nivel de paciente entre los conjuntos de entrenamiento y prueba, evitando el sobreajuste y asegurando que la validación externa se realice en poblaciones independientes y reales, no solo en datos internos.[17][18][19]

3. Validación externa: La validación de los modelos debe realizarse en cohortes externas, idealmente multicéntricas y prospectivas, que reflejen la diversidad clínica y geográfica. Esto permite evaluar la robustez del modelo en diferentes entornos clínicos.[20][17][18][19]
4. Calibración y reporte: Es necesario reportar la calibración del modelo (acuerdo entre predicciones y resultados observados) y utilizar métricas apropiadas para el contexto clínico, como sensibilidad, especificidad y AUC. La transparencia en el reporte y la comparación con estándares clínicos reconocidos son esenciales.[19]
5. Flujo y tiempo: El intervalo entre la prueba índice (IA) y el estándar de referencia debe ser razonable y claramente documentado para evitar sesgos de flujo.[17][18]
6. Referencia estándar: El estándar de referencia debe estar bien definido y correctamente clasificar la condición objetivo, permitiendo una comparación válida entre el desempeño de la IA y los métodos convencionales.[17][18]
7. Evaluación de sesgo y aplicabilidad: Se recomienda el uso sistemático de herramientas como QUA-DAS-AI para identificar y mitigar riesgos de sesgo en todos los dominios, asegurando la aplicabilidad clínica de los resultados.[20][17][18][19]

Estos criterios buscan garantizar que los estudios de IA en ginecología sean metodológicamente sólidos, reproducibles y aplicables en la práctica clínica real, facilitando la integración segura y efectiva de la IA en el diagnóstico y manejo ginecológico.[20][17][18][19]

Bibliografía

1. Revolutionizing Women's Health: A Comprehensive Review of Artificial Intelligence Advancements in Gynecology. Brandão M, Mendes F, Martins M, et al. *Journal of Clinical Medicine*. 2024;13(4):1061. doi:10.3390/jcm13041061.
2. Artificial Intelligence in the Diagnosis and Management of Gynecologic Cancer. Paiboonborirak C, Abu-Rustum NR, Wilailak S. *International Journal of Gynaecology and Obstetrics: The Official Organ of the International Federation of Gynaecology and Obstetrics*. 2025;. doi:10.1002/ijgo.70094.
3. Research Progress of Artificial Intelligence in the Early Screening, Diagnosis, Precise Treatment and Prognosis Prediction of Three Central Gynecological Malignancies. Wang Q, Zhou X, Wu J, et al. *Frontiers in Oncology*. 2025;15:1648407. doi:10.3389/fonc.2025.1648407.
4. Artificial Intelligence and Allied Subsets in Early Detection and Preclusion of Gynecological Cancers. Garg P, Mohanty A, Ramisetty S, et al. *Biochimica Et Biophysica Acta. Reviews on Cancer*. 2023;1878(6):189026. doi:10.1016/j.bbcan.2023.189026.
5. The Transformative Potential of AI in Obstetrics and Gynaecology. Dick K, Humber J, Ducharme R, et al. *Journal of Obstetrics and Gynaecology Canada : JOGC = Journal d'Obstetrique Et Gynecologie Du Canada : JOGC*. 2024;46(3):102277. doi:10.1016/j.jogc.2023.102277.
6. Using Artificial Intelligence as a Technological Gynecologic and Obstetric Health: A Narrative Literature Review. Dos Santos GG. *International Journal of Gynaecology and Obstetrics: The Official Organ of the International Federation of Gynaecology and Obstetrics*. 2025;. doi:10.1002/ijgo.70455.
7. Applying Artificial Intelligence to Gynecologic Oncology: A Review. Mysona DP, Kapp DS, Rohatgi A, et al. *Obstetrical & Gynecological Survey*. 2021;76(5):292-301. doi:10.1097/OGX.0000000000000902.
8. Introduction to Machine Learning in Obstetrics and Gynecology. Shazly SA, Trabuco EC, Ngufor CG, Famuyide AO. *Obstetrics and Gynecology*. 2022;139(4):669-679. doi:10.1097/AOG.0000000000004706.
9. Strategic Guidelines to Integrate Artificial Intelligence in Obstetrics and Gynecology: Best Practices and Ethical Considerations. Sengupta P, Dutta S, Bagchi S, et al. *Reproductive Sciences (Thousand Oaks, Calif.)*. 2025;10.1007/s43032-025-01903-w. doi:10.1007/s43032-025-01903-w.
10. Contributions of Artificial Intelligence Reported in Obstetrics and Gynecology Journals: Systematic Review. Dhombres F, Bonnard J, Bailly K, et al. *Journal of Medical Internet Research*. 2022;24(4):e35465. doi:10.2196/35465.

11. Strategic Guidelines to Integrate Artificial Intelligence in Obstetrics and Gynecology: Best Practices and Ethical Considerations. Sengupta P, Dutta S, Bagchi S, et al. *Reproductive Sciences* (Thousand Oaks, Calif.). 2025;:10.1007/s43032-025-01903-w. doi:10.1007/s43032-025-01903-w.
12. Revolutionizing Women's Health: A Comprehensive Review of Artificial Intelligence Advancements in Gynecology. Brandão M, Mendes F, Martins M, et al. *Journal of Clinical Medicine*. 2024;13(4):1061. doi:10.3390/jcm13041061.
13. Use of Artificial Intelligence in Obstetric and Gynaecological Diagnostics: A Protocol for a Systematic Review and Meta-Analysis. Chaurasia A, Curry G, Zhao Y, et al. *BMJ Open*. 2024;14(5):e082287. doi:10.1136/bmjopen-2023-082287.
14. Artificial Intelligence in the Diagnosis and Management of Gynecologic Cancer. Paiboonborirak C, Abu-Rustum NR, Wilailak S. *International Journal of Gynaecology and Obstetrics: The Official Organ of the International Federation of Gynaecology and Obstetrics*. 2025;. doi:10.1002/ijgo.70094.
15. The Transformative Potential of AI in Obstetrics and Gynaecology. Dick K, Humber J, Ducharme R, et al. *Journal of Obstetrics and Gynaecology Canada : JOGC = Journal d'Obstetrique Et Gynecologie Du Canada : JOGC*. 2024;46(3):102277. doi:10.1016/j.jogc.2023.102277.
16. Using Artificial Intelligence as a Technological Gynecologic and Obstetric Health: A Narrative Literature Review. Dos Santos GG. *International Journal of Gynaecology and Obstetrics: The Official Organ of the International Federation of Gynaecology and Obstetrics*. 2025;. doi:10.1002/ijgo.70455.
17. Role of Artificial Intelligence Applied to Ultrasound in Gynecology Oncology: A Systematic Review. Moro F, Ciancia M, Zace D, et al. *International Journal of Cancer*. 2024;155(10):1832-1845. doi:10.1002/ijc.35092.
18. Application of Artificial Intelligence to Ultrasound Imaging for Benign Gynecological Disorders: Systematic Review. Moro F, Giudice MT, Ciancia M, et al. *Ultrasound in Obstetrics & Gynecology : The Official Journal of the International Society of Ultrasound in Obstetrics and Gynecology*. 2025;65(3):295-302. doi:10.1002/uog.29171.
19. Artificial Intelligence Applied to Ultrasound Diagnosis of Pelvic Gynecological Tumors: A Systematic Review and Meta-Analysis. Geysels A, Garofalo G, Timmerman S, et al. *Gynecologic and Obstetric Investigation*. 2025;:1-22. doi:10.1159/000545850.
20. Revised Tool for the Quality Assessment of Diagnostic Accuracy Studies Using AI (QUADAS-AI): Protocol for a Qualitative Study. Guni A, Sounderajah V, Whiting P, et al. *JMIR Research Protocols*. 2024;13:e58202. doi:10.2196/58202.

10. APENDIX. RECURSOS TÉCNICOS Y GUÍAS PRÁCTICAS

Apendix: Recursos técnicos y guías prácticas

A.1. Introducción a las herramientas de programación para IA en salud

Transcripción y resumen del contenido original

El esquema menciona tres grandes bloques:

1. Lenguajes de programación

- **Python**
 - o Más usado en IA por su sintaxis simple y gran ecosistema de librerías.
 - o Compatible con librerías como TensorFlow, PyTorch, Scikit-learn, Pandas, NumPy.
- **R**
 - o Potente en estadística y bioinformática.
 - o Muy útil para análisis de datos clínicos, epidemiología y visualización.
- **Julia / MATLAB**
 - o Usados en entornos científicos y modelado biomédico de alto rendimiento.

2. Bibliotecas y frameworks de IA

- **TensorFlow / PyTorch:** para redes neuronales, deep learning y modelos de diagnóstico automático.
- **Scikit-learn:** para modelos clásicos de machine learning (regresión, clasificación, clustering).
- **Keras:** interfaz de alto nivel para deep learning en Python.
- **OpenCV:** procesamiento de imágenes médicas (TC, RX, RM).
- **NLTK / spaCy / MedSpaCy:** procesamiento de lenguaje natural clínico (informes, notas médicas).
- **MONAI:** librería específica de deep learning para imágenes médicas.

3. Entornos de desarrollo y gestión de datos

- **Jupyter Notebook / Google Colab:** para prototipado rápido y docencia en IA médica.
- **Anaconda:** distribución que facilita la instalación de paquetes científicos.
- **Git / GitHub:** control de versiones y trabajo colaborativo en proyectos de investigación.
- **FHIR / HL7:** estándares para intercambio de datos clínicos estructurados.
- **DICOM:** formato estándar para imágenes médicas.

Versión ampliada y explicativa: “Guía didáctica para empezar en IA en salud”

1. Lenguajes base

- **Python** → el más recomendado para comenzar.
Ejemplo práctico: crear un modelo para predecir riesgo de diabetes con *Scikit-learn*.
- **R** → ideal si ya trabajas con análisis estadístico clínico o salud pública.
Ejemplo: regresión logística en pacientes hospitalizados.
- **Julia / MATLAB** → útiles si se trabaja en simulaciones fisiológicas o modelos predictivos numéricos.

2. Herramientas clave

Tipo	Herramienta	Aplicación en salud
Deep Learning	TensorFlow, PyTorch	Detección automática en imágenes médicas (p. ej., tumores, retinopatía)
Machine Learning clásico	Scikit-learn	Modelos de predicción de riesgo clínico o resultados terapéuticos
Procesamiento de texto	MedSpaCy, cTAKES	Extracción de información de historias clínicas
Imagen médica	MONAI, OpenCV	Segmentación de órganos, análisis de TAC/RM
Datos clínicos estructurados	FHIR, HL7	Interoperabilidad y comunicación entre sistemas hospitalarios

3. Infraestructura y trabajo colaborativo

- **Jupyter/Colab** → entornos ideales para exploración y enseñanza.
- **GitHub / GitLab** → facilitan reproducibilidad y publicación de modelos.
- **Docker / Kubernetes** → permiten desplegar IA médica de forma segura y escalable.
- **Anonimización y cumplimiento ético:** herramientas como *PyDICOM* o *deid* ayudan a garantizar privacidad (GDPR, HIPAA).

Recomendación práctica

1. Instala **Anaconda** para gestionar tu entorno.
2. Aprende **Python + PyTorch + MONAI** (imagen médica).
3. Complementa con **MedSpaCy o cTAKES** (texto clínico).
4. Usa **FHIR / DICOM** para conectar tus modelos con datos reales del hospital.
5. Documenta y comparte tu trabajo en **GitHub**.

Introducción a las herramientas de programación para IA en salud

Versión ampliada, explicativa y didáctica del tema “Introducción a las herramientas de programación para IA en salud”, pensada para **médicos, residentes o investigadores clínicos** que desean iniciarse en el uso práctico de la inteligencia artificial en el ámbito sanitario.

La inteligencia artificial (IA) está transformando la medicina: desde el diagnóstico por imagen hasta la predicción de riesgos, la gestión hospitalaria o la interpretación de textos clínicos. Para aprovechar su potencial, es esencial conocer **las herramientas de programación y entornos de desarrollo** más utilizados.

A continuación se presenta una guía didáctica estructurada en cuatro bloques:

1. Lenguajes de programación más usados en IA médica

Lenguaje	Fortalezas	Ejemplos de uso en salud	Nivel de dificultad
Python	Sintaxis simple, gran comunidad, miles de librerías IA	Modelos predictivos, procesamiento de imágenes médicas, NLP clínico	★ Fácil
R	Potente en análisis estadístico y bioinformático	Epidemiología, análisis de cohortes, datos genómicos	★ ★ Intermedio
Julia	Alta velocidad y cálculo numérico	Modelos fisiológicos o simulaciones biomédicas	★ ★ ★ Avanzado
MATLAB	Amplio uso académico, gran soporte en ingeniería biomédica	Análisis de señales médicas, procesamiento ECG/EEG	★ ★ Intermedio

💡 Recomendación inicial:

Comenzar con **Python** debido a que es el lenguaje estándar en IA aplicada a salud y dispone de abundante material educativo y soporte clínico.

2. Bibliotecas y frameworks de inteligencia artificial

Estas librerías simplifican el desarrollo de modelos de IA, desde el aprendizaje automático clásico hasta las redes neuronales profundas.

Herramienta	Tipo	Aplicación en salud	Comentario
TensorFlow / Keras	Deep Learning	Clasificación de imágenes médicas, detección de tumores	Ideal para proyectos docentes o clínicos en fase de investigación
PyTorch	Deep Learning	Análisis de imágenes, series temporales fisiológicas	Muy flexible y con comunidad activa (base de MONAI)
Scikit-learn	Machine Learning clásico	Modelos predictivos simples (riesgo cardiovascular, reingresos, etc.)	Requiere menos datos y hardware
OpenCV	Visión por computador	Procesamiento de ecografías, RX, TC	Muy útil en preprocesamiento de imágenes
MONAI	Deep Learning médico	Segmentación, clasificación, cuantificación en imágenes DICOM	Librería especializada en salud
MedSpaCy / cTAKES	Procesamiento de texto médico	Extracción de información de informes clínicos	Permiten crear asistentes clínicos o sistemas de vigilancia epidemiológica

3. Entornos de desarrollo y gestión de datos

Herramienta	Función	Ejemplo práctico
Jupyter Notebook	Entorno interactivo de Python	Probar modelos, visualizar datos de pacientes anonimizados
Google Colab	Ejecución en la nube con GPU gratuita	Entrenar redes neuronales sin instalación local
Anaconda	Gestor de entornos y librerías científicas	Facilita instalación y versiones seguras
Git / GitHub	Control de versiones y colaboración	Compartir código entre equipos de investigación
Docker / Kubernetes	Despliegue reproducible	Implementar IA en un entorno hospitalario controlado

4. Estándares de datos médicos e interoperabilidad

Para integrar la IA en el entorno clínico real, es esencial conocer los estándares de comunicación y formato de datos en salud.

Estándar	Qué hace	Aplicación práctica
DICOM	Estandariza imágenes médicas	Permite que la IA analice radiografías o TC directamente desde PACS
HL7 / FHIR	Estandariza datos clínicos y de historia médica	Conecta modelos IA con sistemas de información hospitalaria (HIS, EMR)
OMOP-CDM	Estructura datos para análisis poblacionales	Facilita la investigación multicéntrica y el uso de IA en Big Data clínico

5. Flujo de trabajo típico en un proyecto de IA médica

1. **Obtención y anonimización de datos** (imágenes, notas clínicas, señales fisiológicas).
2. **Exploración y limpieza** de datos con *Pandas* / *NumPy* / *PyDICOM*.
3. **Entrenamiento del modelo** con *PyTorch* / *TensorFlow* / *Scikit-learn*.
4. **Evaluación y validación clínica** con métricas (AUC, sensibilidad, especificidad).
5. **Despliegue y monitoreo** en un entorno hospitalario (Docker, FHIR).
6. **Auditoría ética y de sesgos** → cumplimiento GDPR / HIPAA.

6. Aplicaciones prácticas por área médica

Área	Ejemplo de uso de IA	Herramientas sugeridas
Radiología	Segmentación automática de lesiones	MONAI, PyTorch, OpenCV
Obstetricia / Ginecología	Análisis de ecografías o predicción de parto prematuro	TensorFlow, MONAI
Epidemiología clínica	Modelos de predicción de riesgo	Scikit-learn, R
Oncología	Estratificación de pacientes y supervivencia	CaPTk, PyTorch
Documentación médica	Procesamiento de notas e informes	MedSpaCy, cTAKES
Gestión hospitalaria	Predicción de demanda o reingresos	Scikit-learn, FHIR

7. Recomendación de ruta formativa práctica (para médicos)

Etapa	Objetivo	Herramientas sugeridas
1. Iniciación (1 mes)	Aprender Python y Jupyter	Python, Anaconda, Colab
2. Análisis básico de datos (2 meses)	Analizar datos clínicos simples	Pandas, Scikit-learn
3. Imagen médica (3 meses)	IA en diagnóstico por imagen	PyTorch, MONAI
4. NLP clínico (2 meses)	Extraer información de textos médicos	MedSpaCy, cTAKES
5. Integración hospitalaria (3 meses)	Conectar modelos con sistemas reales	FHIR, DICOM, Docker

Comentario final

El éxito de la IA en medicina no depende sólo de la potencia de los modelos, sino de la **comprensión clínica**, la **ética del dato** y la **capacidad de colaboración entre médicos e ingenieros**.

Con estas herramientas abiertas y accesibles, cualquier profesional sanitario puede iniciarse en la IA de forma estructurada y segura.

A.2. Bibliotecas de código abierto para el análisis de datos médicos

Lista ampliada de 15 plataformas y portales de código abierto para trabajar con inteligencia artificial aplicada a la medicina y la salud, organizadas por tipo de aplicación:

A. Imagen médica y diagnóstico asistido

Estas plataformas están centradas en análisis de imágenes médicas (TC, RM, RX, ecografía, etc.), segmentación y detección de patologías.

1. MONAI — monai.io

Framework de IA médica impulsado por NVIDIA y King's College London.

- Enfoque: deep learning en imágenes médicas.
- Integración con PyTorch, DICOM, y formatos clínicos.
- Usa modelos pre-entrenados (Model Zoo).
- Licencia: Apache 2.0.

2. Project InnerEye — microsoft.com/innereye

Herramientas open-source para segmentación y clasificación médica.

- Basado en PyTorch.
- Diseñado para flujos radiológicos y planificación radioterápica.
- Licencia: MIT.

3. 3D Slicer — [slicer.org](https://www.slicer.org)

Entorno completo para análisis, registro y visualización de imágenes 3D médicas.

- Ideal para investigación clínica, docencia y desarrollo de módulos IA.
- Soporta extensiones con Python.
- Licencia: BSD-style.

4. CaPTk (Cancer Imaging Phenomics Toolkit) — cbica.github.io/CaPTk

Software open-source del CBICA (UPenn) para análisis de imágenes oncológicas.

- Enfocado en tumores cerebrales, pulmonares y mamarios.
- Incluye módulos ML para predicción de supervivencia o respuesta terapéutica.
- Licencia: BSD 3-Clause.

5. Weasis — weasis.org

Visor DICOM open-source ampliamente usado en entornos hospitalarios.

- Integrable con PACS, RIS y flujos clínicos.
- Extensible para pipelines IA de pre-visualización o anotación.
- Licencia: Eclipse Public License.

B. Texto clínico, notas médicas y lenguaje natural

Herramientas para procesar informes, historias clínicas y literatura biomédica.

6. MedSpaCy — github.com/medspacy/medspacy

Extensión médica de spaCy, centrada en NLP clínico.

- Permite extracción de entidades médicas, negaciones, temporalidad.
- Compatible con modelos UMLS/SNOMED.
- Licencia: MIT.

7. cTAKES (clinical Text Analysis and Knowledge Extraction System) — ctakes.apache.org

Proyecto Apache veterano para procesamiento de texto clínico.

- Basado en NLP y ontologías médicas.
- Identifica síntomas, medicamentos, diagnósticos, relaciones temporales.
- Licencia: Apache 2.0.

8. BioClinical BERT / PubMedBERT — huggingface.co

Modelos de lenguaje abiertos entrenados con textos biomédicos.

- Usados para análisis de notas médicas, artículos o codificación diagnóstica.
- Se integran fácilmente con Hugging Face Transformers.

- Licencias variadas (ver en cada modelo).

C. Genómica y bioinformática

IA para análisis de datos genéticos, secuencias y biomarcadores.

9. DeepVariant — github.com/google/deepvariant

Modelo de Google basado en deep learning para detección de variantes genéticas.

- Convierte datos de secuenciación en imágenes para clasificación.
- Alto rendimiento y precisión validada.
- Licencia: BSD 3-Clause.

10. Bioconda — bioconda.github.io

Repositorio colaborativo de software bioinformático open-source.

- Facilita gestión de entornos y dependencias para IA biomédica.
- Se integra con Conda y pipelines reproducibles.
- Licencia: BSD 3-Clause.

11. OpenMEDLab — github.com/openmedlab

Marco open-source emergente para modelos fundacionales médicos.

- Multi-modal (imagen, texto, genómica).
- Pensado para investigación traslacional.
- Licencia: Apache 2.0.

D. Sistemas clínicos, interoperabilidad y datos

Plataformas para estructurar, compartir y analizar datos médicos con IA.

12. FHIRWorks / FHIR Server for Azure — github.com/microsoft/fhir-server

Servidor FHIR open-source compatible con HL7.

- Permite interoperabilidad y almacenamiento estructurado de datos clínicos.
- Ideal para conectar EHRs con sistemas de IA.
- Licencia: MIT.

13. OpenMRS (Open Medical Record System) — openmrs.org

Sistema de registros médicos libre y modular.

- Se puede integrar con módulos de IA para apoyo diagnóstico o predicción de riesgo.
- Usado en numerosos países en salud pública.

- Licencia: MPL 2.0.

14. GNU Health — gnuhealth.org

EHR libre orientado a salud pública y hospitalaria.

- Incluye gestión clínica, epidemiológica y social.
- Permite integración con módulos analíticos e IA.
- Licencia: GPL 3.

E. Plataformas integradas o colaborativas de IA médica

Entornos que reúnen imagen, texto y datos clínicos en un mismo ecosistema.

15. MAIA (Medical Artificial Intelligence Assistant) — github.com/kthcloud/MAIA

Plataforma modular para integrar modelos IA y colaboración clínica.

- Diseñada para investigación traslacional y despliegue hospitalario.
- Compatible con Kubernetes y pipelines MLOps.
- Licencia: Apache 2.0.

Recomendaciones

1. **Eligir 1–2 áreas de interés** (imagen, texto, o datos clínicos).
2. **Empezar con MONAI o MedSpaCy**, según sean imágenes o textos.
3. Usa **datos públicos anonimizados** (por ejemplo, conjuntos de NIH o PhysioNet).
4. Añadir herramientas de interoperabilidad (FHIR, OpenMRS) para conectar con entornos clínicos reales.
5. Evaluar explicabilidad y validación clínica antes de desplegar cualquier modelo.

Tabla comparativa de plataformas de IA médica de código abierto

Nº	Plataforma	Tipo de datos / aplicación	Nivel técnico requerido	Madurez clínica	Licencia	Comentario / Recomendación
1	MONAI	Imágenes médicas (TC, RM, RX, ecografía)	Medio–Alto	☐ Alta (usado en hospitales)	Apache 2.0	Estándar de facto para IA médica basada en imagen. Excelente documentación.
2	Project InnerEye	Imagen médica, radioterapia	Medio	☐ Alta	MIT	Muy bueno para segmentación y planificación radioterápica.
3	3D Slicer	Imagen médica 3D / análisis / visualización	Medio	☐ Media	BSD	Gran herramienta de investigación y docencia; no certificada como producto médico.

Nº	Plataforma	Tipo de datos / aplicación	Nivel técnico requerido	Madurez clínica	Licencia	Comentario / Recomendación
4	CaPTk	Imagen oncológica (tumores)	Medio	☐ Media	BSD 3-Clause	Ideal para proyectos en neuro-oncología o predicción de respuesta.
5	Weasis	Visualización DICOM / PACS	Bajo	☐ Alta	EPL 2.0	Excelente visor DICOM open source; puede integrarse con IA para análisis automático.
6	MedSpaCy	Texto clínico, informes médicos	Medio	☐ Alta (NLP clínico real)	MIT	Rápido de usar; basado en spaCy. Perfecto para extracción de entidades clínicas.
7	cTAKES	Texto clínico estructurado (UMLS, SNOMED)	Medio-Alto	☐ Alta	Apache 2.0	Muy sólido; algo técnico pero con gran interoperabilidad terminológica.
8	BioClinical-BERT / Pub-MedBERT	Texto biomédico (artículos, historias)	Medio	☐ Media	Varía (open weights)	Base para construir modelos NLP biomédicos; requiere ajustar a tu dominio.
9	DeepVariant	Genómica / secuenciación	Alto	☐ Alta (usado por Google y NIH)	BSD 3-Clause	Precisión muy alta; requiere GPU y datos genómicos de calidad.
10	Bioconda	Bioinformática / pipelines	Medio	☒ Media	BSD 3-Clause	Ideal para reproducibilidad y gestión de entornos IA biomédicos.
11	OpenMEDLab	Modelos fundacionales multi-modalidad	Alto	● Baja-Media (investigación)	Apache 2.0	Prometedor para integrar texto+imagen+genómica; requiere infraestructura.
12	FHIR Server for Azure	Datos clínicos estructurados (HL7 FHIR)	Medio	☐ Alta	MIT	Imprescindible si buscas interoperabilidad entre IA y EHRs.
13	OpenMRS	Historia clínica / EHR modular	Medio	☐ Alta	MPL 2.0	Muy usado globalmente; ideal para conectar IA con datos reales.
14	GNU Health	Historia clínica / salud pública	Medio	☐ Alta	GPL 3	Excelente para salud pública y proyectos hospitalarios comunitarios.
15	MAIA	Integración de modelos IA en entorno clínico	Alto	☐ Media	Apache 2.0	Plataforma moderna de investigación traslacional; ideal para hospitales que exploran IA.

Interpretación de columnas (Tabla comparativa)

- **Nivel técnico requerido:**

- o *Bajo*: Puede usarse sin programación avanzada.
- o *Medio*: Requiere conocimiento básico de Python / ML.
- o *Alto*: Implica pipelines IA, GPU, o integración avanzada.

- **Madurez clínica:**

- o Alta → Ya probado o desplegado en entornos hospitalarios reales.
- o Media → Validado en investigación, pendiente de certificación.
- o Baja → Experimental o de investigación temprana.

Recomendaciones prácticas

1. **Si se trabaja con imagen médica:** empezar por **MONAI** o **InnerEye** (fácil de desplegar, documentación excelente).
2. **Para texto clínico (informes, historias):** usar **MedSpaCy** como primer paso; si se necesita estructura semántica, añadir **cTAKES**.
3. **Si se interesa en IA traslacional:** combinar **OpenMRS + FHIR Server + MONAI** → flujo completo desde datos clínicos hasta modelo.
4. **Para proyectos hospitalarios reales:** integrar herramientas maduras (Weasis, MONAI, GNU Health) dentro de entornos seguros.
5. **Si investigas IA multimodal:** explorar **OpenMEDLab** o **MAIA**, ideales para el futuro de la IA médica integrativa.

Lista de portales y plataformas de código abierto (“open source”)

A continuación, una lista de **portales y plataformas de código abierto** (“open source”) interesantes para trabajar con IA, junto con una breve descripción de cada uno, lo que ofrecen y por qué pueden ser útiles.

1. Hugging Face



Qué es: Es una plataforma/comunidad que agrupa modelos de IA abiertos (especialmente modelos de lenguaje, visión, multimodal) que cualquiera puede acceder, modificar y desplegar. Hugging Face+2Built In+2

Por qué utilizarla:

- Gran repositorio de modelos ya entrenados listos para usar o adaptar.
- Comunidad activa y muchos recursos/tutoriales.
- Buena para trabajar rápido, “tomar prestado” un modelo y adaptarlo.

Cosas a tener en cuenta:

- Aunque el modelo sea de “código abierto”, revisar la licencia de cada modelo (puede haber restricciones).
- Si es producción, revisar requisitos de hardware, escalabilidad, etc.

2. H2O.ai (plataforma “H2O Open Source”)



H2O.ai

H2O AutoML
Wave UI for H2O-3 AutoML

Home Import Data Train **Leaderboard** AutoML Viz Model Explain

Documentation Dark Mode Off

AutoML Leaderboard
 Test Data size (rows): 100
 Target: default payment next month
 Task Type: Binary classification
 Select a model to download the MOJO

Search

model_id	auc	logloss	aucpr	mean_per_class	rmse	mse
XRT_1_AutoML_1_20230411_194740	0.99064	0.26098	0.87554	0.05198	0.26464	0.07003
StackedEnsemble_BestOfFamily_1_AutoML_1_20230411_194740	0.95634	0.34024	0.88351	0.09927	0.32102	0.10305
GBM_5_AutoML_1_20230411_194740	0.94802	0.34357	0.85592	0.10603	0.32432	0.10518
StackedEnsemble_AllModels_1_AutoML_1_20230411_194740	0.9262	0.36804	0.81853	0.17516	0.33827	0.11443
XGBoost_2_AutoML_1_20230411_194740	0.91944	0.33432	0.87285	0.12994	0.31417	0.09871

10 of 10 Download data

Made with H2O Wave

Qué es: Plataforma de machine learning distribuido, de código abierto, que permite escalar y aplicar tanto algoritmos estadísticos como de aprendizaje profundo. h2o.ai+1


Por qué utilizarla:


- Buena para aplicaciones de ML/IA donde hay datos propios para construir modelos.
- Soporta “AutoML” (automatización del proceso de selección de modelos, hiperparámetros, etc.).

Cosas a tener en cuenta:

- Aun siendo “open source”, se necesita infraestructura adecuada (máquinas, memoria, etc).
- Puede ser que la comunidad/tutoría en español sea más limitada que en inglés.

3. LangChain (y similares marcos de agentes)





Qué es: Un marco de trabajo de código abierto para construir “agentes” de IA, es decir, sistemas que pueden usar modelos de lenguaje + herramientas + razonamiento para hacer tareas más complejas. [bu-dibase.com+1](https://github.com/laughedelic/open-swe)

Por qué utilizarla:

- Si quieres ir más allá de “solo modelo que genera texto”, y construir un sistema que “razone”, que haga flujos, que llame a APIs, etc.
- Muy útil para chatbots avanzados, asistentes inteligentes, sistemas de búsqueda con IA (RAG: Retrieval-Augmented Generation).

Cosas a tener en cuenta:

- Requiere más conocimiento técnico que simplemente usar un modelo “ya entrenado”.
- La infraestructura de despliegue puede complicarse (orquestración, herramientas auxiliares, mantenimiento).

4. TensorFlow / PyTorch (plataformas base de IA)

```
import tensorflow_cloud as tfc

tfc.run(
    requirements_txt="requirements.txt",
    chief_config=tfc.MachineConfig(
        cpu_cores=8,
        memory=30,
        accelerator_type=tfc.AcceleratorType.NVIDIA_TESLA_T4,
        accelerator_count=2,
    ),
    docker_image_bucket_name=GCP_BUCKET,
)
```

index.html ✕

```
1 <!DOCTYPE html>
2 <html>
3   <head>
4     <script src="https://cdn.jsdelivr.net/npm/@tensorflow/tfjs/dist/tf.min.js"> </script>
5   </head>
6   <body>
7     <p id="prediction">Prediction(100): </p>
8     <script>
9       async function run(){
10        const model=tf.sequential();
11        model.add(
12          tf.layers.dense({
13            units: 10,
14            activation: 'tanh',
15            kernel_initializer: 'glorot_uniform',
16          });
17        );
18      };
19      model.compile({
20        loss: 'meanSquaredError',
21        optimizer: 'sgd',
22        metrics: ['mse']
23      });
24
25      const xs = tf.tensor1d([1, 2, 3, 4, 5, 6, 7, 8, 9, 10]);
26      const ys = tf.tensor1d([2, 5, 8, 12, 14, 18, 21, 23, 26, 29]);
27
28      await model.fit(xs, ys, {epochs:100});
29      document.getElementById('prediction').innerText+=
30      model.predict(tf.tensor1d([100])).dataSync();
31    </script>
32   </body>
33 </html>
```



TensorFlow

PyTorch training loop

The diagram illustrates the PyTorch training loop with a code snippet and corresponding annotations:

```

# Pass the data through the model for a number of epochs (e.g. 100)
for epoch in range(epochs):
    # Put model in training mode (this is the default state of a model)
    model.train()
    # 1. Forward pass on train data using the forward() method inside
    y_pred = model(X_train)
    # 2. Calculate the loss (how different are the model's predictions to the true values)
    loss = loss_fn(y_pred, y_true)
    # 3. Zero the gradients of the optimizer (they accumulate by default)
    optimizer.zero_grad()
    # 4. Perform backpropagation on the loss
    loss.backward()
    # 5. Progress/step the optimizer (gradient descent)
    optimizer.step()
    
```

Annotations:

- Pass the data through the model for a number of epochs** (e.g. 100 for 100 passes of the data)
- Pass the data through the model, this will perform the `forward()` method located within the model object**
- Calculate the loss value** (how wrong the model's predictions are)
- Zero the optimizer gradients** (they accumulate every epoch, zero them to start fresh each forward pass)
- Perform backpropagation on the loss function** (compute the gradient of every parameter with `requires_grad=True`)
- Step the optimizer** to update the model's parameters with respect to the gradients calculated by `loss.backward()`


Note: all of this can be turned into a function



Qué son: Bibliotecas (frameworks) de aprendizaje automático / profundo ampliamente utilizadas, completamente de código abierto. Built In+1

Por qué utilizarlas:

- Dan control completo sobre el diseño del modelo, entrenamiento, personalización.
 - Amplia comunidad, muchísimos ejemplos, soporte para investigación como para producción.
- Cosas a tener en cuenta:**
- Curva de aprendizaje más alta que usar “modelos ya hechos”.
 - En producción, hay que pensar en escalabilidad, optimización, hardware.

5. OpenAI Gym (entorno para Reinforcement Learning open-source)





Qué es: Un entorno de código abierto para experimentar con aprendizaje por refuerzo (reinforcement learning) y agentes. KDnuggets



Por qué utilizarlo:

- Si el tipo de IA por el que se interesa es “agente que aprende por interacción” → RL.
- Buen punto de partida para prototipos de IA avanzada.

Cosas a tener en cuenta:

- Requiere bastante conocimiento sobre RL, exploración/acción/entorno.
- Puede necesitar muchos recursos de cómputo para entrenamientos complejos.

6. Jan (app open-source alternativa a ChatGPT)



Qué es: Una app de código abierto para “chat con IA”, que se puede ejecutar localmente y que está orientada a la privacidad y al uso personal o desarrollos propios. jan.ai

Por qué utilizarla:

- Buena opción si se quiere “algo que ya funciona” y modificarlo o desplegarlo localmente.
- Menos barrera de entrada que construir todo desde 0.

Cosas a tener en cuenta:

- Puede no estar tan optimizado para uso empresarial/producción como otras plataformas especializadas.
- Verificar licencia y posibles restricciones si se usa comercialmente.


Consejos para elegir la plataforma adecuada



- Defina su **caso de uso**: ¿Procesamiento de texto? ¿Visión por computador? ¿Agentes inteligentes?
- Verifique la **licencia**: “Open source” no siempre significa “sin restricciones comerciales”.
- Evalúe su **infraestructura/hardware**: Algunos modelos requieren GPUs, memoria, etc.
- Considere **soporte y comunidad**: Cuanto más popular, más recursos/tutoriales disponibles.
- Piense en la **producción**: Algunas herramientas son excelentes para prototipos, pero pasar a producción puede requerir más trabajo (escalabilidad, mantenimiento, seguridad).

Lista de portales con código abierto para poder trabajar con IA en medicina

A continuación, se presenta una **lista seleccionada** de portales y plataformas de código abierto, muy útiles para trabajar con IA en el ámbito de la medicina. Para cada uno se incluye qué ofrecen, el porqué pueden ser interesantes, y algunas notas de implementación.

1. MONAI (Medical Open Network for AI)





Qué es: Un marco abierto para IA en imágenes médicas, basado en PyTorch, con licencia Apache 2.0. monai.io


Por qué es útil en medicina:

- Incluye transformaciones específicas para imágenes médicas, modelos pre-entrenados (“model zoo”), herramientas para anotación de imágenes, etc. monai.io
- Abarca todo el ciclo: desde la anotación/etiquetado, hasta entrenamiento y despliegue clínico.

Notas / tips:

- Ideal si se trabaja con imágenes médicas (TC, RM, etc.).
- Verificar compatibilidad de datos (DICOM, FHIR) y normativa local para uso clínico.

2. Project InnerEye



Qué es: Conjunto de herramientas open source bajo licencia MIT para IA en imágenes médicas, desarrollado por Microsoft Research. Microsoft

Por qué es útil:

- Facilita construcción de modelos de segmentación, clasificación en imágenes médicas.
- Buena base para investigación clínica o prototipos.

Notas:

- Puede requerir infraestructuras de GPU para entrenamiento a escala.
- Asegurar que los datos usados cumplan con privacidad/ética.

3. OpenMEDLab

[cs.CV] 4 Mar 2024

OpenMEDLab: An Open-source Platform for Multi-modality Foundation Models in Medicine

Xiaosong Wang¹, Xiaofan Zhang^{1,2}, Guotai Wang³, Junjun He¹, Zhongyu Li⁴, Wentao Zhu⁵, Yi Guo⁷, Qi Dou⁶, Xiaoxiao Li⁹, Dequan Wang^{1,2}, Liang Hong², Qicheng Lao⁸, Tong Ruan¹⁰, Yukun Zhou¹¹, Yixue Li¹², Jie Zhao¹³, Kang Li^{1,14}, Xin Sun¹⁵, Lifeng Zhu¹⁶, and Shaoting Zhang^{6a,1}

¹Shanghai AI Laboratory, China
²Shanghai Jiao Tong University, China
³University of Electronic Science and Technology of China, China
⁴Xi'an Jiaotong University, China
⁵Zhejiang Laboratory, China
⁶Chinese University of Hong Kong, China
⁷Fudan University, China
⁸Beijing University of Posts and Telecommunications, China
⁹University of British Columbia, Canada
¹⁰East China University Of Science And Technology, China
¹¹University College London, UK
¹²Guangzhou Laboratory, China
¹³The First Affiliated Hospital of Zhengzhou University, China
¹⁴West China Hospital, Sichuan University, China
¹⁵Yinshan Hospital, Shanghai Jiao Tong University School of Medicine, China
¹⁶Shanghai Jiao Tong University School of Medicine, China

Medical Data	Medical AI Models	Application
Images data: CT, MRI, X-rays... Text data: Patient and intervention records, Physical examination Experimental data: Cellular, animal, and clinical experiments Medical knowledge: Anatomy, pathology, pharmacology...	Disease-Specific Medical AI Foundation Models RETFound, Neuro-Oph GPT, UNI, Virchow General-Domain Models ChatGPT, Med-PaLM, MedSAM, SAM-Med2D, MedLSAM Multi-Modal Models PathChat, PLIP, OpenMEDLab, IRENE	Disease diagnosis and prognosis prediction Biomarker screening and molecular subtyping Medical image segmentation, diagnoses and report generation Medical question answering Doctors ↔ Patients

Qué es: Plataforma open-source que permite trabajar con “foundation models” médicos multi-modalidad (imágenes, NLP, bioinformática). GitHub


Por qué vale la pena:


- Aborda no sólo imagen, sino también texto médico, proteínas, etc.
- Fomenta soluciones para “problemas de cola larga” en medicina.

Notas:

- Aún en desarrollo/crecimiento: buena para investigación más que despliegue inmediato en producción.
- Requiere buen conocimiento técnico para customizar.

4. 3D Slicer





Qué es: Plataforma abierta para análisis y visualización de imágenes médicas, con licencia BSD-style. Wikipedia


Por qué utilizarla:

- Muy buena para visualización, segmentación y procesamiento de imágenes médicas en investigación.
- Permite integración de módulos personalizados, y es multiplataforma.


Notas:

- Aunque es open-source, no está certificada como producto clínico (según Wikipedia). Wikipedia
- Más orientada a investigación/biomedicina que a uso clínico directo.

5. Weasis



WEASIS
medical viewer



Qué es: Visor de imágenes médicas (DICOM) open-source, bajo licencias como Apache 2.0 o Eclipse 2.0. Wikipedia


Por qué puede interesar:


- Buena herramienta cuando necesitas visualizar imágenes médicas, integrarlas con flujos de trabajo de IA.
- Permite exploración/visualización previa al análisis en IA.

Notas:

- Es más un componente de visualización; si lo que buscas es construir modelos IA completos, tendrás que complementarlo con otros frameworks.

6. MAIA (Medical Artificial Intelligence Assistant)





Qué es: Plataforma open-source reciente para colaboración entre clínicos, investigadores y desarrolladores de IA, modular, escalable. arXiv

Por qué es prometedora:

- Diseñada para integración real en entornos clínicos (datos, modelo, feedback) y despliegue escalable.
- Muy adecuada para proyectos que atraviesan el “laboratorio → clínica”.

Notas:

- Puede requerir infraestructura (Kubernetes, etc).
- Aún bastante nueva, revisa su adopción, comunidad, soporte.

7. GNUHealth

GNU Health - Administrator - GNU SOLIDARIO HOSPITAL [EUR]

3 / 6

Patient Parties

Patient

Main Info

Ana Betz Female -> Male Age: 34y 4m 0d

Critical Information

Z88.0 : Personal history of allergy to penicillin
 E10 : Type 1 diabetes mellitus
 A90 : Dengue fever [classical dengue]
 A40 : Streptococcal sepsis
 Z31.2 : In vitro fertilization

Severe allergic reactions to β -lactams.

Disabilities / Barriers:

General Info Functioning and Disability Surgeries Socioeconomics Lifestyle OB/GYN Genetics Medication

Main Misc

GP: Cordara, Cameron Family: Zenon-Betz Single Insurance: Insurador : 938291

Condition	Status	Ad	In	Severity	At	Pr	Date of Diagn	Healed	Remarks	Institution
Z88.0 : Personal history of allergy to pen	unchanged			Severe			01/07/1991			
E10 : Type 1 diabetes mellitus	chronic			Moderate			11/10/1993			
A90 : Dengue fever [classical dengue]	acute									
A40 : Streptococcal sepsis										
Z31.2 : In vitro fertilization										


Notepad

DoB: 10/04/1985 PUID: GNU777ORG777 Blood type: A Hospitalized: Hb: AA Active:



GNUHealth

The Free / Libre Hospital and Health Information System



Qué es: Sistema de información hospitalaria/libre para salud pública, expediente clínico, laboratorio, etc. Licencia GPL. Wikipedia

Por qué aparece en la lista:

- Aunque no es “IA pura”, es una plataforma open-source robusta del ecosistema salud que puede integrarse con módulos de IA.
- Buena base para gestionar datos clínicos que luego alimenten modelos IA.

Notas:

- Si tu foco está en IA, verás que aquí tienes que añadir capas de análisis/modelado.
- Verifica compatibilidad con normativas de privacidad (GDPR, etc).

Consejos para elegir y usar estas plataformas

- **Definir primero el «caso de uso clínico»:** imagen médica, texto clínico (NLP), sistema de apoyo al diagnóstico, gestión de datos, etc.
- **Revisar la licencia:** Aunque sean “open source”, hay diferencias según uso académico/industrial.
- **Privacidad y datos:** En medicina los datos son muy sensibles. Si usas modelos open-source, asegúrate de tener cumplimiento legal (GDPR, HIPAA, etc) y que los datos estén debidamente anonimizados o seguros.
- **Validación clínica / regulatoria:** Muchos frameworks son para investigación. Si se pretende su uso en producción clínica, revise necesidad de certificación, validación, workflow clínico.
- **Infraestructura técnica:** GPU, almacenamiento, pipelines de anotación, gestión de datos médicos (DICOM, HL7, FHIR) son consideraciones importantes.
- **Comunidad y soporte:** Una herramienta open-source con buena comunidad facilitará la implementación.
- **Escalabilidad y mantenimiento:** Desde prototipo a producción hay muchos retos: actualización de datos, sesgo, monitorización del modelo, explicabilidad, etc.

A.3. Recursos para la formación en ia para profesionales de la salud

Recursos para la formación en Inteligencia Artificial para profesionales de la salud

La incorporación de la IA en la práctica clínica requiere que los profesionales de la salud adquieran **competencias digitales básicas** y una **comprensión aplicada** de los modelos y herramientas.

Existen numerosos recursos -gratuitos y abiertos- diseñados específicamente para médicos, residentes e investigadores clínicos.

1. Cursos introductorios gratuitos y accesibles

Curso / Plataforma	Descripción	Idioma	Nivel
Elements of AI (elementsofai.com)	Curso gratuito de la Univ. de Helsinki, con una versión específica para salud. Ideal para no programadores.	ES GB	Básico
AI for Medicine Specialization (Coursera)	Serie de 3 cursos de Andrew Ng: diagnóstico por imagen, predicción de supervivencia y procesamiento de texto clínico.	GB (con subtítulos ES)	Intermedio
Machine Learning for Healthcare (MIT OpenCourseWare)	Curso del MIT enfocado en aplicaciones clínicas y éticas de la IA.	GB	Avanzado
DeepLearning.AI: Generative AI for Healthcare	Curso breve sobre IA generativa aplicada a medicina, disponible en Coursera.	GB	Intermedio
Stanford AI in Healthcare Bootcamp (edX)	Formación centrada en cómo integrar IA en la práctica médica.	GB	Intermedio-Avanzado
Curso de IA en Salud (OPS/OMS)	Formación gratuita y acreditada orientada a políticas sanitarias y ética de la IA.	ES	Básico-Intermedio

💡 *Sugerencia:* combinar un curso teórico general (*Elements of AI*) con uno aplicado (*AI for Medicine*) para obtener visión y práctica.

2. Plataformas de práctica y experimentación con IA médica

Plataforma	Enfoque	Qué puedes hacer
Kaggle	Ciencia de datos aplicada	Acceso a datasets médicos públicos (p. ej. radiografías, ECG) y notebooks de ejemplo.
Hugging Face	Modelos preentrenados abiertos	Probar modelos de lenguaje biomédico o segmentación de imágenes médicas.
Google Colab	Laboratorio en la nube	Ejecutar código Python y entrenar modelos IA sin necesidad de instalación local.
MONAI Lab / MONAI Tutorials	Imagen médica con IA	Entornos demostrativos y datasets para aprender segmentación médica.
PhysioNet	Bases de datos fisiológicas abiertas	ECG, signos vitales, datos de UCI para proyectos de predicción clínica.

3. Materiales educativos, libros y guías recomendadas

Recurso	Autor / Fuente	Comentario
“Artificial Intelligence in Healthcare”	Adam B. Cohen et al.	Manual práctico sobre aplicaciones, ética y futuro de la IA médica.
“Deep Medicine”	Eric Topol	Ensayo de divulgación que explora cómo la IA puede humanizar la medicina.
“Python for Health Data Science”	Edward Chin	Guía práctica de análisis clínico con Python.
Guía de IA en salud de la OMS (2023)	Organización Mundial de la Salud	Marco ético y regulatorio para la IA médica.
Informe “AI and the Future of Clinical Practice”	The Lancet Digital Health	Revisión actualizada de tendencias y desafíos.

4. Comunidades y proyectos colaborativos open-source

Comunidad	Descripción	Cómo participar
MONAI Community	Grupo activo de desarrolladores e investigadores en imagen médica.	Publicar notebooks o tutoriales.
Nightingale Open Science	Repositorio de datos de salud anonimizados.	Participar en proyectos de predicción de riesgo.
OHDSI (Open Health Data Science Initiative)	Comunidad global sobre análisis de datos clínicos OMOP.	Contribuir con modelos o validaciones.
BioMedIA Community	Red académica centrada en IA y radiología.	Asistir a workshops y retos científicos.

5. Programas de posgrado y certificaciones relevantes

Institución	Programa	Modalidad
Universidad de Stanford	“AI in Healthcare Certificate”	Online / Inglés
Universidad de Oxford	“AI for Healthcare and Clinical Data Science”	Online / Inglés
Universidad de Barcelona / UBx	“IA aplicada a la salud y biomedicina”	Español / Online
Harvard T.H. Chan School of Public Health	“Data Science and Artificial Intelligence for Health”	Online / Inglés
ESADE Health Institute	“Transformación Digital e IA en Salud”	Híbrido / Español

6. Ruta sugerida de formación progresiva

Etapa	Objetivo	Recurso recomendado
1. Introducción conceptual	Comprender qué es la IA y su impacto ético	<i>Elements of AI</i> , OMS
2. Fundamentos técnicos	Adquirir nociones básicas de programación y modelos	<i>AI for Medicine</i> , Google Colab
3. Aplicación clínica	Identificar casos de uso en tu especialidad	<i>MONAI Tutorials</i> , <i>PhysioNet</i>
4. Validación y ética	Evaluar sesgos y fiabilidad de modelos	<i>OMS 2023 Guidelines</i> , <i>The Lancet Digital Health</i>
5. Implementación hospitalaria	Integrar IA en sistemas reales (FHIR, PACS)	Cursos MIT / Stanford / UBx

7. Consejos finales para profesionales de la salud

1. **Empezar por lo esencial:** entender los conceptos, no el código.
2. **Aprender de forma aplicada:** usar datasets médicos reales (anonimizados).
3. **Colaborar con ingenieros o científicos de datos.**
4. **Evaluar siempre la ética y la validez clínica.**
5. **Compartir los aprendizajes:** crear comunidades en tu hospital o servicio.

Se debe ser conscientes que el contenido y estrategia de la formación sobre los profesionales de la salud, dependerá del tipo de responsabilidades inherentes a su lugar de trabajo

Existen una serie de **recursos muy útiles** para el profesional de la salud que quiera formarse en inteligencia artificial (IA) aplicada al ámbito sanitario: van desde lecturas clave, guías, cursos hasta artículos de contexto.

Por qué es importante formarse en IA sanitaria

- La IA ya se está introduciendo en la educación médica: por ejemplo, generando cuestionarios, simulando pacientes virtuales, identificando áreas de dificultad en estudiantes. AAMC+1
- Sin embargo, existe un déficit de formación específica en IA para el ámbito sanitario, lo que dificulta la adopción eficaz de estas tecnologías. PMC
- Para profesionales de salud: entender la IA no solo como “herramienta” sino también sus implicaciones éticas, de seguridad del paciente, de privacidad, de sesgo. MGH Institute of Health Professions+1

Por todo ello, formarse permite: mejorar la colaboración con equipos de datos/IA, tomar decisiones informadas sobre la implementación clínica, garantizar calidad, seguridad y efectividad.

Recursos recomendados

Se proponen varias categorías de recursos con enlaces, para que el alumno pueda elegir según tu tiempo, interés o nivel.

1. Guías y colecciones de recursos

- AAMC – “Advancing AI Across Academic Medicine Resource Collection”: colección práctica de recursos para integrar IA en la educación médica: cómo diseñar el currículo, ética, etc. AAMC
- NYU Langone Health – Guía “AI in Healthcare” que cubre introducción a IA, herramientas, tutoriales, consideraciones de autoría, tendencias. hslguides.med.nyu.edu
- UCLA Health – Recurso de “AI Best Practices in Health Care”: buen compendio de qué hacer/evitar, concienciación para profesionales de salud. UCLA Health

2. Lecturas académicas / artículos clave

- “Artificial Intelligence Education Programs for Health Care” – revisa el estado del arte, deficiencias, lo que se necesita. PMC
- “Mapping the use of artificial intelligence in medical education” – revisión que analiza cómo se está integrando la IA en la educación médica de grado, qué obstáculos hay. BioMed Central
- “Artificial Intelligence Revolutionizing the Field of Medical Education” – analiza cómo la IA puede ayudar en la formación de profesionales de salud (tutores inteligentes, pacientes virtuales, etc). PMC

3. Herramientas prácticas / listas de IA para salud

- Artículo “10 Top AI Tools in Healthcare for 2025” – muy útil para familiarizarse con herramientas concretas (chatbots, análisis de datos clínicos, etc) y ver los retos (privacidad, cumplimiento, etc) TechTarget
- “AI Tools for Medical Education and Research” – lista categorizada de herramientas de IA aplicadas a educación e investigación médica. evms.edu

4. Formación orientada a profesionales de salud

- Cursos online / programas mencionados en blogs como “AI in Healthcare Courses: Our 8 Best Choices for 2024” – ideal para ver opciones estructuradas. keragon.com
- Seminario web de la AAMC “AI Skill Building for Medical Educators” – enfocado a educadores médicos que quieren usar la IA para diseñar currículos, evaluar, ver el impacto. AAMC

Cómo aprovechar estos recursos según el perfil del alumno

Aquí algunas sugerencias de enfoque:

- Si es un **clínico sin formación en IA**: empiece por las guías básicas (NYU, UCLA), luego lea artículos de contexto (por qué, para qué). Por ejemplo, entender qué herramientas ya existen y qué implicaciones tienen.
- Si es **educador o formador** en salud: enfóquese en recursos de currículo – cómo integrar la IA en la enseñanza, qué competencias desarrollar. (ver AAMC, seminarios web).
- Si es un responsable en **gestión o implementación institucional**: pase a herramientas + mejores prácticas + implicaciones éticas/seguridad (artículos y listas de herramientas).
- Sea cual sea tu nivel, siempre tenga presente los **aspectos críticos**: ética, sesgo, privacidad de datos, usabilidad clínica, regulación. (ver artículos sobre barreras)

Aquí se sugieren una **selección de cursos y programas en español** (o con opción en español) orientados a profesionales del ámbito sanitario que quieren formarse en IA aplicada a salud. Le indico qué ofrece cada uno, para que pueda valorar cuál se ajusta a sus necesidades y disponibilidad.

1. Máster en Inteligencia Artificial en Salud – Universidad Europea de Madrid

- 100 % online, en español. Universidad Europea
- 10 meses de duración, 60 ECTS. Universidad Europea
- Dirigido a quienes quieren dominar la IA (Machine Learning, Deep Learning) aplicada a salud: diagnóstico por imagen, procesamiento del lenguaje, IoT en salud, etc. Universidad Europea
- Buena opción si buscas una titulación “completa” a nivel máster universitario.

2. Máster en Inteligencia Artificial Aplicado a la Medicina – AICAD Business School

- Máster “oficial” centrado en IA para medicina. Aicad Business School
- Enfocado a adquirir competencias para liderar proyectos en salud con IA: diagnóstico, tratamiento, personalización, etc. Aicad Business School
- Ideal si ya tienes experiencia en salud y quieres dar el salto al liderazgo o implementación de IA clínica.

3. Curso de Especialista en Inteligencia Artificial para la Salud – UCJC – Universidad Camilo José Cela

- Curso de formación permanente, duración de 150 horas (6 ECTS). UCJC Madrid
- Online, con enfoque en IA + Big Data + interoperabilidad en ámbito sanitario. UCJC Madrid
- Buena opción si tienes un perfil sanitario y quieres formarte sin dedicarte a un máster completo.

4. Curso de Inteligencia Artificial en Salud – Postgrado – Grupo CTO

- Curso diseñado específicamente para profesionales sanitarios que buscan integrar IA generativa en su práctica diaria. Grupo CTO
- Online, duración aproximada de 4 meses, con acreditación ECTS. Grupo CTO
- Ideal para introducirse en IA generativa, herramientas tipo ChatGPT aplicadas a salud.

5. Curso de Salud Digital: Big Data, IA y Ciberseguridad – Deusto Salud

- Curso online que aborda IA, Big Data y ciberseguridad en salud. Deusto Salud
- Más enfocado en la gestión de datos sanitarios, acompañando el tema de IA.
- Buena opción si tu papel es más de gestión, dirección de servicios, análisis de datos sanitarios.

Consejos para elegir

- Nivel de implicación / duración: Si puede dedicar tiempo prolongado, un máster completo (opciones 1 y 2) le dará una formación muy sólida. Si dispone de menos tiempo, los cursos más cortos (opciones 3, 4, 5) pueden bastar para dar el “salto inicial”.
- Perfil profesional:
 - Si es clínico/a y quiere mejorar la práctica con IA → cursos prácticos (4) o (3).
 - Si está en gestión, dirección o análisis de datos sanitarios → curso (5).
 - Si quiere liderar proyectos de IA en salud → máster (1) o (2).
- **Idioma y modalidad:** Todos los cursos están en español o con opción en español. Pueden ser 100 % online, lo cual facilita compatibilizar con trabajo en salud.
- **Coste y acreditación:** Verificar acreditación (ECTS, titulación universitaria), técnicas de enseñanza (¿clases en directo?, ¿casos prácticos?), coste y posibles bonificaciones.
- **Contenido concreto:** Verificar que incluyan: fundamentos de IA, Machine Learning/Deep Learning, ética & privacidad de datos en salud, aplicaciones clínicas, gestión de datos sanitarios, casos reales. Los cursos anteriores lo contemplan (ver los enlaces).

Si le parece bien, le presento **un listado más amplio, actualizados a 2025-2026**, con filtros: **gratuitos / costo reducido**, modalidad **español**, nivel **introductorio, intermedio y avanzado**, con fechas de inicio y precios.

Aquí tiene un **listado ampliado** de cursos, tanto gratuitos como de pago, en español (o con opción en español) y/o orientados al ámbito sanitario, para profesionales de la salud que quieran formarse en IA. He señalado nivel, idioma, modalidad, y enlace cuando está disponible. Es recomendable revisar fechas y condiciones de cada uno porque pueden variar.

Nº	Curso	Nivel / modalidad	Idioma	Comentarios
1	Bases de la Inteligencia Artificial aplicadas a sanidad (Universidad de Navarra)	Formación permanente para sanitarios	Español	Curso diseñado para profesionales sanitarios del Servicio Madrileño de Salud (SERMAS) que desean conocer retos y oportunidades de la IA en sanidad. Universidad de Navarra
2	Curso de Inteligencia Artificial Generativa para el Ámbito Sanitario (Grupo CTO)	Corto (≈ 4 meses)	Español	Orientado a profesionales sanitarios con enfoque de IA generativa, online. Grupo CTO
3	Curso de Formación Permanente en Inteligencia Artificial para la Salud (Universidad Camilo José Cela – UCJC)	150 horas (≈ 6 ECTS)	Español	Cubre fundamentos, big data, interoperabilidad en ámbito sanitario. UCJC Madrid
4	Curso en Inteligencia Artificial en Salud (Universitat Autònoma de Barcelona – UAB)	Curso de introducción	Español	Curso que introduce a IA y ciencia de datos en salud, con conceptos de calidad, procedimiento, ética. UAB Barcelona
5	Diplomado Internacional en Inteligencia Artificial Aplicada a la Salud	12 semanas	Español (latino)	Modalidad online-híbrido, para familiarizarse con IA aplicada al ámbito salud. he-tins.com
6	Inteligencia Artificial para la Salud: Fundamentos y Aplicaciones	Nivel medio	Español	Programa que aborda IA, procesamiento del lenguaje natural (PLN) y casos de uso en salud. Educación Continua
7	Máster en Inteligencia Artificial en Salud (Universidad Europea de Madrid)	Máster online, 60 ECTS	Español	Formación completa para liderar proyectos de IA en salud; aborda desde fundamentos a visión por ordenador, IoT sanitario. Universidad Europea
8	Máster en Inteligencia Artificial y Big Data en Salud (I3PT Parc Taulí)	Máster 2 años	Español	Formación muy completa, duración mayor, con 60 ECTS para especialización avanzada. tauli.cat
9	AI in Healthcare (FutureLearn / University of Manchester)	Curso online MOOC	Inglés (verificar subtítulos)	Aunque no está completamente en español, es de alto nivel e interesante para ampliar perspectiva global. FutureLearn
10	Generative AI for Healthcare (Google Cloud Skills Boost)	Curso gratuito	Inglés (verificar idioma)	Enfocado en IA generativa y modelos de lenguaje para salud. Muy útil para aplicarlo como profesional. Google Cloud Skills Boost

Recomendaciones según su objetivo y perfil

- Si se quiere **una introducción rápida** y sin mucho compromiso: cursos como el “Diplomado...” (5) o el “Curso de Formación Permanente...” (3) son buenos puntos de partida.
- Si ya se tiene un poco de conocimiento y se quiere **aplicar IA en su práctica sanitaria**.
- Si se desea **liderar proyectos de IA en salud** o cambiar su rol hacia dirección/implementación tecnológica: los másters (7, 8) son más adecuados.
- Si le interesa la **IA generativa** específicamente (modelos de lenguaje, ChatGPT, etc) en salud: el curso 2 y 10 son clave.

Otra fuente de información para los alumnos y los médicos en su fase formativa, la pueden encontrar en las revistas de prestigio como por ejemplo el The Lancet. ***The Lancet Digital Health*** es una de las revistas científicas más influyentes dedicadas a la aplicación de las tecnologías digitales en la salud, con un enfoque muy riguroso en inteligencia artificial, ciencia de datos y medicina digital.

Qué es *The Lancet Digital Health*

- **Editorial:** parte del grupo *The Lancet*, una de las editoriales médicas más prestigiosas del mundo.
- **Fundada:** en 2019.
- **Enfoque:** publicación revisada por pares dedicada a la investigación y el debate sobre salud digital, IA médica, análisis de datos clínicos y políticas de innovación tecnológica en salud.
- **Sitio web:** [thelancet.com/journals/landig](https://www.thelancet.com/journals/landig)

Temas principales

1. **Inteligencia artificial y machine learning** en diagnóstico, pronóstico y apoyo a la decisión clínica.
2. **Análisis de big data sanitario** y uso de registros electrónicos de salud (EHR).
3. **Medicina personalizada y predictiva.**
4. **Evaluación ética, regulatoria y de sesgos en IA.**
5. **Telemedicina, wearables y salud móvil.**
6. **Ciberseguridad, privacidad y gobernanza de datos clínicos.**

Tipos de publicaciones

- Artículos originales de investigación.
- Revisiones sistemáticas y metaanálisis.
- Comentarios y perspectivas sobre IA, ética y política sanitaria.
- Cartas y debates sobre la implementación clínica de IA.

Ejemplos de artículos destacados

- “Regulatory frameworks for clinical AI models: global perspectives”
- “Bias in medical AI: current evidence and mitigation strategies”
- “AI in obstetrics: opportunities and limitations in fetal imaging”
- “Data sharing in health research: towards equitable digital ecosystems”

Por qué es útil para profesionales de la salud

- Es **fuentes de evidencia científica actualizada** sobre el uso responsable de IA.
- Permite seguir la evolución de las **guías éticas y regulatorias internacionales**.
- Ofrece ejemplos de **validación clínica real** de modelos de IA.
- Ideal para **docencia, investigación y diseño de proyectos** de IA hospitalaria.

Estudios relevantes en revistas relacionadas que pueden ser de interés, y también algunos artículos de la revista que tocan el tema más ampliamente. A continuación, se resume lo más relevante.

Estudios relacionados relevantes

“Artificial intelligence-enabled prenatal ultrasound for the detection of ...”

Se publicó en otra revista (no exactamente The Lancet Digital Health) sobre la aplicación de IA en ecografía prenatal. The Lancet

- Enfoque: usar IA en ecografía prenatal para detección de anomalías fetales.
- Relevancia para OB/GYN: demuestra progreso en imagenología obstétrica.
- Limitaciones: no aparece (al menos accesible desde los resultados revisados) que sea un estudio publicado *dentro* de The Lancet Digital Health, por lo que requiere verificación adicional.

“Clinical Prospects for Artificial Intelligence in Obstetrics and Gynecology”

Revisión publicada en otra plataforma, aborda IA en obstetricia/ginecología de forma general. jmaj.jp

- Contenido: utiliza deep learning para imágenes, ultrasonidos, placenta, cáncer ginecológico.
- No específico de The Lancet Digital Health, pero útil para contexto.

Artículos de The Lancet Digital Health sobre IA médica general

Por ejemplo: “Medical digital twins: enabling precision medicine and ...” publicado en The Lancet Digital Health. The Lancet

- Aunque no centrado en OB/GYN, aborda la IA multimodal en salud.
- Otro: “Artificial intelligence-guided detection of under-recognised cardiomyopathies...” (Ultrasonografía cardíaca) en The Lancet Digital Health. The Lancet
- Estos muestran que la revista sí publica estudios de IA aplicada en salud, lo que aumenta la posibilidad de que en el futuro haya más en obstetricia y ginecología.

Consideraciones y limitaciones

- Puede que existan artículos en OB/GYN + IA **pero no indexados claramente** o con terminología no tan obvia (por ejemplo “fetal imaging”, “placenta MRI”, “ultrasound obstetrics” etc.).
- Es posible que algunos estudios estén *en prensa* (“online first”) o *bajo revisión* en The Lancet Digital Health.
- La integración clínica de IA en OB/GYN aún parece estar en fases más tempranas comparadas con otras áreas (radiología, cardiología), lo que puede explicar menor volumen de publicaciones específicas.

¿Qué podemos hacer a continuación?

- Realizar una **búsqueda exhaustiva avanzada** (por ejemplo en bases de datos como PubMed, Embase) filtrando por revista *The Lancet Digital Health* + obstetricia/ginecología + IA, para ver si encontramos artículos muy recientes o “online first”.
- Si lo prefieres, **ampliar la búsqueda** a otras revistas de alto impacto (ej. *npj Digital Medicine*, *JAMA Network Open*, *Ultrasound in Obstetrics & Gynecology*) que tengan artículos OB/GYN + IA, y elaborar una lista con los mejores estudios de los últimos dos años.

Aquí se propone una **lista de publicaciones de *The Lancet Digital Health* de los últimos 2 años** (desde octubre de 2023 hasta el presente) relevantes para **IA y salud de la mujer/OB-GYN**. A continuación se incluye un tipo de artículo y una nota clínica rápida.

1. **PIERS-ML para preeclampsia (riesgo materno inmediato)** — *Original research*, 2024.
“Machine learning-enabled maternal risk assessment for pre-eclampsia.” Mejora la estratificación de riesgo de eventos adversos maternos en 48 h. *The Lancet*
2. **Gemelos digitales del embarazo** — *Comment/Viewpoint*, 2024.
“Virtual pregnancies: predicting and preventing pregnancy complications with digital twins.” Explora cómo gemelos digitales podrían anticipar complicaciones obstétricas. *The Lancet*
3. **Infección materno-fetal y neonatal** — *Viewpoint*, 2024.
“Advancing the management of maternal, fetal, and neonatal infection through harnessing digital health innovations.” Uso de IA y salud digital para mejorar cribado/seguimiento. *The Lancet*
4. **Cáncer de ovario con analítica de laboratorio + IA** — *Original research*, 2024.
“Artificial-intelligence-based models enabling accurate diagnosis of ovarian cancer using laboratory tests.” Modelos multivariados con rendimiento diagnóstico alto en cohortes multicéntricas. *The Lancet*
5. **Salud de la mujer y tecnologías digitales** — *Review/Comment*, 2025.
“Transforming women's health, empowerment, and gender equity through digital health technologies.” Marco general de impacto y oportunidades (incluye OB-GYN). *The Lancet*
6. **Control prenatal con telemedicina integrada** — *Original research*, 2023.
“Effect of telehealth-integrated antenatal care on pregnancy outcomes.” Evidencia sobre seguridad, efectividad y satisfacción; base para circuitos obstétricos híbridos. *The Lancet*
7. **Cáncer de endometrio: clasificación molecular con deep learning en WSI** — *Original research*, 2023.
“Interpretable deep learning model to predict the molecular classes in endometrial carcinoma from whole-slide images.” Potencial para patología computacional ginecológica. *The Lancet*

11. AVANCES RECIENTES _____ DESTACADOS EN MEDICINA

Avances Recientes Destacados en Medicina

1. Competición de IA para Alzheimer financiada por Bill Gates

Gates Ventures ha lanzado el Alzheimer's Insights AI Prize, con un premio de 1 millón de dólares. Equipos diversos (desde *startups* hasta tecnólogos) competirán para crear herramientas de IA capaces de analizar extensos datos de Alzheimer, pensando, razonando y actuando de forma autónoma. La herramienta ganadora será accesible gratuitamente en la plataforma de Alzheimer's Disease Data Initiative. (Financial Times)

2. Asistente Médico Digital para Misiones Espaciales (NASA + Google)

La NASA y Google colaboran en el Crew Medical Officer Digital Assistant (CMO-DA). Este asistente basado en IA, con reconocimiento multimodal (voz, texto, imágenes), diagnosticará y tratará condiciones médicas sin contacto inmediato con la Tierra. En pruebas simuladas, alcanzó tasas de diagnóstico de entre el 74 % y el 88 %. Podría adaptarse también para atención en zonas remotas o afectadas por desastres. (Cinco Días)

3. Diagnósticos Psiquiátricos Más Objetivos

Se están empleando patrones cerebrales, biomarcadores y realidad virtual para identificar biotipos de depresión o trastornos psicóticos, usando herramientas como el análisis ocular (Senseye). Estas tecnologías buscan superar la subjetividad del DSM. Aunque con cautela, se reconoce su potencial para personalizar tratamientos. (El País)

4. Herramienta Diagnóstica de Microsoft Supera a Médicos

Microsoft presentó el Microsoft AI Diagnostic Orchestrator (MAI-DxO), un sistema que aúna cinco agentes de IA para diagnosticar mediante una "cadena de debate". En pruebas con 304 casos médicos complejos, obtuvo un 85.5 % de éxito, frente al 20 % de médicos en condiciones restringidas. Aunque todavía no está listo para clínicas, podría integrarse en Copilot y Bing. (Financial Times)

5. Asistente Virtual 'Lola' para Vacunación en La Rioja

La Rioja (España) ha introducido un asistente virtual, Lola, que llamará por teléfono —con voz simulada— a personas de 65 años para animarles a vacunarse contra el herpes zóster y el neumococo. En un año contactará hasta 10.000 personas, informándolas, facilitando citas y ofreciendo seguimiento. El sistema está en fase piloto desde el 18 de agosto con 4.000 personas seleccionadas. (Cadena SER)

6. Prueba con IA para Identificar Beneficiarios de Tratamiento de Cáncer de Próstata

Un equipo internacional ha creado una prueba basada en IA que analiza biopsias del tumor y detecta qué pacientes con cáncer de próstata no metastásico de alto riesgo responderán al fármaco abiraterona. En un estudio con más de 1 000 hombres, el tratamiento redujo la mortalidad a cinco años del 17 % al 9 % en el 25 % con biomarcador positivo. Se pide revisar su cobertura en el NHS. (The Guardian)

7. Startup Valenciana en el Reino Unido para Detección de Cáncer de Próstata

La empresa española Quibim, especializada en IA de imágenes médicas, ha sido seleccionada por el NHS para probar su herramienta QP-Prostate en siete hospitales, analizando imágenes de 3.000 pacientes. La compañía recibió 2.6 millones de libras dentro del programa SBRI y ya cuenta con alianzas con Philips, Merck y Novartis. (Cinco Días)

8. **IA Mejora el Alcance de los ECG en Detección Cardíaca**

La herramienta EchoNext, desarrollada en la Universidad de Columbia, analiza ECG comunes para identificar pacientes que deberían someterse a un ecocardiograma. Superó a 13 cardiólogos con un 77 % de precisión frente al 64 %. Detectó 3 400 posibles casos no diagnosticados al revisar los historiales de casi 85.000 personas. (Reuters)

Resumen por Áreas:

Aplicación	Ejemplos Recientes
Diagnóstico precoz y personalizado	Alzheimer AI Prize, Quibim, EchoNext, prueba de abiraterona
Toma de decisiones autónoma	MAI-DxO (Microsoft)
Acceso y logística sanitaria	Lola (asistente telefónico)
Ambientes extremos / remotos	CMO-DA (NASA + Google)
Psiquiatría de precisión	Diagnóstico por biotipos y realidad virtual
Reducción de cargas administrativas	No cubierto en noticias recientes, pero existen tendencias como <i>Scribers</i> generativos

Avances Tecnológicos

- **ChatGPT-5 no cumple expectativas:** Aunque era uno de los lanzamientos más esperados, muchos expertos consideran que el nuevo modelo de OpenAI no ha supuesto una revolución y algunos lo ven como un parón en el sector.
- **IA en dispositivos Pixel:** Google ha lanzado el Pixel 10 con funciones de IA nativa, incluyendo traducción de llamadas en tiempo real.

IA y Espiritualidad

- **Chatbots religiosos:** Herramientas como “GPTJesus” permiten mantener conversaciones simuladas con figuras religiosas, lo que ha generado debate sobre el papel de la IA en la espiritualidad.

IA en Salud y Educación

- **Diagnóstico de trastornos:** Neurekalab ha desarrollado una IA capaz de detectar dislexia y TDAH, ayudando a mejorar el rendimiento escolar.
- **IA como tutor:** Se están explorando formas en que la IA pueda enseñar habilidades, no solo realizarlas por ti.

Ética y Sostenibilidad

- **Consumo energético:** Google ha revelado que cada pregunta a su IA consume tanta energía como ver nueve segundos de televisión.

- **Impacto ambiental y social:** Se intensifican los debates sobre cómo la IA puede beneficiar o perjudicar a distintos sectores sociales.

Aplicaciones Clínicas Reales

En el Health Revolution Congress, se presentaron casos prácticos como:

- Chatbots que ayudan a dejar de fumar, ofreciendo apoyo emocional diario.
- Plataformas de rehabilitación remota con algoritmos que adaptan los ejercicios según el progreso del paciente.
- IA para diagnóstico precoz, seguimiento personalizado y automatización de tareas médicas.

Beneficios Económicos y Operativos

Según la Revista Salud y Familia, la IA podría reducir entre un 5 % y un 10 % los costos anuales del sistema sanitario, lo que equivale a 200–360 mil millones de dólares al año.

- Mejora la eficiencia administrativa, libera tiempo para los profesionales y optimiza recursos.

Medicina de Precisión y GenAI

En 2025, se está consolidando el uso de IA generativa para crear tratamientos personalizados y apoyar decisiones clínicas complejas.

- La medicina de precisión se beneficia de análisis masivos de datos genéticos, históricos y ambientales.

Humanización y Ética

En el Foro de IA en Salud, se debatió cómo la IA puede humanizar la atención médica, no solo automatizarla. Se busca que los sistemas sean empáticos, accesibles y éticamente responsables.

¿Qué Retos Enfrenta la IA en el Sector Salud?

La inteligencia artificial en salud promete grandes avances, pero también enfrenta desafíos complejos que van más allá de lo técnico. Los principales retos que están marcando el debate en 2025 son:

Ética y Equidad

- **Sesgos algorítmicos:** Si los datos de entrenamiento no representan a toda la población, los diagnósticos pueden ser menos precisos para ciertos grupos.
- **Privacidad de datos:** La gestión de información médica sensible exige marcos legales sólidos para evitar filtraciones o usos indebidos.
- **Acceso desigual:** Las innovaciones tienden a concentrarse en zonas urbanas o países desarrollados, dejando atrás a comunidades rurales o vulnerables.

Interoperabilidad y Fragmentación

- **Sistemas desconectados:** Muchos hospitales y clínicas usan plataformas incompatibles, lo que dificulta integrar la IA de forma efectiva.

- **Falta de estándares comunes:** Sin protocolos universales, los desarrollos en IA no se pueden escalar ni compartir fácilmente entre instituciones.

Capacitación Profesional

- **Brecha de habilidades:** Solo el 0.8 % de las vacantes en salud mencionan habilidades en IA, aunque la demanda está creciendo.
- **Resistencia al cambio:** Algunos profesionales temen que la IA reemplace su rol, cuando en realidad puede potenciarlo.

Seguridad y Regulación

- **Ciberseguridad:** Los sistemas de salud son blanco frecuente de ataques, y la IA puede ser vulnerable si no se protege adecuadamente.
- **Falta de regulación clara:** Muchos países aún no han definido cómo supervisar el uso de IA en salud, lo que genera incertidumbre legal.

Validación Científica

- **Ensayos clínicos con IA:** Aún se debate cómo validar algoritmos médicos con el mismo rigor que los medicamentos tradicionales.
- **Explicabilidad:** Algunos modelos funcionan como “cajas negras”, lo que dificulta entender cómo llegan a sus conclusiones.

Estos retos no son obstáculos insalvables, sino puntos clave para construir una IA en salud que sea segura, justa y útil para todos.

¿Cómo se Está Abordando la Regulación en Otros Países?

La regulación de la inteligencia artificial en salud está avanzando rápidamente en varios países, cada uno con enfoques distintos, pero con un objetivo común: garantizar un uso ético, seguro y transparente de la tecnología.

Unión Europea: Pionera en Regulación

- La UE ha aprobado el Reglamento de Inteligencia Artificial, que entró en vigor en agosto de 2024.
- Clasifica las aplicaciones de IA según su nivel de riesgo:
 - **Alto riesgo:** Como IA en salud o vigilancia, requieren evaluaciones rigurosas.
 - **Riesgo mínimo:** Tienen una regulación más flexible.
- Se imponen sanciones estrictas para usos indebidos y se exige transparencia en los algoritmos.

Organización Mundial de la Salud (OMS)

- Publicó un informe global con 6 principios rectores para el uso de IA en salud:
 - Protección de derechos humanos.
 - Transparencia y explicabilidad.
 - Inclusión y equidad.

- Responsabilidad legal.
 - Sostenibilidad.
 - Promoción del bienestar humano.
- Recomienda que la IA complemente, no reemplace, la atención médica humana.

Estados Unidos

- Aunque no tiene una ley federal específica, se están desarrollando guías éticas sectoriales.
- La FDA evalúa herramientas de IA como dispositivos médicos, exigiendo validación clínica y pruebas de seguridad.

China

- Ha implementado regulaciones centradas en el control estatal y la seguridad nacional.
- Exige que los algoritmos médicos sean revisados por autoridades antes de su despliegue.

Tendencia Global

Se está formando un consenso internacional sobre la necesidad de:

- Estándares comunes para interoperabilidad.
- Auditorías éticas y técnicas.
- Educación profesional sobre IA en salud.

El Coste Aproximado de la Introducción de la IA en México y en España

La inversión en inteligencia artificial (IA) está creciendo rápidamente tanto en México como en España, pero con enfoques y escalas distintas. Aquí tienes un resumen comparativo:

MX México: Inversión en IA

- **Valor proyectado del mercado en 2025:** Se estima que el mercado de aplicaciones de IA alcanzará los 450 millones de dólares, frente a los 98 millones en 2024, lo que representa un crecimiento de 2.4 veces.
- **Sectores líderes:** Finanzas y manufactura están a la cabeza en adopción de IA, especialmente con modelos híbridos que combinan la nube y soluciones locales.
- **Inversión privada destacada:** Microsoft anunció una inversión de 1300 millones de dólares en infraestructura y capacitación en IA para los próximos tres años.
- **Barreras principales:** La calidad de los datos, la falta de talento especializado y la capacitación insuficiente son los mayores retos.

ES España: Inversión en IA

- **Estrategia Nacional de IA (ENIA):** El Gobierno ha destinado 2500 millones de euros entre 2021 y 2025 para impulsar la digitalización y la adopción de IA en sectores estratégicos como sanidad, energía y administración pública.
- **Capital riesgo en startups de IA:** Desde 2020, las *startups* españolas han captado 2 billones de euros en inversión privada, posicionando a España como el 5.º *hub* europeo en IA.

- **Costes operativos:** La IA implica altos costes energéticos, de *hardware* especializado, formación de personal y cumplimiento legal. Cada *prompt* o interacción puede tener un coste significativo en términos de infraestructura.

☒ Comparativa Rápida

Aspecto	México MX	España ES
Inversión pública estimada	No centralizada, pero creciente	2,500 millones € (2021–2025)
Inversión privada destacada	Microsoft: 1,300 millones USD	2 billones € en capital riesgo
Sectores clave	Finanzas, manufactura	Sanidad, energía, administración
Retos principales	Datos, capacitación	Energía, talento, infraestructura

¿Cómo Impacta la IA en la Economía de México y España?

La inteligencia artificial (IA) está remodelando las economías de México y España, pero lo hace de formas distintas según sus estructuras productivas, niveles de inversión y políticas públicas. Aquí tienes un análisis comparativo:

MX Impacto de la IA en la Economía de México

- **Transformación sectorial:**
 - **Manufactura:** Robots inteligentes y mantenimiento predictivo están mejorando la eficiencia y reduciendo costes.
 - **Finanzas:** IA para detección de fraudes, personalización de servicios y gestión de riesgos.
 - **Retail y comercio:** *Chatbots*, análisis de datos y *marketing* personalizado están cambiando la experiencia del consumidor.
- **Startups como motor de cambio:**
 - Más de 2 millones de empresas mexicanas ya usan IA, con las *startups* liderando la adopción.
 - El 83 % de las empresas que adoptaron IA reportan aumento de ingresos (16 % promedio) y mejoras en productividad (88 %).
- **Retos estructurales:**
 - Solo el 3 % de las empresas usa IA de forma avanzada.
 - La falta de talento especializado, la infraestructura limitada y la desigualdad digital son barreras clave.

ES Impacto de la IA en la Economía de España

- **Proyecciones económicas:**
 - Se estima que la IA aportará 282 000 millones de euros al PIB español en 2030.
 - Puede aumentar la productividad en un 3 % en la próxima década.
- **Empleo y transformación laboral:**
 - Hasta el 65 % de los trabajadores verá sus tareas complementadas por IA.

- Beneficia especialmente a jóvenes y reduce desigualdades entre trabajadores con menor rendimiento inicial.

- **Políticas públicas y regulación:**

- España ha lanzado la estrategia HispanIA 2040 y aprobado el Reglamento Europeo de IA, que regula según niveles de riesgo.
- La Estrategia Nacional de IA impulsa talento y digitalización en pymes, que aún tienen baja adopción (solo el 8 %).

- **Ecosistema inversor:**

- La IA ha reactivado el ecosistema *startup* tras años de crisis, con rondas históricas y mayor inversión extranjera.

☒ Comparativa Rápida

Aspecto	México MX	España ES
Aporte estimado al PIB	No definido claramente	282.000 M€ en 2030
Productividad	Mejora en sectores clave	+3% en 10 años
Adopción empresarial	38% de empresas usan IA	36% (8% en pymes) ⁵
Empleo	Riesgo de automatización en 2–5%	Transformación de tareas en 65%
Retos	Talento, infraestructura, desigualdad	Brecha pymes-grandes empresas, regulación
Políticas públicas	Capacitación masiva con AWS	Estrategia HispanIA 2040

¿Qué Políticas Públicas Están Implementando Ambos Países Sobre IA?

¡Gran pregunta! México y España están tomando caminos distintos, pero complementarios, para regular y fomentar el desarrollo de la inteligencia artificial (IA). Aquí te presento un resumen claro y actualizado de sus políticas públicas:

MX México: Políticas Públicas sobre IA

México está en una fase de construcción normativa, con múltiples iniciativas en curso:

- **Propuestas legislativas clave:**

- **Ley para la regulación ética de la IA y la robótica:** Establece principios de derechos humanos y crea el Consejo Mexicano de Ética para la IA.
- **Reforma constitucional (art. 73):** Otorga al Congreso facultades para legislar sobre IA, ciberseguridad y neuroderechos.
- **Ley de la Agencia Mexicana para el Desarrollo de la IA:** Propone una entidad encargada de coordinar políticas públicas en educación, empleo e infraestructura.
- **Ley Federal que regula la IA:** Basada en niveles de riesgo (similar al modelo europeo), con supervisión del Instituto Federal de Telecomunicaciones.

- **Agenda Nacional de IA:**

- Elaborada por la Secretaría de Economía y la Coalición IA2030MX.

- Promueve la innovación responsable, pero aún carece de mecanismos ejecutivos vinculantes.

- **Retos actuales:**

- Fragmentación normativa.
- Falta de especialización jurídica.
- Brecha entre avance tecnológico y capacidad regulatoria.

ES España: Políticas Públicas sobre IA

España ha adoptado un enfoque más estructurado y ambicioso:

- **Estrategia Nacional de IA 2024:**

- **Presupuesto:** 1500 millones € adicionales (más 600 millones ya movilizados).
- **Ejes principales:**
 - Supercomputación (MareNostrum 5).
 - Modelos de lenguaje en castellano y lenguas cooficiales (proyecto ALIA).
 - Centros de datos sostenibles.
 - Formación y becas para talento especializado.

- **Administración Pública Digital:**

- **Estrategia Consenso por una Administración Abierta:**
 - Plataforma soberana de IA (14 millones €).
 - Simplificación de trámites administrativos.
 - Identidad Digital Europea y evolución de “Mi Carpeta Ciudadana”.

- **Impacto en el sector público:**

- La IA generativa podría mejorar hasta el 50 % de las tareas de más del 67 % de los trabajadores públicos.
- Se estima un aumento de productividad del 9 % en 10 años.

☒ Comparativa Rápida

Elemento	México MX	España ES
Marco legal	En desarrollo, con múltiples iniciativas	Consolidado, con estrategia nacional activa
Enfoque regulatorio	Ética, derechos humanos, riesgo tecnológico	Ético, sostenible, centrado en talento y datos
Instituciones pro-puestas	Agencia Mexicana de IA, Consejo de Ética	AESIA, MareNostrum, Ministerio de Transformación Digital

Presupuesto público	No centralizado, depende de iniciativas	2.100 millones € (2021–2025)
Aplicación sectorial	Educación, empleo, infraestructura	Administración pública, pymes, investigación

¿Qué Sector se Beneficiará Más de Estas Políticas?

Las políticas públicas de inteligencia artificial (IA) en México y España están diseñadas para transformar múltiples sectores, pero hay algunos que destacan por el impacto directo y la velocidad de adopción. Aquí te presento los sectores más beneficiados en cada país:

MX México: Sectores Más Beneficiados

● **Salud:**

- La IA está ayudando a mejorar el diagnóstico médico, optimizar la gestión hospitalaria y facilitar el acceso a servicios en zonas rurales.
- Se espera que la telemedicina y los sistemas de IA reduzcan los tiempos de atención y mejoren la precisión clínica.

● **Educación:**

- Las políticas promueven la formación en habilidades digitales y el uso de IA para personalizar el aprendizaje.
- Se están desarrollando plataformas educativas inteligentes para reducir la brecha digital.

● **Industria y manufactura:**

- Automatización de procesos, mantenimiento predictivo y control de calidad con IA.
- Microsoft y otras empresas están invirtiendo en infraestructura para potenciar este sector.

ES España: Sectores Más Beneficiados

● **Sector público y administración:**

- La IA generativa podría mejorar entre el 10 % y el 50 % de las tareas de más del 67 % de los trabajadores públicos, aumentando la productividad hasta un 9 %.
- Se está aplicando para reducir la burocracia, mejorar la atención ciudadana y optimizar la contratación pública.

● **Educación y formación:**

- Becas, formación profesional y redes de talento especializado están en el centro de la Estrategia Nacional de IA 2024.
- Se impulsa el desarrollo de modelos de lenguaje en castellano y lenguas cooficiales para mejorar la accesibilidad educativa.

- **Sanidad:**

- IA para diagnóstico, gestión hospitalaria y predicción de enfermedades.
- Se están financiando proyectos de IA en hospitales y universidades con fondos europeos.

☒ **Comparativa Rápida**

Sector	México MX	España ES
Salud	Diagnóstico, telemedicina	Gestión hospitalaria, IA clínica
Educación	Plataformas inteligentes, inclusión	Formación profesional, modelos lingüísticos
Administración pública	En desarrollo	Reducción de burocracia, eficiencia
Industria	Automatización, inversión privada	Menor prioridad, pero con potencial

En resumen:

- España está apostando fuerte por la administración pública como motor de transformación.
- México está viendo un impulso notable en salud, educación e industria, gracias a la colaboración público-privada.

¿Qué Desafíos Enfrentan Estos Sectores en la Adopción de IA?

La adopción de inteligencia artificial (IA) en sectores clave como salud, educación, industria y administración pública en México y España está avanzando, pero no sin obstáculos. Aquí te presento los desafíos más relevantes que enfrentan ambos países:

MX México: Desafíos en Sectores Clave

- **Falta de talento especializado:**

- Solo el 19 % de las empresas tiene competencias sólidas en IA.
- El 55 % de las *startups* identifica la escasez de talento como su principal barrera.

- **Infraestructura limitada:**

- Muchas empresas, especialmente pymes, carecen de acceso a infraestructura tecnológica moderna y conectividad adecuada.
- La migración a la nube es clave, pero aún insuficiente en muchas regiones.

- **Calidad y gestión de datos:**

- La mayoría de las empresas no cuenta con datos limpios, seguros y estructurados, lo que limita el entrenamiento de modelos de IA.

- **Ciberseguridad y gobernanza:**

- La adopción de IA sin una postura robusta de seguridad genera riesgos de privacidad y confianza.

- **Brecha entre grandes empresas y pymes:**

- Solo el 3 % de las empresas mexicanas usa IA de forma avanzada.

- Las *startups* lideran la adopción, pero las empresas tradicionales enfrentan deuda técnica y procesos lentos.

ES España: Desafíos en Sectores Clave

- **Brecha entre uso y transformación real:**

- Aunque el 78 % de los profesionales usa IA habitualmente, solo el 36 % se siente suficientemente formado.
- Apenas 1 de cada 4 empleados recibe orientación sobre cómo aplicar IA en su trabajo.

- **Formación y cultura organizativa:**

- La falta de capacitación continua y liderazgo digital limita el impacto de la IA.
- Las empresas necesitan reimaginar procesos *end-to-end* para liberar valor real.

- **“IA en la sombra”:**

- El 54 % de los empleados usaría herramientas de IA sin autorización, lo que plantea riesgos de seguridad y gobernanza.

- **Costes de implementación:**

- Altos costes de integración, especialmente en pymes, dificultan la adopción estratégica.

- **Falta de datos estructurados:**

- La indisponibilidad de datos de calidad es una barrera para el desarrollo de modelos eficaces.

☒ Comparativa Rápida

Desafío	México MX	España ES
Talento especializado	Escaso, especialmente en pymes	Formación insuficiente en empleados
Infraestructura	Limitada, brecha digital	Costes altos en pymes
Datos	Calidad y gestión deficiente	Falta de datos estructurados
Ciberseguridad	Gobernanza débil	Riesgo por uso no autorizado (“IA en la sombra”)
Cultura organizativa	Resistencia al cambio	Falta de transformación profunda

En resumen:

- México necesita cerrar la brecha entre *startups* y empresas tradicionales, mejorar la infraestructura y formar talento.
- España debe traducir su liderazgo en uso de IA en una transformación operativa real, con más formación, liderazgo y seguridad.

¿Cuáles Son Ejemplos Específicos en el Sector Salud?

La inteligencia artificial (IA) está revolucionando el sector salud en México y España con aplicaciones concretas que ya están en marcha. Aquí tienes ejemplos específicos y actuales que muestran cómo esta tecnología está mejorando la atención médica:

MX México: Ejemplos Destacados en Salud

- **Diagnóstico de ceguera en recién nacidos:**
 - En el Hospital Luis Sánchez Bulnes, Microsoft y la Asociación para Evitar la Ceguera desarrollaron un algoritmo que detecta ceguera en bebés a partir de imágenes del fondo del ojo.
- **Detección de brotes epidemiológicos:**
 - Pablo AI, una herramienta creada por epidemiólogos mexicanos, analiza redes sociales para identificar patrones de enfermedades contagiosas y alertar a autoridades sanitarias.
- **Cirugías remotas y medicina predictiva:**
 - Se están explorando cirugías asistidas por IA y el uso de algoritmos para predecir enfermedades como el Alzheimer y el cáncer, gracias al análisis de datos biométricos.
- **Integración de historiales médicos:**
 - Proyectos piloto buscan crear historiales médicos únicos y encriptados accesibles desde cualquier hospital del país, usando *blockchain*.

ES España: Ejemplos Destacados en Salud

- **Diagnóstico asistido por IA:**
 - Algoritmos analizan imágenes médicas (radiografías, resonancias) para detectar tumores o anomalías con mayor precisión que el ojo humano.
- **Desarrollo de medicamentos:**
 - La IA acelera el diseño de fármacos al analizar bases de datos genéticas y predecir la eficacia de compuestos químicos.
- **Cirugía robótica:**
 - Robots quirúrgicos guiados por IA permiten operaciones más precisas y seguras, reduciendo errores humanos.
- **Monitorización con wearables:**
 - Dispositivos como relojes inteligentes detectan ritmos cardíacos irregulares o apnea del sueño, alertando a médicos en tiempo real.

- **Chatbots y telemedicina:**

- Asistentes virtuales programan citas, responden dudas médicas y gestionan tratamientos a distancia, especialmente útiles en zonas rurales.

☒ Comparativa Rápida

Aplicación	México MX	España ES
Diagnóstico por imagen	Ceguera neonatal, cáncer	Tumores, enfermedades cardiovasculares
Epidemiología	Detección de brotes vía redes sociales	Predicción de eventos de salud
Cirugía	Remota y asistida por IA	Robótica de alta precisión
Telemedicina	En expansión, con IA básica	Integrada con NLP y asistentes virtuales
Gestión de datos médicos	Blockchain para historiales únicos	IA para historiales electrónicos

Estos ejemplos no solo muestran el potencial de la IA, sino que también reflejan cómo cada país adapta la tecnología a sus necesidades sanitarias.

La inteligencia artificial (IA) está revolucionando la salud y en los próximos años su impacto será aún más profundo. La combinación de *big data*, aprendizaje profundo, aprendizaje federado y robótica permitirá mejoras en diagnóstico, tratamiento, personalización de la medicina y gestión hospitalaria.

Diagnóstico Más Rápido y Preciso

- **IA en imágenes médicas:** Algoritmos avanzados detectarán cáncer, enfermedades cardíacas y neurológicas con mayor precisión que los radiólogos humanos.
- **Diagnóstico basado en IA federada:** Modelos entrenados con datos de múltiples hospitales sin comprometer la privacidad, mejorando el diagnóstico en obstetricia y neonatología.
- **Biopsia líquida con IA:** Algoritmos que analizan biomarcadores en sangre para detectar enfermedades como el cáncer en etapas tempranas.
- **Ejemplo:** Google Health ha desarrollado IA que supera a los médicos en la detección del cáncer de mama en mamografías.

Personalización del Tratamiento (Medicina de Precisión)

- IA para identificar tratamientos personalizados en base al ADN del paciente (farmacogenómica).
- Modelos predictivos para ajustar medicamentos y dosis en enfermedades como diabetes, hipertensión o cáncer.
- Optimización de tratamientos en obstetricia: la IA puede predecir preeclampsia y parto prematuro, permitiendo intervenciones tempranas.
- **Ejemplo:** IBM Watson Oncology ya sugiere tratamientos personalizados para pacientes con cáncer.

Asistentes Médicos Virtuales y Chatbots

- *Chatbots* con IA avanzados ayudarán a los pacientes con síntomas, seguimiento de enfermedades crónicas y recordatorios de medicamentos.
- IA en telemedicina: Mayor automatización en consultas médicas remotas.
- Soporte a profesionales de la salud en la toma de decisiones clínicas.

- **Ejemplo:** Babylon Health utiliza IA para diagnosticar y recomendar tratamientos a través de un *chatbot* médico.

Cirugía Robótica y Automatización

- Robots quirúrgicos con IA como Da Vinci serán más autónomos y precisos en procedimientos complejos.
 - IA en ginecología y obstetricia: Cirugías mínimamente invasivas asistidas por IA para patologías ginecológicas.
 - Gestión hospitalaria optimizada: la IA mejorará la asignación de recursos, la predicción de ingresos hospitalarios y la reducción de tiempos de espera.
- **Ejemplo:** En hospitales ya se usa IA para predecir ingresos a UCI con gran precisión.

IA en la Prevención y Salud Pública

- Predicción de brotes epidemiológicos mediante análisis de *big data*.
 - Monitorización en tiempo real de signos vitales con dispositivos *wearables*.
 - IA aplicada a la nutrición y bienestar, ajustando dietas personalizadas según la salud del paciente.
- **Ejemplo:** BlueDot, una IA, detectó el brote de COVID-19 antes que la OMS.

Ética, Regulación y Seguridad en IA para la Salud

- **Privacidad y seguridad de datos:** Implementación del aprendizaje federado para evitar compartir datos sensibles.
 - **IA explicable y transparente:** Mayor regulación para evitar sesgos en modelos de IA.
 - **Certificación de IA en salud:** La IA tendrá que cumplir regulaciones más estrictas, como la FDA y la EMA.
- **Ejemplo:** En Europa, la IA en salud debe cumplir con el Reglamento de Inteligencia Artificial de la UE para garantizar seguridad y ética.

Conclusión: Un Futuro con IA y Médicos Trabajando Juntos

La IA no reemplazará a los médicos, sino que se convertirá en un aliado fundamental para mejorar la precisión, eficiencia y personalización de la medicina. Con avances como el aprendizaje federado en hospitales, la IA en obstetricia y neonatología puede reducir complicaciones y salvar vidas.

Cómo Formar a los Médicos para el Uso de la IA en el Futuro

Formar a los médicos para el uso de la inteligencia artificial en el futuro requiere una combinación de educación técnica, ética y práctica clínica. Aquí hay un enfoque estructurado para lograrlo:

1. Integración en la Educación Médica

- **Pregrado:** Incluir módulos sobre fundamentos de IA en el currículo de medicina. Materias como análisis de datos, aprendizaje automático y bioética en IA pueden ser parte de la formación básica.

- **Posgrado y Especialización:** Incorporar la IA en programas de residencia y especialización para que los médicos aprendan a usar herramientas específicas según su área (radiología, dermatología, oncología, etc.).
- **Educación Continua:** Ofrecer cursos, certificaciones y talleres en IA aplicada a la salud para médicos en ejercicio.

2. Formación en Competencias Digitales

Los médicos no necesitan ser programadores, pero deben entender los principios básicos de la IA para su aplicación clínica:

- Conceptos básicos de IA y *Machine Learning* (redes neuronales, modelos predictivos, NLP, etc.).
- Interacción con sistemas de IA (interpretación de resultados, validación de predicciones).
- Gestión de datos clínicos (seguridad, privacidad, interoperabilidad).
- Toma de decisiones asistida por IA (cómo combinar la inteligencia humana con la artificial).

3. Simulación y Práctica Clínica con IA

- **Casos Clínicos Simulados:** Entrenamiento con sistemas de IA para diagnóstico y pronóstico.
- **Uso de Asistentes Virtuales:** Implementación de *chatbots* y sistemas de soporte para mejorar la atención médica.
- **Colaboración con Ingenieros y Científicos de Datos:** Equipos multidisciplinarios para resolver problemas médicos con IA.

4. Enfoque Ético y Regulatorio

- **Implicaciones bioéticas:** Sesgos en la IA, equidad en la salud, toma de decisiones autónoma.
- **Regulaciones y estándares de IA en salud:** Normativas como GDPR, HIPAA, FDA y EMA.
- **Responsabilidad legal del médico al usar IA:** Cómo interpretar recomendaciones de la IA sin reemplazar el juicio clínico.

5. Desarrollo de una Mentalidad de Aprendizaje Continuo

- Acceso a repositorios de investigación en IA y salud.
- Plataformas de formación *online*: Coursera, edX, Stanford AI in Healthcare.
- Participación en *hackathons* y proyectos de innovación en salud digital.

6. Implementación en el Sistema de Salud

- **Hospitales Inteligentes:** Creación de entornos donde la IA apoye diagnósticos, tratamientos y gestión hospitalaria.
- Protocolos de uso de IA en consultas médicas.
- Adopción de herramientas de IA validadas clínicamente.

Proyecto Práctico

Para médicos interesados en empezar con IA, se puede diseñar un proyecto de análisis de datos clínicos, por ejemplo:

- Usar *Machine Learning* para predecir el riesgo de enfermedades (diabetes, hipertensión).

- Implementar un *chatbot* para responder preguntas médicas frecuentes en una clínica.
- Explorar modelos de visión por computadora para el diagnóstico de imágenes médicas.

Conclusión

La formación en IA para médicos debe ser progresiva y adaptada a su nivel de conocimiento tecnológico. Con una combinación de educación formal, práctica clínica y ética, los médicos podrán aprovechar la IA como una herramienta para mejorar la atención al paciente sin perder el enfoque humanístico de la medicina.

El Futuro de la IA en la Salud: Tendencias y Predicciones

La inteligencia artificial (IA) está revolucionando la salud y en los próximos años su impacto será aún más profundo. La combinación de *big data*, aprendizaje profundo, aprendizaje federado y robótica permitirá mejoras en diagnóstico, tratamiento, personalización de la medicina y gestión hospitalaria.

El futuro de la inteligencia artificial (IA) en la salud de la mujer y en la sostenibilidad está lleno de posibilidades transformadoras. Ambas áreas, aunque distintas, convergen en un punto: el uso ético e inteligente de la tecnología para mejorar vidas y proteger el planeta. El desarrollo de la inteligencia artificial (IA) avanza rápidamente y promete revolucionar múltiples aspectos de la sociedad en los próximos años.

1. IA General (AGI - Inteligencia Artificial General)

- **Visión:** Crear sistemas de IA con capacidades cognitivas humanas completas, que puedan razonar, aprender y adaptarse a una amplia variedad de tareas sin reentrenamiento.
- **Impacto:** Podrían desempeñar cualquier trabajo intelectual humano y resolver problemas complejos como el cambio climático o la exploración espacial.
- **Desafío:** Actualmente, la IA sigue siendo "estrecha" (especializada en tareas específicas). Lograr AGI requerirá avances significativos en neurociencia, computación y ética.

2. IA en Interfaces Cerebro-Máquina

- **Descripción:** Desarrollar conexiones directas entre cerebros humanos y máquinas para amplificar las capacidades cognitivas o rehabilitar funciones perdidas.
- **Proyectos actuales:**
 - Neuralink de Elon Musk trabaja en implantes cerebrales para controlar dispositivos con la mente.
 - Interfaces no invasivas como dispositivos de electroencefalografía avanzada.
- **Futuro:** Podrían permitir habilidades como el aprendizaje instantáneo, la comunicación directa sin lenguaje y la integración de la IA en la mente humana.

3. Modelos Multimodales Avanzados

- **Descripción:** Sistemas que combinan múltiples fuentes de información, como texto, imágenes, audio y video, para interactuar con el mundo de forma más integral.
- **Ejemplo actual:** GPT-4 ya tiene capacidades multimodales.
- **Futuro:** Modelos que integren datos sensoriales complejos, como olores o sensaciones táctiles, para aplicaciones avanzadas en robótica, medicina y educación.

4. Robótica Impulsada por IA

- **Visión:** Robots que aprendan como los humanos, adaptándose al entorno sin programación previa específica.
- **Áreas clave:**
 - **Nanobots médicos:** Robots microscópicos que navegan por el cuerpo humano para reparar tejidos, administrar medicamentos o eliminar tumores.
 - **Asistentes domésticos inteligentes:** Robots que entienden y anticipan las necesidades del hogar.
 - **Exploración espacial:** Robots con autonomía completa para colonizar otros planetas o explorar ambientes extremos.

5. Modelos Predictivos para la Salud

- **Avances esperados:**
 - Sistemas de IA que analicen datos genéticos, estilo de vida y patrones de salud para predecir enfermedades años antes de que aparezcan los síntomas.
 - "Gemelos digitales" humanos: Modelos virtuales personalizados que simulen el cuerpo de una persona para predecir respuestas a tratamientos o procedimientos médicos.
- **Impacto:** Revolución en la medicina preventiva y personalizada.

6. IA en Sostenibilidad y Cambio Climático

- **Proyectos futuros:**
 - Sistemas de IA que optimicen redes de energía renovable en tiempo real.
 - Algoritmos para diseñar nuevos materiales que absorban dióxido de carbono de la atmósfera.
 - Modelos climáticos ultraprecisos que predigan eventos extremos con semanas de antelación.

7. IA Emocional y Social

- **Descripción:** Sistemas que no solo entiendan, sino que también simulen emociones humanas para interactuar de forma más natural.
- **Aplicaciones:**
 - Asistentes virtuales empáticos para salud mental y terapia.
 - IA en educación personalizada, adaptándose al ritmo y estado emocional del estudiante.
- **Riesgo:** Distinguir entre emociones simuladas y reales puede plantear problemas éticos.

8. IA Cuántica

- **Definición:** La combinación de inteligencia artificial y computación cuántica para resolver problemas demasiado complejos para las computadoras clásicas.
- **Impacto potencial:**
 - Resolver problemas de optimización en segundos, como logística global o simulaciones moleculares.

- Acelerar el descubrimiento de fármacos y el diseño de materiales revolucionarios.
- **Desafío:** La computación cuántica aún está en sus primeras etapas de desarrollo.

9. Creación y Arte Generativo Avanzados

- **Futuro:** IA capaz de generar obras de arte, música, literatura y cine que rivalicen con la creatividad humana.
- **Proyectos emergentes:** Modelos de IA como DALL-E y MidJourney, evolucionados hacia creaciones completamente interactivas y contextuales.
- **Impacto:** Nuevas formas de expresión artística y democratización de herramientas creativas.

10. Economía y Sociedad Impulsadas por IA

- **Automatización de industrias completas:** Desde la agricultura y manufactura hasta los servicios legales y financieros.
- **Ingreso básico universal:** La automatización masiva podría llevar a modelos económicos alternativos para garantizar el bienestar en una sociedad donde muchas tareas laborales sean reemplazadas.
- **Gobernanza basada en IA:** Sistemas que ayuden a los gobiernos a tomar decisiones más justas y basadas en datos.

11. Educación Personalizada Masiva

- **Visión:** Plataformas de aprendizaje adaptativas que ajusten el contenido, la dificultad y el método de enseñanza a las necesidades individuales de cada estudiante.
- **Futuro:** Educación disponible para cualquier persona, en cualquier idioma, de forma completamente gratuita.

Retos y Consideraciones Éticas

- **Regulación:** Evitar usos indebidos de la IA, como vigilancia masiva o manipulación social.
- **Control humano:** Asegurar que la IA esté alineada con los valores y objetivos humanos.
- **Inclusión:** Garantizar que los beneficios de la IA lleguen a todos, evitando desigualdades.

IA en la Salud de la Mujer: Un Futuro Personalizado y Predictivo

El futuro de la inteligencia artificial (IA) en la salud de la mujer y en la sostenibilidad está lleno de posibilidades transformadoras. Ambas áreas, aunque distintas, convergen en un punto: el uso ético e inteligente de la tecnología para mejorar vidas y proteger el planeta. Aquí tienes una visión articulada de ambos campos: La IA está posicionada para revolucionar cada etapa del ciclo vital femenino: desde la pubertad hasta la menopausia y más allá.

1. Ginecología y Obstetricia

- **Detección precoz** de cánceres ginecológicos (mama, cuello uterino, ovario) mediante análisis automatizado de imágenes y datos genéticos.
- **Modelos predictivos de embarazo:** predicción de riesgos como preeclampsia, parto prematuro o diabetes gestacional.
- **Ultrasonografía inteligente:** IA que asiste en la interpretación de ecografías obstétricas, incluso por no especialistas en entornos rurales.

2. Medicina Personalizada en Fertilidad

- **Análisis de ciclos, hormonas y estilos de vida** con IA para optimizar ventanas fértiles.
- **Selección embrionaria asistida por IA** en FIV, con alta precisión basada en datos morfocinéticos y genéticos.

3. Salud Mental y Emocional Femenina

- **Chatbots y asistentes virtuales** entrenados en salud mental con enfoque de género.
- IA que detecta signos tempranos de ansiedad o depresión postparto mediante análisis de voz, escritura o expresión facial.

4. Menopausia y Envejecimiento Saludable

- Algoritmos que personalizan el manejo hormonal, nutricional y físico en función del perfil de riesgo y preferencias individuales.

IA y Sostenibilidad en Salud: Eficiencia Inteligente

La sostenibilidad en el ámbito de la salud abarca no solo aspectos ecológicos, sino también económicos, éticos y sociales. La inteligencia artificial (IA) puede desempeñar un papel fundamental para su consecución.

1. Hospitales verdes inteligentes

- **Gestión energética optimizada por IA:** Se logra una reducción significativa en el consumo de electricidad, agua y gases medicinales.
- **Modelos de predicción de residuos clínicos:** Permiten una mejor planificación y contribuyen a la disminución de plásticos de un solo uso.

2. Toma de decisiones clínicas sostenibles

- **Recomendación de tratamientos con menor huella ambiental:** La IA sugiere alternativas con menor impacto ecológico cuando existen equivalentes clínicos.
- **Optimización del uso de laboratorios y pruebas:** Los algoritmos ayudan a evitar procedimientos innecesarios.

3. Telemedicina y descentralización inteligente

- **Reducción de desplazamientos innecesarios:** La IA filtra consultas o monitorea remotamente, lo que beneficia especialmente a mujeres embarazadas o personas mayores.

4. Equidad en el acceso

- **IA multilingüe y adaptativa:** Facilita el acceso a la salud para mujeres en zonas rurales o en situaciones de exclusión.
- **Algoritmos para evitar sesgos de género:** Se entrenan para asegurar diagnósticos y decisiones terapéuticas equitativas.

Convergencia: IA para una Salud Femenina Sostenible

El futuro ideal integra ambos mundos: una IA que cuida de las mujeres sin perjudicar al planeta. Algunos ejemplos incluyen:

- Aplicaciones de salud menstrual que educan y promueven el uso de productos reutilizables.
- Plataformas de seguimiento del embarazo que previenen visitas innecesarias, pero alertan ante riesgos reales.
- Biobancos virtuales con datos femeninos que alimentan algoritmos éticos y sostenibles para la investigación.

Conclusión

El futuro de la IA en la salud de la mujer y la sostenibilidad será:

- Preventivo en lugar de reactivo.
- Personalizado, no estandarizado.
- Inclusivo y ético, con enfoque de género.
- Ecológico, porque no hay salud en un planeta enfermo.

Tendencias y Predicciones

En este punto, es crucial distinguir dos niveles de conocimiento, de manera análoga a la medicina. Existe un cuadro clínico que, manejado con la mejor intención, ofrece la posibilidad de un diagnóstico más o menos cercano a la realidad, aunque con un porcentaje significativo de errores (en algunas patologías, superior al 50 %). Sin embargo, existe otro nivel, más profundo y alejado de los signos clínicos observables. El médico intuye la existencia de un escenario propio para investigadores o especialistas en ciencia básica (comprendiendo por "básico" los mecanismos y preceptos celulares y nucleares). Cuando estos dos niveles se conjugan, suelen generar resultados espectaculares (desde nuestra perspectiva actual), aunque no siempre están al alcance de la mayoría de los profesionales clínicos.

En el ámbito de la IA sucede algo similar. Hasta ahora, con mayor o menor fortuna, los profesionales utilizaban ordenadores clásicos, en muchas ocasiones programados por informáticos o médicos con conocimientos de programación de rutinas, pero sin rebasar los límites establecidos por la máquina y el software. Este escenario queda obsoleto al entrar en el terreno de la inteligencia artificial, con la posibilidad de aplicarse a la práctica totalidad de los ámbitos de nuestra vida, tanto individual como colectiva. Además, la capacidad de la máquina para autoformarse, al integrar diversas informaciones que conducen a resultados similares, es un factor adicional. Todo esto, que parece impensable, se fundamenta en el manejo de bases de datos inmensamente grandes, con miles de millones de datos estructurados, capaces de superar cualquier obstáculo. Este fenómeno solo es posible si se estructura de manera adecuada y profesional. Desde la gestión de un puerto comercial o industrial hasta el funcionamiento miocárdico, pasando por el diseño y construcción de robots que pueden realizar casi todo lo que hace un humano, con la ventaja de obedecer órdenes en cualquier idioma y establecer conversaciones en todas las lenguas, incluso realizando traducciones simultáneas con una perfección superior a la humana, registrando todos los textos y ofreciéndolos al final como si de un acta se tratara. Los vehículos autónomos y las aeronaves sin piloto serán algo común antes de diez años. Las labores de montaje, ya sean de coches o de aparatos de precisión, estarán bajo la acción de robots específicos.

¿Qué impacto tendrá esto en la vida social y laboral de la humanidad? Es una pregunta que nadie puede responder con certeza. Según las proyecciones de las Naciones Unidas, se espera que la población mundial alcance aproximadamente 8.888 millones de personas para el año 2035. Este crecimiento no será uniforme

en todas las regiones. Se anticipa que África experimentará el mayor incremento, con su población aumentando de 1.341 millones en 2020 a 1.878 millones en 2035, lo que representa un crecimiento del 40 %. Por otro lado, Asia seguirá siendo el continente más poblado, pasando de 4.641 millones en 2020 a 5.096 millones en 2035, lo que supone un incremento del 9.8 %. En contraste, Europa podría experimentar una ligera disminución en su población, pasando de 748 millones en 2020 a 735 millones en 2035.

Estas tendencias reflejan diferencias en las tasas de natalidad, mortalidad y migración entre las distintas regiones del mundo. ¿Se imaginan que todos estos datos estén en bases de datos y puedan ser manipulados? La GPU A100 de Nvidia, cuando se utiliza para el aprendizaje profundo, es capaz de 312 teraFLOPS (o 312.000.000 MIPS), es decir, 730 millones de veces más rápida que la 6502, y la asombrosa cifra de 110.000 millones de veces más rápida que la ENIAC.

Nota:

- **GPU:** Unidades de Procesamiento Gráfico
- **TeraFLOPS:** Un billón de operaciones de coma flotante por segundo
- **MIPS:** Millones de instrucciones por segundo
- **Nvidia y ENIAC:** Nvidia es una empresa líder en el desarrollo de IA; ENIAC fue uno de los primeros ordenadores electrónicos.

Como puede observarse, estamos vislumbrando un futuro difícil de comprender en la actualidad, y mucho menos de limitar temporalmente (por ejemplo, al año 2035), porque la velocidad de avance puede ser aún mayor de lo calculado en los modelos más optimistas.

¿Qué nos deparará? ¿Un poderoso compañero desarrollador de IA o despidos masivos? Considero y espero que será más de lo primero y menos de lo segundo, aunque la apuesta más segura es una combinación de ambos métodos. Al igual que sucedió con la energía de vapor en el siglo XIX, una IA verdaderamente útil no puede detenerse ahora que existe; algo que convierte a los desarrolladores en objetivos fáciles de sustituir, nos guste o no. De todas maneras, sistemas de IA competentes significan educación prácticamente gratuita para todos, en todas partes, y esto solo puede conducir a resultados positivos.

El alfabeto cerebral humano

En el desarrollo de la estrategia de la IA, se utilizan diversos modelos que aprovechan adecuadamente los principios biológicos. Un ejemplo significativo es el desciframiento del "alfabeto cerebral humano".

Este constituye uno de los ejemplos más significativos y útiles. Se ha descifrado el "alfabeto cerebral" que posibilita los complejos movimientos de nuestras manos. De la misma forma en que es posible crear todas las palabras de un idioma combinando las letras de su alfabeto, las acciones más complejas de la mano humana pueden construirse a partir de un reducido número de movimientos básicos almacenados en el cerebro.

Si hubiera que destacar la habilidad que más distingue a los humanos de otras criaturas, muchos elegirían nuestra extraordinaria capacidad para usar las manos con destreza. Acciones tan cotidianas como escribir, abrir una puerta, utilizar un sacacorchos o enhebrar una aguja nos parecen intuitivas, casi automáticas. Sin embargo, nada más lejos de la realidad. Cada una de ellas esconde una frenética actividad cerebral, una orquestación neuronal de movimientos precisos y ordenados de una complejidad asombrosa. ¿Cómo logra nuestro cerebro que realicemos todo eso sin apenas darnos cuenta? El autor de la crónica acierta al intentar vincular los fundamentos del funcionamiento del cerebro humano con lo que pueden realizar las redes neuronales informáticas.

Fruto de la colaboración entre investigadores de la Universidad de Carnegie Mellon y la de Coimbra en Portugal, se ha revelado que, para construir la infinita variedad de acciones que realizamos con nuestras manos, el cerebro humano emplea un sencillo "alfabeto" de movimientos básicos. La investigación, recientemente publicada en *Proceedings of the National Academy of Sciences*, compara el funcionamiento del cerebro

con el de un lenguaje. De este modo, al igual que las palabras se construyen a partir de un número limitado de letras, todas las acciones complejas que llevamos a cabo con nuestras manos se basan en una pequeña serie de movimientos fundamentales.

El estudio, liderado por la neurocientífica Leyla Caglar, del Mount Sinai Medical Center, ha identificado una región cerebral clave en este proceso: el llamado "giro supramarginal" (GSM), situado en el lóbulo parietal inferior izquierdo, un área que ya se conocía por su papel en la planificación de acciones dirigidas a objetos.

Para lograr su hallazgo, los investigadores se valieron de una técnica de modelado computacional de datos de resonancia magnética funcional (fMRI). Esta herramienta fue utilizada para analizar la actividad cerebral de voluntarios que participaron en el estudio realizando diversas tareas manuales.

Los resultados mostraron, sin lugar a dudas, que el giro supramarginal procesa las acciones de una manera sorprendentemente sistemática. Así, en lugar de almacenar cada acción como una entidad separada, esta región combina un conjunto limitado de patrones de movimientos coordinados de dedos, manos, muñecas y brazos, a los que los científicos han denominado "sinergias cinemáticas".

Un ejemplo puede ayudar a clarificar este concepto. Pensemos en la postura de la mano al utilizar unas tijeras. Es muy similar a la que adoptamos para manipular unos alicates. Es decir, aunque la función de ambos objetos es radicalmente diferente, el patrón de movimiento básico para agarrarlos y manipularlos comparte elementos comunes. Por el contrario, aunque unas tijeras y un cúter puedan servir para el mismo propósito (cortar), la postura de la mano requerida para cada una de esas tareas es totalmente distinta.

De esta forma, el estudio mostró que la actividad en el GSM era muy similar para los objetos que requerían posturas de la mano parecidas, independientemente de su función final. Lo cual sugiere que el cerebro agrupa las acciones basándose en la mecánica del movimiento y no en el objetivo para el que se usan.

Esta idea, aunque no es del todo nueva en neurociencia (el concepto de sinergias motoras ya fue planteado por científicos como Nikolái Bernstein en el siglo pasado, quien observó cómo el sistema nervioso simplificaba el control de movimientos complejos), cobra una nueva dimensión con este nuevo trabajo. Caglar y su equipo, en efecto, han conseguido la primera evidencia concluyente de que el cerebro utiliza una estructura combinatoria para las acciones de la mano, con el giro supramarginal actuando como un verdadero "centro de ensamblaje".

En palabras de Caglar, «del mismo modo en que las regiones cerebrales que sustentan el lenguaje combinan sonidos, o fonemas, para formar palabras, el cerebro también combina sinergias cinemáticas para formar acciones complejas dirigidas a objetos». Y añade: «A partir de este conjunto cerrado de bloques de construcción básicos, el cerebro construye todo el repertorio de acciones que se pueden realizar con la mano humana».

Implicaciones fascinantes

El impacto de este hallazgo va mucho más allá de la neurociencia básica. Sus ramificaciones, de hecho, podrían revolucionar campos como la robótica, las interfaces cerebro-máquina e incluso el tratamiento de ciertos trastornos neurológicos.

En el campo de la robótica, por ejemplo, comprender cómo el cerebro humano orquesta los movimientos complejos podría ser la clave para diseñar sistemas artificiales mucho más ágiles e inteligentes. Actualmente, muchos robots requieren una programación detallada y rígida para cada tarea manual. Si los ingenieros logran replicar el sistema de sinergias cinemáticas recién descubierto, podrían crear robots capaces de "aprender" a manipular objetos de forma más natural y flexible, combinando movimientos básicos ya existentes en lugar de tener que programar cada uno de ellos desde cero para cada nueva función. Jorge Almeida, coautor del estudio, subraya esta idea: «Esto nos acerca a la creación de sistemas artificiales capaces de actuar con la agilidad, eficiencia e inteligencia comparables a las de los humanos».

Prótesis biónicas que se sienten y actúan

Pero quizás la aplicación más emocionante se encuentre en otro campo muy diferente: el desarrollo de interfaces cerebro-máquina, tecnologías que permiten a las personas con parálisis o amputaciones controlar prótesis o dispositivos externos directamente con sus pensamientos. Si los científicos logran "mapear" estas sinergias de la actividad neuronal, podrían construir interfaces mucho más eficientes. Las ventajas serían enormes: en lugar de tener que descifrar cada movimiento individual del dedo, la interfaz interpretaría las sinergias básicas, permitiendo a los usuarios controlar sus prótesis con una naturalidad, precisión y flexibilidad mucho mayores. Sería como pasar de componer palabras letra por letra para una imprenta manual a escribir frases completas en un ordenador. Un paso de gigante que mejorará la calidad de vida de miles de personas.

Por último, el descubrimiento también abre nuevas perspectivas en el estudio de enfermedades neurológicas como la apraxia, una condición en la que los pacientes pierden la capacidad de usar objetos correctamente a pesar de que aún pueden reconocerlos. Un paciente con apraxia ideomotora, por ejemplo, podría saber que un peine se usa para el cabello, pero sería incapaz de realizar el movimiento correcto para peinarse. Almeida sugiere que este tipo de trastornos podrían ser el resultado de un "déficit en el ensamblaje" de los movimientos. De forma análoga a una dislexia en el lenguaje, donde la dificultad radica en combinar los sonidos para formar palabras, el daño en el giro supramarginal podría dificultar la planificación y ejecución de acciones complejas con objetos.

Aprendido, no innato

Con todo, una de las conclusiones más importantes de la investigación es que este sistema de "alfabeto motor" no es algo que ya llevamos incorporado al nacer, sino que se va moldeando a lo largo de nuestra vida. Si bien todos los humanos contamos con una estructura cerebral común para el lenguaje y las acciones, nadie nace sabiendo usar un bolígrafo o una llave. El aprendizaje cultural y la experiencia son, por lo tanto, fundamentales. El cerebro, en su constante plasticidad, se adapta y organiza para integrar la información visual, táctil, motora y conceptual. Y el giro supramarginal, estratégicamente situado para recibir e integrar todos estos tipos de información, es un claro ejemplo de cómo la estructura cerebral refleja la interacción entre nuestra biología evolutiva y nuestra experiencia individual.

«Este estudio —concluye Leyla Caglar— nos acerca un paso más a la comprensión de los principios fundamentales de la organización cerebral que hacen posible el uso de herramientas por parte de los humanos». En definitiva, un "viaje alucinante" al interior de nuestra mente, donde la complejidad de nuestras acciones más cotidianas se revela como una sinfonía perfectamente interpretada por la combinación de naturaleza y aprendizaje. (ABC. José Manuel Nieves). Quiero expresar mi más sincero agradecimiento al autor de la crónica, que nos ha brindado una visión de futuro muy esperanzadora.

Por otro lado, con el fin de que se tome conciencia de la seriedad del tema, los invito a leer la crónica que publicó Belén Arribas en el periódico *El Nacional* (Cataluña) y que pone en evidencia la trascendencia económico-social de la introducción de esta tecnología.

Tras un proceso de consulta pública y reuniones con los líderes de Silicon Valley, la Casa Blanca presentó recientemente el documento *Winning the AI Race: America's AI Action Plan*, un compendio de más de noventa medidas que reorganizan las prioridades nacionales en torno a tres pilares estratégicos: acelerar la innovación, construir infraestructura tecnológica y ejercer un liderazgo.

Los orígenes del plan estratégico

En enero de 2025, el presidente Donald Trump firmó la Orden Ejecutiva 14179, bajo el título *Removing Barriers to American Leadership in Artificial Intelligence*. Con este gesto, el mandatario dejó en claro que la inteligencia artificial sería un eje central de su segundo mandato, no solo como motor de innovación económica, sino también como herramienta estratégica para reforzar el liderazgo estadounidense en un escenario internacional dominado por la competencia tecnológica.

La orden, que revocaba políticas de su predecesor, instruía a la Oficina de Política Científica y Tecnológica a elaborar, en un plazo de 180 días, un plan integral para garantizar que Estados Unidos mantenga la delantera en la carrera global de la IA.

Los ejes del plan: innovación, infraestructura y poder global

1. El primer eje se centra en la innovación. Trump plantea una política de desregulación agresiva, con el objetivo de eliminar lo que considera trabas burocráticas al desarrollo de la inteligencia artificial. Se anuncia la revisión de decisiones de la Comisión Federal de Comercio (FTC) tomadas durante la administración anterior, y se advierte que los estados que adopten regulaciones "excesivas" sobre IA podrían ver reducidos sus fondos federales.

En este marco, el plan promueve una IA "libre de sesgos ideológicos", ordenando revisar las guías técnicas del Instituto Nacional de Estándares y Tecnología (NIST) para eliminar referencias a temas como desinformación, diversidad o cambio climático. Nada más y nada menos.

También se impulsa el desarrollo de modelos de código abierto y se garantizan mayores recursos a *start-ups* y universidades para acceder a infraestructura de computación avanzada. La administración promete, asimismo, fomentar proyectos piloto en áreas como salud, agricultura y energía, bajo esquemas reguladores flexibles que permitan experimentar con aplicaciones de IA en beneficio de la competitividad del país.

2. El segundo pilar gira en torno a la infraestructura. El plan contempla un despliegue acelerado de centros de datos, fábricas de semiconductores y redes de energía capaces de sostener el consumo exponencial de la IA. Para ello, se anuncia la flexibilización de los procesos de permisos y la reducción de normas ambientales, lo que permitiría instalar instalaciones críticas en suelos federales con mayor rapidez.

El gobierno apuesta por una combinación de fuentes energéticas, que incluyen no solo renovables y nucleares, sino también gas y carbón, en línea con la política energética pragmática de Trump. A este esfuerzo se suma la promoción de megaproyectos como Stargate, una iniciativa liderada por un consorcio de gigantes tecnológicos como OpenAI, Oracle y SoftBank, que busca levantar la infraestructura de inteligencia artificial más avanzada del mundo dentro de Estados Unidos y en países aliados.

Con estas medidas, la administración pretende garantizar que el ecosistema tecnológico estadounidense no dependa de cadenas de suministro externas y pueda responder al desafío planteado, en particular, por China.

3. El tercer pilar pone el acento en la dimensión internacional. El plan establece una política de exportaciones generosa hacia países aliados, tanto en *hardware* como en *software* y modelos de inteligencia artificial, con el propósito de consolidar un bloque tecnológico alineado con Washington.

Paralelamente, refuerza la oposición frontal a la influencia de China en organismos multilaterales como la ONU y el G20, donde Estados Unidos pretende imponer sus estándares como referencia global. No obstante, la estrategia no está exenta de contradicciones.

Reacciones al plan de Trump

Las reacciones al plan no se hicieron esperar. Desde la Casa Blanca, el equipo cercano a Trump —con figuras como David Sacks, designado como "zar" de IA y criptomonedas— defiende el espíritu de desregulación como la clave para permitir la innovación y lograr que el mercado lidere la próxima revolución tecnológica. El sector empresarial, especialmente figuras como Jensen Huang, director ejecutivo de Nvidia, ha mostrado entusiasmo por el impulso a la infraestructura y la apertura hacia proyectos privados de gran escala. Sin embargo, no faltan voces críticas.

Científicos y académicos han advertido que los recortes presupuestarios en agencias como la Fundación Nacional de Ciencias, los Institutos Nacionales de Salud o la NASA ponen en riesgo la base investigadora que históricamente ha nutrido los avances tecnológicos.

Organizaciones ambientalistas alertan, por su parte, sobre el impacto ecológico de multiplicar centros de datos en un contexto de relajación de normas. También surgen preocupaciones legales respecto a posibles violaciones en materia de control de exportaciones y de constitucionalidad en los acuerdos comerciales con países competidores.

La IA en la administración

En el ámbito gubernamental, el plan se traduce en la implementación de la plataforma USAi, destinada a empleados federales y desarrollada en alianza con empresas como OpenAI, Anthropic, Google y Meta. Esta herramienta busca acercar la inteligencia artificial a la administración pública, aunque algunos críticos señalan que podría concentrar demasiado poder en manos de un puñado de compañías.

El balance del AI Action Plan es complejo. Desde una perspectiva económica y de competitividad, el plan apuesta fuerte por la velocidad, la inversión privada y la eliminación de obstáculos reguladores. Sin embargo, esa misma lógica de aceleración genera inquietudes sobre la sostenibilidad ambiental, la imparcialidad en el uso de los algoritmos y la solidez del marco institucional. El discurso oficial se centra en "ganar la carrera" frente a China y reafirmar el liderazgo estadounidense, pero los costos de este enfoque podrían ser altos a largo plazo. La pregunta es si esta visión de desarrollo tecnológico prioriza el interés público y la seguridad global o si responde principalmente a una lógica de poder geopolítico.

Calidad asistencial

Desde hace años, los servicios más avanzados, con el objetivo de la mejora continua, se adhirieron a métodos de control mediante el diseño y la definición de indicadores. Estos indicadores sirvieron como guía para la mejora y la formación continua de los profesionales, así como para un adecuado control de la calidad del servicio.

La calidad asistencial es el conjunto de características de la atención sanitaria que aseguran que los pacientes reciben la mejor atención posible, de forma efectiva, segura, equitativa y centrada en la persona.

Según la OMS y el Instituto de Medicina de EE. UU., la calidad asistencial debe cumplir con varios principios fundamentales:

1. **Seguridad:** Evitar daños innecesarios a los pacientes durante la atención.
2. **Efectividad:** Basarse en la mejor evidencia científica disponible y lograr los resultados deseados.
3. **Oportunidad:** Brindar atención en el momento adecuado, sin demoras evitables.
4. **Eficiencia:** Usar los recursos disponibles de forma óptima, sin despilfarro.
5. **Equidad:** Garantizar el mismo nivel de atención a todas las personas, sin discriminación.
6. **Atención centrada en el paciente:** Respetar las preferencias, valores y necesidades del paciente.

¿Cómo se mide la calidad asistencial?

Se mide a través de indicadores de calidad, que pueden ser de tres tipos:

- **Estructura:** Recursos, personal, tecnología.
- **Proceso:** Cómo se brinda la atención (protocolos, tiempos).
- **Resultados:** Salud del paciente, complicaciones, satisfacción.

¿Por qué es clave la calidad asistencial?

Mejora la experiencia del paciente, reduce eventos adversos y errores médicos, optimiza el uso de recursos, aumenta la confianza en el sistema sanitario y facilita la mejora continua de los servicios.

Gran parte de este proceso se basa en la correcta manipulación de los indicadores y los estándares, los cuales han constituido la base de los programas de calidad de muchos centros asistenciales obstétricos y ginecológicos, ratificándose con el tiempo como herramientas de gran valor. De esta forma, se ha podido hacer un seguimiento de la calidad asistencial dentro de los propios servicios, o se han realizado estudios comparativos entre ellos, permitiendo la toma de decisiones adecuadas para conseguir los objetivos pactados.

En 1999, la Sociedad Española de Ginecología y Obstetricia desarrolló indicadores de calidad para centros hospitalarios, no asistenciales de atención primaria. Es evidente que cada nivel asistencial es determinante para el funcionamiento del sistema, y si uno falla, todos lo hacen. Sin embargo, para comenzar, se consideró más oportuno iniciar con indicadores útiles para grandes hospitales, dejando para un futuro inmediato el abordaje de los indicadores asistenciales del primer nivel, cuyos puntos cardinales de actuación son sensiblemente distintos.

Más adelante, y tal como se anunció en su día, cualquier centro podría solicitar una evaluación según los distintos indicadores aplicables a su ámbito de competencia. El objetivo es comprobar hasta qué punto se encuentran dentro de los límites recomendables. En caso de cumplir con todos ellos, se le reconocería un nivel competencial de excelencia, lo cual constituiría un aval de garantía tanto para la comunidad asistida como para las diversas administraciones (universidad, I+D, entidades privadas, etc.).

La utilización de los Indicadores de Calidad permitió evaluar si la asistencia, técnicamente impecable, se realizaba dentro de un marco adecuado de calidad, no solo percibida por los profesionales, sino también por el paciente y su entorno. En otras palabras, si la asistencia es adecuada, oportuna, segura, accesible, con la correcta utilización de recursos y en períodos de tiempo razonables. Por ello, los indicadores no deben ser interpretados como herramientas de control de nuestra labor, sino más bien como un sistema de autoevaluación. Su uso, si se emplea correctamente, permite analizar y cuantificar cómo es y cómo está nuestra asistencia y, en caso necesario, cuáles son los aspectos a mejorar, cambiar o utilizar adecuadamente. Esta herramienta está diseñada para ser utilizada de dos formas: aplicando el mismo indicador en dos períodos de tiempo distintos (por ejemplo, comparando los resultados de dos años consecutivos para ver la evolución de nuestra práctica asistencial), o comparando los resultados de un período con los estándares orientativos que se adjuntan a los indicadores, lo que permite apreciar la calidad de nuestra asistencia con respecto a estos referentes.

De las aproximaciones más básicas, centradas en la relación médico-paciente individual, se ha pasado, a medida que se modificaba el concepto de salud, a aproximaciones más generales. Estas incluyen no solo la globalidad de servicios prestados por todos los profesionales de la salud, sino también los aspectos de atención a una comunidad y, por tanto, los conceptos de efectividad y equidad en la distribución de los recursos para la atención de la salud.

Antecedentes de la calidad en la atención sanitaria

Los primeros antecedentes documentados relacionados con la calidad de la atención sanitaria se remontan a la segunda mitad del siglo XIX, cuando Florence Nightingale estudió las tasas de mortalidad de los hospitales militares durante la guerra de Crimea. También se considera precursor de estudios sobre el tema a Ernest Codman, cofundador del Colegio Americano de Cirujanos, quien en 1912 desarrolló en Estados Unidos un método que permitía clasificar y medir los resultados de la atención quirúrgica. Otra referencia habitual es la definición de "The Minimum Standard", realizada por el Colegio Americano de Cirujanos en 1918, la cual especificaba los estándares mínimos que debía cumplir un hospital y que fue la base de la acreditación.

Se debe remarcar también como un evento importante la creación de la Joint Commission on The Accreditation of Hospitals (JCAH) en 1951, formada por una agrupación de colegios profesionales americanos. Esta comisión inició su labor acreditando centros hospitalarios que lo solicitaban de forma voluntaria, siem-

pre que cumplieran unos estándares de calidad preestablecidos. Durante su evolución, ha impulsado el desarrollo de diferentes metodologías en el ámbito de la calidad y ha extendido su actuación a otros tipos de centros sanitarios, motivo por el cual cambió de nombre y, actualmente, se denomina Joint Commission on Accreditation of Healthcare Organizations (JCAHO).

Una aportación significativa de la década de los cincuenta fue la de Paul Lembdke, cirujano de la John Hopkins University Medical School, quien desarrolló un nuevo método para evaluar la calidad: el *audit* médico. Lembdke, profundamente preocupado por la variabilidad de resultados que observaba en su práctica diaria, estableció los criterios explícitos que permitían la comparación entre centros y profesionales y una sistemática de recogida de información que incluía la verificación de los datos y el diseño del estudio. Más adelante, entre 1965 y 1966, se crearon en Estados Unidos los programas federales de atención a ancianos y personas sin recursos (MEDICARE y MEDICAID), y se estipuló que los hospitales que habían pasado la Acreditación de la JCAHO serían reconocidos para la atención de este tipo de pacientes.

Cabe citar también los trabajos de J. Williamson, quien en los años setenta introdujo una nueva metodología con la formulación del concepto de ABNA (*achievable benefit not achieved*, beneficio posible no alcanzado). Este mide la diferencia entre los estándares considerados deseables para el diagnóstico y tratamiento y la práctica real, evaluada tanto mediante la revisión de las historias clínicas como mediante la revisión del estado de los pacientes y el envío de cuestionarios en los que reportaban su estado de salud. Williamson realizó parte de sus trabajos en el ámbito de la atención primaria (hipertensión, etc.), estableciendo los "resultados deseables" de la atención y poniendo especial énfasis en la mejora de la calidad obtenida tras los estudios. Se inauguraba así la etapa de la garantía de calidad (*quality assurance*), tras la etapa anterior más centrada en la evaluación que en la mejora.

Sin embargo, uno de los autores que más impacto tuvo en el cambio del panorama de la calidad fue, sin duda, R. Brook. Él estableció el seguimiento de pacientes a largo plazo después de la atención sanitaria y demostró la baja correlación entre el proceso y los resultados de la asistencia. Los trabajos de Brook han representado, durante las dos décadas posteriores, la capacidad para cuestionar los paradigmas anteriormente establecidos en cada momento y aportar siempre una visión innovadora que ha generado polémicas y avances notables. Además, sus trabajos sobre este tema, que se concretarían después en el desarrollo de métodos para establecer la adecuación de procedimientos, fueron una de las aportaciones más interesantes, ya que pusieron de manifiesto las hipótesis que permiten explicar la variabilidad (sistemas de pago, formación de los profesionales, etc.) y la forma de abordarla desde el punto de vista de los estudios de calidad.

En este breve repaso histórico, no se puede olvidar la aportación de un gran estudioso en este campo, como es el Profesor Avedis Donabedian, quien desde la clasificación de los métodos de evaluación de la calidad en estructura, proceso y resultado en el año 1966, y desde la reflexión sobre el impacto del modelo de calidad industrial sobre el modelo sanitario en el año 1992, ha ofrecido una gran cantidad de estudios y planteamientos, tanto teóricos como de aplicación práctica, de indudable ayuda para todos aquellos profesionales que trabajan para la mejora de la calidad. Fruto de esta reflexión, tanto Donabedian como Heather Palmer, han realizado aportaciones sobre las dimensiones de la calidad que han influido de forma decisiva en la conceptualización de esta disciplina.

La Oficina Regional de la OMS en Europa define: "Una atención sanitaria de alta calidad es la que identifica las necesidades de salud (educativas, preventivas, curativas y de mantenimiento) de los individuos o de la población de una forma total y precisa, y destina los recursos necesarios (humanos y otros) a estas necesidades de forma oportuna y tan efectiva como el estado actual del conocimiento lo permite". Más recientemente, se ha presentado un cambio importante en cuanto al enfoque filosófico y conceptual al proponer el paso de "Quality Assurance" a "Continuous Quality Improvement" o "Mejora Continua de la Calidad", surgida de la adaptación de conceptos y estrategias de la calidad industrial al sector sanitario.

Es necesario tener presentes los esquemas básicos de la calidad asistencial.

De forma resumida, los puntos básicos de la mejora continua de la calidad, hasta hace pocos años, son:

- Implicación y liderazgo de los elementos directivos.
- Planificación de la calidad: Definición de las bases de la calidad en la organización.
- Enfoque al cliente interno y externo.

- Implicación de todos los profesionales.

El desarrollo de estos puntos debe permitirnos alcanzar la aplicación total de la definición de calidad, expuesta anteriormente. Para ello, se utilizó en su momento la Trilogía de Juran, que plantea que toda la organización debe planificar, medir y mejorar la calidad.

La planificación de la calidad incluye, según Juran:

- Definir la calidad tal como a los clientes les interesa.
- Diseñar los servicios adecuados a las necesidades de los clientes.
- Destinar y organizar los recursos de forma que permitan alcanzar dichos servicios.
- Diseñar los procesos que sean capaces de producirlos.
- Trasladarlos a las actividades habituales.
- Diseñar el sistema de medición.

Durante los años 80, la JCAHO requirió la existencia en todos los centros de planes de calidad integrados a nivel global, los cuales encontraron una importante resistencia. En 1986, estableció el estándar que implementaba los sistemas de monitorización y su desarrollo metodológico. Los sistemas de monitorización se conciben como una valoración global de todo un servicio y no solo de las áreas problemáticas que puedan detectarse. Para llevarlos a cabo, era necesario definir el tipo de atención que se realizaba en un determinado servicio o centro mediante un proceso de "dimensionado", estableciendo las principales áreas de trabajo y creando los indicadores que permitían medirlo. Estos indicadores, que se evalúan de forma periódica, permiten tener una visión de conjunto, con una cierta aproximación, de la calidad del servicio y actuar en los casos en que se presentaban desviaciones. Se aplicaron básicamente a la evaluación de diferentes especialidades y con menos intensidad a nivel global de los centros.

Sin embargo, tal como se verá seguidamente, todas estas metodologías necesitan una adecuada y correcta información para poder obtener los mejores resultados, y ahí es donde se inicia a poner el interés en el dato, es decir, en el valor de un acto, para que, en conjunción con muchos más de su estirpe, pueda acercarse al valor más idóneo para los cálculos. Como es de suponer, esta evolución ha hecho que el control de calidad se haya facilitado al máximo y concretado hasta el límite que puede aportar la correcta base de datos. Tanto es así que la importancia que ha adquirido el dato sea la parte más significativa y relevante para poder diseñar programas con algoritmos pertinentes para cada uno de los criterios de cada estándar, siendo así que se realice, por el momento, la mejor forma de construir mediante árboles diferentes un programa holístico de calidad que incluya no tan solo los resultados asistenciales, sino también los de otros aspectos como la privacidad y la complicitad de los datos en términos de calidad. Todo este escenario lo aportan los diversos algoritmos y capas neuronales de la inteligencia artificial, ofreciendo una información que puede, dependiendo de la profundidad de trabajo, incluso sugerir las medidas a tomar en cada una de las distintas áreas especificadas.

Metodología De Evaluación Y Mejora De La Calidad Antes Y Con Ia

Para ello se seguían dos sistemas básicos de trabajo:

- a) El llamado "por posibilidades de mejora", que incluye tanto el análisis de problemas como el de puntos débiles y utiliza básicamente el ciclo de evaluación que se describe más adelante.
- b) Los "sistemas de monitorización" que se utilizaban para detectar problemas y evaluar de forma periódica su mejora. Se explica con detalle en el apartado correspondiente.

Cuando trabajamos con "posibilidades de mejora", se intentaba responder a la pregunta: ¿Qué podemos o debemos mejorar?; y cuando trabajábamos mediante sistemas de monitorización, nos formulábamos la siguiente pregunta: ¿De todo lo que hacemos, qué es lo más importante y cómo aseguramos que lo estamos haciendo con un nivel de calidad correcto? En cualquier caso, son enfoques que se complementaban. Los equipos de mejora pueden trabajar en base a una u otra sistemática, dependiendo de su enfoque. Además, en

situación real es habitual trabajar paralelamente con las dos. De todas maneras, los resultados no eran satisfactorios en todos los aspectos, de ahí que con la nueva herramienta se buscasen soluciones alternativas, más fáciles, eficaces y útiles en varios sentidos.

Posibilidades de Mejora: Ciclo de Evaluación

Por otro lado, las posibilidades de mejora, que seguían la metodología de la evaluación y mejora de la calidad basándose en el seguimiento de los pasos de un ciclo de evaluación, también se han visto simplificadas con las nuevas directrices y metodologías de la IA. En la bibliografía podemos identificar diferentes versiones antiguas como el ciclo de la mejora de la calidad, las fases de los proyectos de mejora estipuladas por el Juran Institute, el ciclo de Deming, el PDCA, etc.

A continuación, a modo de recordatorio, se describen brevemente los pasos del ciclo, enumerando después los métodos e instrumentos utilizados en cada uno de ellos. La secuencia es:

- **Detección de posibilidades de mejora:** En esta fase se procede a la detección de posibilidades de mejora en un ámbito concreto de la atención mediante el uso de diferentes fuentes y técnicas de información (todo ello ya superado con las herramientas de la IA).
- **Priorización de posibilidades de mejora:** Una vez detectadas las posibilidades de mejora, debemos proceder a su priorización para averiguar por cuál empezaremos a trabajar. Este es uno de los puntos más importantes en la utilización de la IA.
- **Análisis causal:** Se realizará sobre la(s) posibilidad(es) de mejora priorizada(s), planteando y valorando todas las posibles causas que puedan influir en ella. Aquí, debe realizarse un algoritmo bien definido.
- **Definición de los criterios de evaluación:** Cuando la fase anterior no permite averiguar con exactitud la totalidad de las causas y su peso específico, procedemos a la definición de criterios de evaluación. Los criterios son juicios de buena práctica del ámbito que estamos estudiando y los utilizaremos como variables fundamentales a medir durante la realización del estudio de evaluación. Esta acción ya la realiza de entrada la utilización de la IA.
- **Diseño de estudios de evaluación:** El diseño y la realización de un estudio de evaluación incluirá la medida del nivel de cumplimentación de los criterios definidos en la fase anterior. Su objetivo es conocer el nivel de calidad actual y los motivos por los que se produce.
- **Implantación de acciones de mejora:** Se realizan hoy día con una buena utilización de la IA.
- **Estrategias de cambio:** Aquí se estudiaban y analizaban cuáles eran los trabajos de implantación más adecuados para cada acción de mejora propuesta y, también, cuáles eran las posibles resistencias que nos podíamos encontrar por parte de los profesionales implicados, a fin de prevenirlas y tratarlas.
- **Reevaluación:** Una vez implantadas las acciones de mejora, se reevalúa el tema, al cabo de un cierto tiempo, para comprobar la efectividad de las decisiones tomadas. Este apartado, el final, el que nos permite tomar decisiones, pero que se minimizan en la IA, dado que este hecho, en función de los árboles y algoritmos utilizados, ya se presentan sistemáticamente.

Vamos ahora a estudiar el proceso como se hacía en su totalidad y se puntualizará lo que la correcta utilización de la IA, en especial en su vertiente de privacidad y su utilización ética, puede brindar.

IA y Ética en la Evaluación de Calidad

La incorporación de IA en la evaluación de la calidad asistencial requiere garantizar principios éticos y de privacidad. La protección de datos y la transparencia en el uso de algoritmos son esenciales para evitar sesgos y asegurar decisiones justas. La combinación de sistemas tradicionales con nuevas tecnologías permite construir modelos holísticos de calidad que integran tanto la evaluación de resultados asistenciales como aspectos clave como la privacidad y seguridad de los datos.

En conclusión, la evolución de los sistemas de calidad asistencial ha pasado por diferentes etapas, desde los modelos tradicionales de evaluación hasta la integración de la inteligencia artificial. Hoy, la IA permite una supervisión más precisa, ágil y personalizada, facilitando la toma de decisiones basada en datos y mejorando la eficiencia de los sistemas de salud.

Insistimos en que todo el funcionamiento interno de la inteligencia artificial (IA) en cualquier contexto sanitario dependerá de una planificación y diseño adecuados, realizados por especialistas en la materia, junto con la asistencia que proporciona la propia IA a través de sus bases de datos y modelos analíticos avanzados, tal como se ha visto en los epígrafes anteriores.

Detección y Priorización de Problemas

Entendemos por posibilidades de mejora tanto los problemas que se han producido o se están produciendo en la realización de los diferentes trabajos de la atención, como los denominados puntos débiles, que son aquellos puntos en los que no se ha presentado un problema propiamente dicho, pero existe el riesgo de que se presente y es susceptible de una acción de mejora. Por tanto, podemos trabajar desde un enfoque de resolución de problemas o desde un enfoque de prevención de problemas, respectivamente. Es importante tener en cuenta que la metodología que se utiliza es la misma y se basa en el seguimiento de los pasos definidos previamente.

Se presentan a continuación los diferentes métodos para obtener esta información, teniendo en cuenta las diferentes fuentes de información accesibles:

Fuentes y Métodos de Información

Profesionales

- **De grupo:**

- Técnica de *brainstorming*.
- Técnica nominal de grupo.
- Diagrama de flujos.

- **Individuales:**

- Estudios de opinión mediante el uso de encuestas o buzón de sugerencias.
- Observación directa.

Clientes Externos

- Estudios de opinión, de satisfacción y/o de insatisfacción mediante uso de encuestas, de reclamaciones, de *focus groups*, etc.

Sistemas de Información (H.C., estadísticas, otros)

- Estudio de monitorización.
- Estudio de perfiles (desviación de la norma).
- Estudio de registros.
- Estudio de incidencias.

Ejemplos:

- Los pacientes sufren demoras sobre la hora programada en la sala de espera de consultas.
- Se produce una repetición innecesaria de exploraciones.
- No se ofrece de forma sistemática la anestesia regional en los partos.
- Las linfadenectomías realizadas no contienen un número suficiente de ganglios.

Priorización de Posibilidades de Mejora

Una vez obtenida la relación de las diferentes posibilidades de mejora de un determinado ámbito de la atención, se debe proceder a su priorización para decidir por cuál se empezará a trabajar.

Los métodos de priorización habitualmente utilizados son:

- a) La parrilla de priorización.
- b) La técnica de Delphi.

Parrilla de Priorización

Es una adaptación de los métodos propuestos por W. Hanlon y Williamson. Es un método de grupo en el que cada individuo prioriza una serie de posibilidades de mejora en función de los siguientes criterios:

- Número de clientes afectados.
- Riesgo que comporta el problema para el cliente.
- Coste diferencial (entre la solución prevista y la existencia del problema).
- Capacidad del equipo para resolver el problema.

Debemos tener en cuenta la posibilidad de utilizar otros criterios, dependiendo del tema que se trate, como por ejemplo:

- Coste de la "no calidad".
- Percepción del cliente externo (descontento que genera).
- Percepción del cliente interno.
- Evidencia de la variación en la práctica.
- Gestores y trabajadores interesados.
- Número de profesionales implicados.
- Posibles resistencias en el desarrollo del proyecto.

El uso de unos u otros criterios, más que permitir extraer una conclusión matemática, pretende ser un elemento de reflexión en el que se valoran una serie de factores que influyen en el posterior estudio y solución del problema. En cualquier caso, se utiliza un sistema de puntuación de cada criterio para cada problema. La puntuación es individual por parte de cada uno de los miembros que participan en el equipo de priorización, quienes después ponen en común las puntuaciones. Finalmente, queda una relación priorizada de las posibilidades de mejora donde se ha conjugado la opinión individual de cada miembro y la del equipo en global, que posteriormente se valora y discute con el equipo para verificar que refleja la opinión global. De todas maneras, como pueden asumir, todo ello lo realizarán las herramientas de la IA, sin tener que solicitarlo, puesto que ella misma (con la adecuada estructura de diseño del programa) ya se cuidará de aportar las soluciones requeridas.

Análisis Causal

La fase de análisis causal de un problema sirve para descubrir cuáles son las posibles causas y qué peso específico tiene cada una de ellas en el problema. Las herramientas metodológicas que nos han sido más útiles en esta fase son:

- a) **Diagrama de Ishikawa, de causa-efecto o de espina de pez:** Es una representación gráfica (espina de pez) de todas las posibles causas de un problema ordenadas por categorías.
- b) **Diagrama de Pareto:** Identificación de las causas de mayor impacto.
- c) **Diagrama de flujos:** Visualización del proceso afectado para identificar ineficiencias.

De todas maneras, la programación de los esquemas de funcionamiento, tal como se vio en los capítulos anteriores, tiene que incorporar todos los atributos propios de cada criterio y estándar de calidad. Antes, recordemos lo que significan los distintos atributos de cada estándar.

Diseño de Estudios de Evaluación

Se entrará en la fase de diseño de estudios de evaluación cuando el análisis causal no haya permitido determinar la totalidad de las causas y su peso específico o bien, cuando se necesite confirmar la propia existencia del problema o su magnitud. Los estudios de evaluación de la calidad parten de la evidencia científica, demostrada en los estudios de investigación, para valorar los niveles de calidad de la atención. Se utilizan fundamentalmente los estudios observacionales y, especialmente, los descriptivos en los que se evalúa el nivel de calidad de la práctica. Pero todo este proceso es el que debe realizar la estructura diseñada de la IA, con la aportación de una gran cantidad (ingente) de información, lo que redundará en una aproximación muy significativa al problema que nos ocupa.

Su objetivo es, pues, constatar de forma objetiva el grado de cumplimiento de los criterios establecidos (que se utilizarán como variables fundamentales) y las causas de no cumplimiento de los mismos. En la fase del diseño de estudios deberemos seguir los siguientes pasos que describimos brevemente:

1. **Objetivos:** Deben reflejar claramente "qué" y "para qué" hacemos el estudio. Es decir, cuál es la información que se quiere obtener para verificar y cuantificar el problema. Para ello, debe ser imperiosa la información proporcionada al sistema.
2. **Tipo de estudio:** Elección de la técnica de estudio que se va a seguir. Habitualmente se trata de estudios observacionales y descriptivos, es decir, sin asignación aleatoria. Este apartado lo discierne y analiza la propia IA, dando la información procedente de miles de estudios realizados y reportados a los foros científicos, tanto escritos como presentados en *meetings*.
3. **Población:**
 - **Población diana:** Población a la que se refieren los objetivos del estudio.
 - **Población de estudio:** Es el resultado de aplicar los criterios de inclusión y exclusión a la población diana y a la que podremos finalmente generalizar los resultados del estudio.
4. **Muestra:** Cuando sea necesario, se realizará el estudio sobre una muestra, teniendo en cuenta el tamaño requerido y la selección muestral. En cuanto al tamaño, dado que se trata de una estimación del cumplimiento del criterio, se trata de responder a la pregunta "¿cuántos individuos es necesario estudiar para poder estimar el parámetro deseado de la población, con un nivel de confianza determinado?". Para ello se recurre a las fórmulas habituales que aparecen en los tratados de estadística o a los programas informáticos específicos, pero que la IA lo ofrece sistemáticamente.
5. **Variables:** Es el aspecto o característica que queremos medir. Serán, por tanto, los criterios y las causas principales del problema. Pueden incorporarse otras variables que se consideren de interés, pero siempre procurando que el número de ellas sea el menor posible y adecuado.

6. **Recogida de información:** Se trata de seleccionar la fuente de información que permita obtener los datos necesarios y verificar su existencia. Las fuentes habituales son: documentales (sobre todo a partir de la Historia Clínica), observacionales, entrevistas y cuestionarios. Se incluye también en esta etapa la planificación de la técnica de registro con la elaboración de una hoja para la recogida de datos. La IA utiliza todo lo que tenga a su alcance.
7. **Asignación de responsables y previsión de recursos humanos y técnicos necesarios:** Es conveniente prever los recursos necesarios en cuanto a profesionales y material, así como el responsable de la realización del estudio.
8. **Análisis de resultados:** Una vez procesados los datos obtenidos, hay que extraer la información necesaria de los resultados a fin de responder a los objetivos del estudio. La estadística como método de razonamiento nos permitirá interpretar unos datos cuyo carácter esencial es la variabilidad, pudiendo establecer conclusiones relacionadas con la población a partir de los resultados obtenidos en las muestras. Habitualmente se realizan pruebas de conformidad, comparando los resultados obtenidos con los estándares establecidos. Cuando se trata de reevaluaciones, se compara además con resultados anteriores (siempre teniendo en cuenta que no se trata de poblaciones o series exactamente comparables). Es conveniente el uso del intervalo de confianza de los resultados, sobre todo cuando el número de casos revisados es inferior al tamaño muestral requerido (es decir, contamos con una muestra pequeña). En estos casos, los límites del intervalo de confianza nos permitirán saber entre qué valores se sitúa el auténtico valor de la población y, por tanto, saber cuándo NO cumplimos el estándar. Con esta información estaremos en condiciones de proponer acciones que respondan a la realidad y actúen sobre los déficits de calidad y sus causas. Con la utilización de las herramientas de la IA, estos procesos pueden optimizarse mediante los algoritmos predictivos y con datos en tiempo real. Es necesario pensar en todo momento que el acceso a las grandes bases de datos (internos o externos) será la herramienta ideal.

Análisis de Acciones de Mejora

Los resultados obtenidos en la valoración del cumplimiento o no de los criterios (juicios de buena práctica) nos permitirán acotar el problema y nos facilitarán determinar sus causas.

Los criterios en los que se obtienen unos resultados iguales o supraestándar son descartados, dado que estos resultados nos están demostrando que no son parte del problema.

Por lo tanto, la discusión de las causas y soluciones del problema se centrará en el estudio de aquellos criterios en los que se haya obtenido un resultado por debajo del estándar definido.

En el análisis de estas causas podemos evidenciar que algunas de ellas son suficientemente complejas como para determinar la necesidad de realizar un estudio concreto e individual sobre las mismas, para poder detectar sus causas profundas. En otros casos, la detección de las mismas nos permitirá planificar las soluciones pertinentes. Todo ello está sujeto a los resultados que informa la IA diseñada de manera adecuada. Tengamos presente que actualmente ya existen programas, o mejor dicho, acciones que se proponen por parte del intercambio de opiniones con las fuentes de información de la IA, incluso incorporando posibles soluciones a aplicar si los algoritmos iniciales ya han sido definidos para tal fin.

A grandes rasgos, podemos clasificar las causas en tres grandes grupos:

- Causas organizativas.
- Causas de falta de formación.
- Causas de actitud.

Cada una de ellas requerirá una solución diferente en función del déficit detectado. Esto es particularmente importante porque frecuentemente se observa que las soluciones propuestas por los diferentes grupos de trabajo tienen poco que ver con las causas establecidas del problema. Las causas organizativas requieren cambios en el sistema de organización: redistribución de tareas, cambios de plantilla, cambios en el sistema de trabajo, circuitos, etc. Los problemas debidos a temas de formación pueden solventarse con formación

continuada, individual o de grupo, visitas a otros centros, protocolos, etc. Los problemas de actitud requieren un análisis en profundidad y pueden modificarse con cambios en la cultura del centro o del equipo, potenciación de los clientes internos, sistemas de incentivos, etc. Todo ello estará definido con las estrategias sugeridas por la IA. Sin embargo, podemos aplicar, si es necesario, la técnica del *brainstorming* o la nominal de grupo para poder recoger todas las posibles soluciones que planteen los miembros del equipo de mejora, quienes tendrán acceso a las informaciones que aparecen cada día de las posibilidades de la IA, lo que provoca la aparición de nuevas nomenclaturas, como cerebros informáticos, inteligencia cerebral, etc., que intentan acercar cada vez más la IA a los procesos que desarrollan los cerebros humanos.

Cuando estudiemos las posibles soluciones a cada una de las causas detectadas, deberemos tener en cuenta la posible existencia de:

- Restricciones ante la posibilidad de obtener nuevos recursos.
- Normas internas o externas a cumplir.
- Características de la cultura de la organización a respetar.

Estos factores pueden ser motivo de exclusión de posibles soluciones planteadas. Para poder determinar qué soluciones elegimos, entre la lista de posibles soluciones, podemos hacer una priorización en base a los siguientes criterios:

- Eficacia de la solución.
- Eficiencia de la solución.
- Factibilidad de la solución.
- Oportunidad de la solución.
- Aceptabilidad de la solución.

Con la IA, la reevaluación se convierte en un proceso continuo y automatizado, permitiendo monitorear el cumplimiento de los estándares de calidad en tiempo real y generar alertas cuando se detectan desviaciones.

Implementación de Acciones de Mejora: Estrategias de Cambio

Una vez decididas las acciones de mejora a proponer, debe plantearse la sistemática de implementación de las mismas.

Para realizar cualquier cambio se recomienda:

1. Llamar la atención sobre el problema.
2. Hacer que el mensaje sea comprensible.
3. Aceptación del mensaje.
4. Decidir la estrategia más adecuada.
5. Crear una actitud de cambio.
6. Crear una intención de cambio.
7. Cambiar la práctica.
8. Consolidar el cambio.

Esta sistemática de implementación irá estrechamente ligada con la planificación de diferentes estrategias para favorecer el cambio y tratar las resistencias que todo cambio provoca.

Por lo tanto, deberemos plantearnos:

- Acciones a tomar para favorecer el cambio, en general.
- Detección de posibles resistencias, motivos de las mismas y acciones concretas a tomar.

Sistemas de Monitorización

Un sistema de monitorización mide y evalúa, de forma periódica, aspectos relevantes de la asistencia, mediante el uso de indicadores de calidad, que constituyen la unidad básica de un sistema de monitorización. Ha de aceptarse que la IA lo hace sistemáticamente en los períodos que decide el responsable asistencial, de manera que tiene recogida la información de manera inmediata, pudiendo analizar las tendencias de los resultados y confirmar si las medidas correctoras han sido útiles o no.

Las situaciones en las que se puede iniciar un sistema de monitorización son:

- a) Identificar el nivel de calidad de un servicio, a partir de la selección de los aspectos más relevantes de este.
- b) A partir de los ciclos de evaluación y mejora de la calidad, cuando el sistema de trabajo adoptado ha sido el de “posibilidades de mejora”.
- c) También son útiles para el seguimiento de un sistema de objetivos o tras la implementación de una nueva actividad o diseño de un servicio.

Cualquiera de las vías de acceso a la monitorización tiene como fin último identificar problemas, situaciones mejorables o bien desviaciones, y los indicadores actúan como llamadas de atención o señales de alarma que nos advierten de esta posibilidad. Como puede verse, si todos estos requisitos son identificados, piensen que con esta información la IA, a través de los árboles y algoritmos pertinentes, pondrá en marcha las soluciones y su impacto, siendo medido al final para ver si hay algún dato mejorable, o bien que no existan sutilezas de estructura no evidenciables.

Un indicador es también un criterio de calidad, aunque muy específico, y por tanto le son aplicables todas las condiciones y características que se recomiendan en la construcción de criterios (aceptables, comprensibles, relevantes, medibles, etc.). Del mismo modo hablaremos de indicadores de estructura, proceso y resultado, en función del ámbito de la evaluación.

Dado que un indicador es un instrumento de medida que se utiliza de forma sistemática y cuyo resultado será tenido en cuenta en la gestión de calidad, tendremos que asegurarnos de que refleje la realidad.

Para ello hay que tener en cuenta 3 características o propiedades que debe reunir todo indicador:

1. **Validez:** Un indicador es válido cuando cumple el objetivo de identificar situaciones en que se podría mejorar la calidad de la asistencia. También se puede hablar de “validez aparente” (*face validity*), refiriéndonos al grado en que el indicador es inteligible. ¿Se entiende su sentido e importancia sin muchas explicaciones?
2. **Sensibilidad:** Cuando detecta TODOS los casos en que se produce una situación o problema real de calidad.
3. **Especificidad:** Cuando SOLO detecta aquellos casos en que existen problemas de calidad.

Estos aspectos deben ser tenidos en cuenta cuando se procede a la construcción y programación de indicadores, seleccionando aquellos con mayor nivel de validez, sensibilidad y especificidad. Hemos de tener presente que la IA utilizará esos datos para aprender de nuestras necesidades, siendo mucho más útil en el futuro, de ahí la trascendencia. Aquí hemos de pensar en el incremento de “expertez” que el propio sistema de la IA puede usar, para que cada resultado final vaya acompañado de las posibles soluciones, aplicables, no al final, sino durante el proceso de trabajo del sistema, controlado por la IA. Este hecho, tan significativo en estos momentos, provoca múltiples preguntas que los profesionales pueden hacerse, incluida una que empieza a imperar en ciertos ambientes, que consiste en asumir que la informática inteligente suplantará al propio profesional. Sin embargo, creo que cometeríamos un error si se estableciese una competencia en la que hay ganadores y perdedores. La IA no va por delante de nosotros; ella hace lo que los profesionales de la informática han decidido. Por lo tanto, no puede ir por delante del médico, pero tampoco puede ir por detrás, dado que no aportaría sus ventajas. Así que, la IA tiene que ir “cogida de la mano”, en un nivel

equiparable al profesional, y el profesional adquirir los “conocimientos” que le proporciona la “máquina”, y a su vez, los médicos, ir enseñando a la máquina a utilizar las lógicas propias de nuestra profesión.

Los pasos a seguir para diseñar un sistema de monitorización son los siguientes:

- Definir el proceso.
- Identificar aspectos más relevantes.
- Diseñar indicadores.
- Establecer estándares.
- Recoger y tabular.
- Comparar con estándares.
- Buscar causas.
- Identificar y poner en marcha medidas.
- Conseguir.
- Identificar problema u oportunidad de mejora.

Definir el Proceso

Consiste en especificar el ámbito de la asistencia que se someterá a monitorización. Conviene definir las actividades, profesionales, estructuras, circuitos, etc., que intervienen en el proceso. Esto nos garantiza que ningún aspecto importante susceptible de mejora será olvidado. Cuando se trata de un servicio, corresponde a la fase de dimensionado que intenta presentar un mapa completo de su realidad. Si el punto de partida es un ciclo de mejora, el proceso ya está definido en sí mismo. En cualquier caso, cuando la IA ha entrado en el circuito, ella misma utilizará los distintos árboles de información, ampliando de manera eficiente la calidad de todo el proceso asistencial.

Seleccionar los Aspectos más Relevantes

Se trata de priorizar los aspectos más importantes relacionados con el proceso definido. Podemos utilizar diferentes criterios de priorización como:

- Número de clientes afectados.
- Riesgo de la actividad para el paciente.
- Actividad identificada como problemática.

Diseñar y Construir los Indicadores Correspondientes

El indicador de calidad es la medida cuantitativa que se utiliza como guía para controlar y valorar la calidad de aspectos importantes de la práctica asistencial. Para la construcción de indicadores, es recomendable definir y considerar una serie de apartados propuestos inicialmente por la Joint Commission on Healthcare Organizations americana, los cuales serán una ayuda para seleccionar aquellos que reúnan las mejores características.

A continuación, recordemos nuevamente estos apartados y su significado:

- **Nombre del Indicador.**
- **Dimensión:** Característica o atributo de la atención asistencial para que esta sea considerada de calidad.
- **Justificación:** Utilidad del indicador como medida de la calidad. Se relaciona con la validez; es decir, ¿lo que vamos a medir tiene sentido?
- **Fórmula:** Expresión matemática que reflejará el resultado de la medición. De todas maneras, la IA ya lo hará por sistema. Habitualmente se expresa en forma de porcentaje, pero también puede hacerse como una media o número absoluto.

- **Explicación de términos:** Definición de aquellos aspectos del indicador que puedan ser ambiguos o sujetos a diversas interpretaciones. Ej. Si en el indicador se menciona la realización de un hemograma completo, habrá que especificar cuáles son los parámetros necesarios para que el hemograma pueda etiquetarse de completo.
- **Población:** Descripción de la unidad de estudio que va a ser objeto de medida. Puede referirse a pacientes, exploraciones, visitas, etc. En algunas ocasiones, será necesario introducir criterios de exclusión en la población así definida. Ej. Si queremos saber el nivel de utilización de la incisión de Pfannenstiel en las cesáreas, la población de referencia será el total de cesáreas realizadas, aunque de ellas deberán excluirse aquellas gestantes portadoras de una laparotomía media previa o en las que ha habido riesgo de muerte inminente del recién nacido. En estos casos no está indicado este tipo de incisión y, por tanto, no se trata de población tributaria de ser sometida a un Pfannenstiel. La inclusión de estas pacientes en el denominador se traduciría en una disminución falsa del nivel de utilización del Pfannenstiel. Al realizar la cuantificación del indicador, no siempre es necesario hacer la medición sobre la totalidad de la población definida. En estos casos se recurre a la revisión de una muestra.
- **Tipo:** Se refiere a la clasificación de indicadores según el enfoque de la evaluación. Se identifican como de estructura, proceso o resultado, siguiendo el mismo concepto que el expresado para los criterios.
- **Fuente de datos:** Define cuál será el origen de la información y la secuencia de obtención de datos necesaria para poder cuantificar el indicador. Es un aspecto importante, ya que el nivel de desarrollo de los sistemas informativos de cada centro puede condicionar la posibilidad o no de medir el indicador. En el presente trabajo, se ha obviado la especificación de este apartado, ya que el origen y manejo de la información será distinto en cada centro.
- **Estándar:** Refleja el nivel deseado de cumplimiento para el indicador. Nos referimos siempre a este apartado con la expresión “estándar orientativo”, dada la variabilidad de las fuentes bibliográficas consultadas, que no siempre coinciden o presentan un amplio intervalo de resultados. Cuando la variación es muy importante, se ha optado por no explicitar el estándar, al igual que cuando no se han encontrado referencias bibliográficas suficientemente contrastadas, usando la expresión “No establecido”. En otras ocasiones, el estándar se ha situado en el 100% o 0% cuando se considera que se trata de asegurar que lo básico se está haciendo bien. En cualquier caso, la IA puede realizar un ejercicio comparativo entre lo obtenido en un centro y los aportados por otras unidades con semejantes patrones de actividad clínica, hecho que además hace que ella aprenda para la próxima ocasión. El acceso a grandes bases de datos, como se ha explicado anteriormente, mejora el resultado esperado, incluso con los *benchmarking* correspondientes.
- **Comentarios:** Este apartado se reserva para las reflexiones sobre la validez del indicador o para poner de manifiesto posibles factores de confusión que deberán ser tenidos en cuenta a la hora de interpretar los resultados. Ej: Profilaxis de la anemia durante la gestación. En este caso, el resultado del indicador puede estar afectado por el nivel de cumplimiento terapéutico de la paciente.

A veces la actuación es clara y evidente, pero otras veces será necesario iniciar los pasos del ciclo de evaluación si no conocemos las causas del problema. He aquí, pues, el momento en que un sistema de monitorización se complementa con el ciclo de evaluación para obtener los resultados previstos por un programa de evaluación y mejora de la calidad. Una vez identificadas las causas, propuestas las acciones de mejora e implementadas estas, se continúa con la medición sistemática del indicador, observando si ello ha producido las mejoras deseadas. En este caso, diremos que tenemos de nuevo el indicador “bajo control”. De todas maneras, todo esto que estamos mencionando lo hará la infraestructura de la IA, en la medida que esté diseñada en la dirección conveniente.

Herramientas De Los Programas De Calidad Asistencial

Las herramientas de los programas de calidad asistencial son instrumentos y metodologías diseñados para mejorar continuamente la atención al paciente, asegurar la seguridad clínica y optimizar los procesos sanitarios. A continuación, se presenta una lista estructurada de las principales herramientas que se utilizan en estos programas:

1. Indicadores de calidad:

- Estructura: número de profesionales, tecnología disponible, etc.
- Proceso: cumplimiento de guías clínicas, tiempos de espera, etc.
- Resultado: tasas de mortalidad, complicaciones, satisfacción del paciente.

2. **Auditorías clínicas:** Revisión sistemática de historias clínicas y procesos asistenciales para evaluar
3. la conformidad con estándares definidos.
4. **Protocolos y guías clínicas:** Documentos basados en la evidencia que orientan la práctica clínica para asegurar homogeneidad y efectividad.
5. **Círculos de calidad / Grupos de mejora:** Equipos multidisciplinares que identifican problemas asistenciales y proponen soluciones concretas.
6. **Revisión de eventos adversos y análisis de causas raíz (ACR):** Investigación estructurada de incidentes que comprometen la seguridad del paciente para prevenir su repetición.
7. **Encuestas de satisfacción:** Instrumentos para recoger la percepción del paciente sobre la atención recibida.
8. **Benchmarking:** Comparación de indicadores de calidad con otras instituciones para identificar oportunidades de mejora.
9. **Mapas de procesos y flujogramas:** Diagramas visuales que permiten entender y optimizar los circuitos asistenciales.
10. **Cuadros de mando (Dashboards):** Herramientas visuales para monitorear en tiempo real el desempeño de los servicios.
11. **Formación continua y evaluación de competencias:** Planes de actualización del personal para garantizar que se mantiene la calidad asistencial.
12. **Gestión por procesos:** Enfoque que analiza transversalmente la atención para evitar silos organizativos y mejorar la coordinación.
13. **Planes de mejora continua (PDCA: Plan-Do-Check-Act):** Ciclos iterativos para identificar, implantar, evaluar y ajustar intervenciones de mejora.
14. **Notificación voluntaria de incidentes:** Sistemas internos para que el personal reporte errores o situaciones de riesgo sin sanciones.

Las herramientas de inteligencia artificial (IA) están desempeñando un papel clave en los programas de calidad asistencial, especialmente en hospitales y entornos clínicos (como el Hospital Quirónsalud de Barcelona).

Herramientas De Calidad Asistencial En Obstetricia

Ejemplo de Construcción de un Algoritmo: Búsqueda en una Lista

Supongamos que quieres crear un algoritmo para buscar un número específico en una lista de números. Aquí te muestro cómo podrías hacerlo siguiendo estos pasos:

1. **Definición del Problema:** Necesitamos encontrar un número en una lista y devolver su posición si está presente, o indicar que no se encontró.

2. Planificación y Pseudocódigo:

- **Entradas:** Lista de números L y número x a buscar.
- **Salida:** Posición de x en la lista, o un mensaje diciendo que no se encontró.

Pseudocódigo:

plaintext

```
CopiarEditar
Para cada elemento en la lista L:
    Si el elemento es igual a x:
        Devolver la posición
Si x no está en la lista:
    Devolver "No se encontró"
```

3. Escritura en Código (Python):

python

```
CopiarEditar
def buscar_numero (lista, x):
    for i in range(len(lista)):
        if lista[i] == x:
            return f"Encontrado en la posición {i}"
    return "No se encontró"
```

4. Verificación y Pruebas:

Prueba con listas y números variados para verificar que el código funcione en cada caso.

Ejemplo:

python

```
CopiarEditar
lista = [3, 5, 7, 9]
print(buscar_numero(lista, 7)) # Debería devolver "Encontrado en la posición 2"
```

5. Optimización (si es necesario):

Si la lista está ordenada, se podría optimizar utilizando una búsqueda binaria en lugar de una búsqueda lineal, lo que reduciría la complejidad a $O(\log n)$ en lugar de $O(n)$.

Siguiendo estos pasos, puedes construir algoritmos efectivos para resolver una amplia variedad de problemas, ya sea en programación o en otros contextos donde sea necesario un proceso lógico.

Plan De Implementación De Un Programa De Control De Calidad Asistencial

Duración: 6-12 meses

Objetivo: Garantizar y mejorar la calidad asistencial mediante la medición, análisis y optimización de procesos en salud.

Fase 1: Diagnóstico Inicial (Mes 1-2)

- **Acciones clave**

- Evaluación de protocolos clínicos y operativos.
- Análisis de incidentes y eventos adversos.
- Encuestas a pacientes y profesionales de salud.
- Evaluación del cumplimiento de normativas (ISO 9001, Joint Commission).

- **Herramientas y Recursos:**

- Cuestionarios y entrevistas estructuradas.
- Revisión de historias clínicas.
- Sistemas de gestión de calidad.

- **Resultado esperado:**

- Informe con brechas de calidad y áreas de mejora.

Fase 2: Definición de Indicadores Clave (KPIs) (Mes 2-3)

- **Acciones clave:**

- Establecimiento de métricas clave para medir la calidad asistencial:

- **Seguridad del paciente:** Tasa de infecciones nosocomiales, errores de medicación.
- **Eficiencia:** Tiempo de espera en urgencias, duración promedio de hospitalización.
- **Satisfacción del paciente:** Niveles de satisfacción y quejas.
- **Efectividad clínica:** Mortalidad ajustada por riesgo, tasa de reingresos hospitalarios.

- Definición de metodología de recolección y análisis de datos.

- **Herramientas y Recursos:**

- Software de análisis de datos (Excel, Power BI, Tableau).
- Bases de datos hospitalarias.

- **Resultado esperado:**

- Lista de indicadores con métodos de medición y objetivos específicos.

Fase 3: Implementación de Monitoreo y Control (Mes 4-6)

- **Acciones clave:**

- Desarrollo de *dashboard* para visualización de indicadores.
- Implementación de IA para detección temprana de riesgos clínicos.
- Auditorías internas periódicas y comités de revisión de calidad asistencial.
- Establecimiento de alertas automáticas para eventos críticos.

- **Herramientas y Recursos:**

- Power BI, Tableau, Google Data Studio.
- Modelos de *machine learning* para análisis predictivo.
- Sistemas de gestión hospitalaria (HIS, EHR).

- **Resultado esperado:**

- Plataforma de monitoreo en tiempo real con alertas automáticas.

Fase 4: Intervención y Mejora Continua (Mes 6-12)

- **Acciones clave:**

- Implementación de estrategias para corregir deficiencias detectadas.
- Capacitación al personal en mejores prácticas clínicas.
- Aplicación de metodologías *Lean Healthcare* y *Six Sigma*.
- Evaluación del impacto de las medidas implementadas.

- **Herramientas y Recursos:**

- Talleres de formación.
- Protocolos de mejora continua.
- Análisis de datos para ajuste de estrategias.

- **Resultado esperado:**

- Mejora sostenida en los indicadores de calidad.

Beneficios del Programa

- Reducción de errores clínicos y eventos adversos.
- Mayor satisfacción y seguridad del paciente.
- Optimización de recursos y reducción de costos.
- Mejor cumplimiento de estándares de calidad.

Siguientes Pasos

- Adaptación del programa a una institución específica.
- Implementación de herramientas tecnológicas de seguimiento.
- Integración de IA para predicción de riesgos en salud.

Proyecto Piloto: "Ia Para Detección Temprana De Riesgo De Sepsis Neonatal"

Objetivo: Desarrollar o implementar un modelo de IA que identifique recién nacidos con alto riesgo de desarrollar sepsis en las primeras horas/días de vida, utilizando datos clínicos disponibles de forma rutinaria.

Justificación:

- La sepsis neonatal tiene alta morbilidad y mortalidad, y su diagnóstico precoz es difícil.
- Las manifestaciones clínicas iniciales son inespecíficas.

- Un sistema basado en IA puede detectar patrones sutiles en constantes, analíticas y antecedentes que predican el riesgo de sepsis antes de que sea clínicamente evidente.

Variables que puede usar el modelo de IA:

- **Datos maternos:** Fiebre intraparto, corioamnionitis, colonización por estreptococo, duración de rotura de membranas.
- **Datos neonatales:** Apgar, peso, edad gestacional, tipo de parto.
- **Signos vitales:** Frecuencia cardíaca, temperatura, frecuencia respiratoria.
- **Analíticas tempranas:** PCR, leucocitos, procalcitonina.

¿Cómo funcionaría?

- **Recolección de datos:** Anónimos y estructurados, de recién nacidos ingresados.
- **Entrenamiento del modelo:** Usando *machine learning* (por ejemplo, árboles de decisión, XGBoost o redes neuronales simples).
- **Validación:** Evaluar precisión, sensibilidad, especificidad.
- **Implementación inicial (modo sombra):** El sistema da alertas de riesgo, pero sin intervenir aún en la clínica.
- **Evaluación del impacto clínico:** ¿Se mejora el tiempo de detección y tratamiento? ¿Se reducen las complicaciones?

Posibles Beneficios

- Diagnóstico más temprano de sepsis.
- Uso más racional de antibióticos.
- Menor estancia hospitalaria.
- Mejora de la seguridad del paciente.

¿Qué necesitas para empezar?

Recurso	Descripción
Datos	Hojas clínicas neonatales y maternas estructuradas (mínimo 200-500 casos).
Soporte técnico	Colaboración con ingeniero de datos o bioinformático.
Comité ético	Aprobación para uso de datos anónimos.
Software	Python (scikit-learn, pandas) o plataforma como DataRobot, Google AutoML.

Proyecto: Diagnóstico De Neumonía Con Aprendizaje Federado

Objetivo: Entrenar un modelo de *deep learning* para detectar neumonía en radiografías pulmonares sin compartir datos entre hospitales.

Tecnologías y Herramientas:

- Python
- TensorFlow Federated (TFF)
- PyTorch + Flower (alternativa flexible)
- Dataset: Chest X-Ray (COVID-19, neumonía, normal)
- Google Colab/Servidor local para entrenamiento y simulación de hospitales

Fases del Proyecto

1. Recopilación y preprocesamiento de datos:

- Usaremos el *dataset* público de radiografías Chest X-Ray (puede descargarse de Kaggle).
- Dividimos los datos en diferentes nodos (hospitales simulados).
- **Pasos clave:**
 - Cargar *dataset* y visualizar imágenes.
 - Aplicar preprocesamiento (escalado, normalización, aumento de datos).
 - Separar datos en hospitales virtuales.

2. Construcción del modelo de IA:

- Usaremos una red neuronal convolucional (CNN) basada en ResNet o EfficientNet.
- **Pasos clave:**
 - Definir arquitectura del modelo en TensorFlow o PyTorch.
 - Entrenar y evaluar en datos locales (por hospital).

3. Implementación de Aprendizaje Federado:

- En lugar de enviar los datos a un servidor central, cada hospital entrena localmente y solo envía los parámetros del modelo.
- **Pasos clave:**
 - Implementar TensorFlow Federated (TFF) o Flower.
 - Definir un servidor central para la agregación de modelos.
 - Ejecutar rondas de federación y evaluar mejoras.

4. Evaluación y optimización:

- Comparamos resultados del aprendizaje federado vs. centralizado.
- Ajustamos hiperparámetros para mejorar precisión.
- Analizamos ventajas en privacidad y eficiencia.

Resultados Esperados

- Modelo de IA capaz de detectar neumonía en radiografías.
- Preservación de privacidad sin necesidad de compartir datos.
- Comparación de rendimiento entre modelos federados y centralizados.

¿Cómo Empezar?

- **Paso 1:** Descarga y analiza el *dataset*.
- **Paso 2:** Configura hospitales simulados.
- **Paso 3:** Implementa una CNN para diagnóstico.
- **Paso 4:** Integra aprendizaje federado.
- **Paso 5:** Evalúa y optimiza el modelo.

Papel De Los Programas De Calidad Asistencial: Acreditaciones

Los programas de calidad asistencial juegan un papel clave en la mejora de la atención sanitaria, garantizando seguridad del paciente, eficiencia operativa y cumplimiento de estándares internacionales. Sus funciones clave incluyen:

1. Seguridad del paciente:

- Reducción de errores médicos y eventos adversos.
- Implementación de protocolos de atención basada en evidencia.
- Monitoreo y control de infecciones nosocomiales.

2. Eficiencia y optimización de recursos:

- Disminución de tiempos de espera y mejor uso de infraestructura.
- Gestión eficiente del personal y equipamiento.
- Reducción de costos sin comprometer la calidad asistencial.

3. Satisfacción del paciente y humanización del servicio:

- Evaluación de la experiencia del paciente.
- Implementación de estrategias para mejorar la comunicación médico-paciente.
- Medición de satisfacción a través de encuestas y *feedback*.

4. Cumplimiento normativo y acreditaciones:

- Asegurar el cumplimiento de normativas nacionales e internacionales.
- Facilitar la obtención de certificaciones de calidad.
- Implementación de auditorías internas y externas.

Glosario de Inteligencia Artificial (IA)

A

- **Algoritmo:** Conjunto de instrucciones que las máquinas siguen para resolver un problema.
- **Análisis Predictivo:** Uso de modelos para anticipar resultados futuros a partir de datos históricos.
- **Aprendizaje Automático (Machine Learning, ML):** Rama de la IA donde los sistemas aprenden patrones a partir de datos sin ser programados explícitamente.
- **Aprendizaje Profundo (Deep Learning, DL):** Subcampo del ML que utiliza redes neuronales con muchas capas para tareas complejas (ej., visión, lenguaje).

B

- **Batch (Lote):** Conjunto de ejemplos procesados simultáneamente durante el entrenamiento de un modelo.
- **Bias (Sesgo):** Distorsión en los resultados de un modelo, debida a datos no representativos o a prejuicios inherentes en estos.
- **Big Data:** Conjuntos de datos masivos y heterogéneos que requieren técnicas avanzadas de procesamiento.

C

- **Chatbot:** Programa que simula una conversación con un humano.
- **Clasificación:** Tarea en la que un modelo asigna categorías a los datos (ej., benigno/maligno).

- **Computación en la Nube (Cloud Computing):** Uso de recursos de procesamiento y almacenamiento a través de internet.
- **Convolución:** Operación matemática empleada en redes neuronales convolucionales (CNN) para el análisis de imágenes.

D

- **Data Mining (Minería de Datos):** Extracción de patrones ocultos en grandes volúmenes de datos.
- **Dataset (Conjunto de Datos):** Colección organizada de información utilizada para entrenar y evaluar modelos.
- **Detección de Anomalías:** Identificación de patrones inusuales o fuera de lo esperado en los datos.

E

- **Entrenamiento:** Proceso mediante el cual un modelo ajusta sus parámetros a partir de ejemplos.
- **Época (Epoch):** Una pasada completa por todo el conjunto de datos de entrenamiento.
- **Etiquetado de Datos:** Proceso de asignar etiquetas (clases, categorías, etc.) a datos para entrenar modelos supervisados.
- **Explainable AI (XAI):** Técnicas que permiten entender cómo y por qué un modelo toma decisiones.
- **Explicabilidad:** Capacidad de un modelo de IA para explicar sus decisiones o resultados de manera comprensible.

F

- **Feature (Característica):** Variable o atributo medido en los datos que el modelo utiliza para aprender.
- **Fine-tuning (Ajuste Fino):** Ajustar un modelo previamente entrenado en una tarea a un nuevo conjunto de datos o tarea específica.

G

- **Generative AI (IA Generativa):** Modelos capaces de crear contenido nuevo (texto, imágenes, audio).
- **Gradient Descent (Descenso de Gradiente):** Algoritmo de optimización utilizado para ajustar los parámetros de un modelo.

H

- **Heurística:** Método aproximado para resolver problemas cuando no hay soluciones exactas.
- **Hiperparámetros:** Configuraciones externas de un modelo (ej., número de capas, tasa de aprendizaje).

I

- **Inferencia:** Uso de un modelo ya entrenado para hacer predicciones sobre nuevos datos.
- **Inteligencia Artificial (IA):** Sistemas capaces de imitar funciones cognitivas humanas (razonamiento, aprendizaje, percepción).
- **Interpretabilidad:** Grado en el que un humano puede entender cómo un modelo de IA toma decisiones.

L

- **Label (Etiqueta):** Valor correcto asociado a un dato en el entrenamiento (ej., diagnóstico confirmado).
- **Lenguaje Natural (PLN):** Campo de la IA que procesa y entiende el lenguaje humano.

M

- **Machine Learning (ML):** Ver Aprendizaje Automático.
- **Matriz de Confusión:** Herramienta para evaluar el rendimiento de un modelo de clasificación.
- **Modelo:** Representación matemática entrenada para predecir o clasificar.

N

- **Neuronas Artificiales:** Unidades básicas en una red neuronal que procesan información, inspiradas en el cerebro humano.
- **Normalización:** Ajuste de datos para que todas las variables tengan escalas comparables.

O

- **Optimización:** Ajuste de parámetros para mejorar el rendimiento del modelo.
- **Overfitting (Sobreajuste):** Cuando un modelo aprende demasiado bien los datos de entrenamiento y falla al generalizar a datos nuevos.

P

- **Parámetros:** Valores internos de un modelo que se ajustan durante el entrenamiento.
- **Predicción:** Resultado generado por el modelo a partir de datos nuevos.
- **Prompt:** Instrucción o entrada textual que se da a un modelo de lenguaje para obtener una respuesta.

R

- **Red Neuronal Artificial (RNA):** Modelo inspirado en el cerebro humano para detectar patrones.
- **Regresión:** Tarea donde se predice un valor numérico continuo.
- **Reinforcement Learning (Aprendizaje por Refuerzo):** Entrenamiento basado en recompensas y penalizaciones.

S

- **Semi-supervised Learning:** Combinación de datos etiquetados y no etiquetados.
- **Sesgo (Bias):** Ver "Bias".
- **Sistema Experto:** Sistema de IA diseñado para emular la toma de decisiones de un experto humano en un área específica.
- **Speech Recognition (Reconocimiento de Voz):** Conversión de audio en texto.
- **Supervised Learning (Aprendizaje Supervisado):** El modelo aprende con ejemplos que tienen etiquetas.

T

- **Token:** Unidad mínima de texto procesada por un modelo de lenguaje.
- **Transfer Learning (Aprendizaje Transferido):** Uso de un modelo entrenado previamente en una nueva tarea.
- **Transformers:** Arquitectura de redes neuronales clave en modelos de lenguaje y visión.

U

- **Underfitting (Subajuste):** Cuando un modelo es demasiado simple y no logra aprender los patrones de los datos, incluso en el entrenamiento.
- **Unsupervised Learning (Aprendizaje No Supervisado):** El modelo encuentra patrones en datos sin etiquetas (ej., *clustering*).

V

- **Validación Cruzada:** Método para evaluar la capacidad de generalización de un modelo.
- **Visión por Computadora:** Rama de la IA que permite interpretar imágenes y videos.

W

- **Weight (Peso):** Valor numérico ajustable que define la fuerza de la conexión entre neuronas en una red neuronal.

Glosario de Terminología en IA

Conceptos Generales

- **Inteligencia Artificial (IA):** Campo de estudio que busca crear sistemas capaces de realizar tareas que normalmente requieren inteligencia humana.
- **Aprendizaje Automático (Machine Learning):** Subcampo de la IA que permite a las máquinas aprender a partir de datos sin ser explícitamente programadas.
- **Red Neuronal Artificial:** Modelo inspirado en el cerebro humano, compuesto por "neuronas" conectadas que procesan información.
- **Deep Learning (Aprendizaje Profundo):** Tipo de aprendizaje automático que utiliza redes neuronales con muchas capas para detectar patrones complejos.

Datos y Procesamiento

- **Dataset (Conjunto de Datos):** Colección estructurada de datos usada para entrenar modelos de IA.
- **Preprocesamiento:** Transformación de datos crudos en un formato adecuado para el entrenamiento.
- **Overfitting (Sobreajuste):** Cuando un modelo aprende demasiado bien los datos de entrenamiento, pero falla al generalizar en datos nuevos.
- **Underfitting (Subajuste):** Cuando un modelo no logra capturar la relación entre los datos, ni siquiera en el entrenamiento.

Modelos y Algoritmos

- **Modelo:** Representación matemática que aprende patrones a partir de datos.
- **Algoritmo:** Conjunto de reglas o instrucciones que el modelo sigue para aprender.
- **Regresión:** Técnica para predecir valores numéricos continuos.
- **Clasificación:** Técnica para asignar categorías o etiquetas a datos.

Evaluación y Métricas

- **Precisión (Accuracy):** Porcentaje de predicciones correctas.
- **Recall (Sensibilidad):** Capacidad del modelo para detectar correctamente los casos positivos.
- **F1 Score:** Métrica que combina precisión y *recall* en un solo valor.
- **Validación Cruzada:** Técnica para evaluar el rendimiento de un modelo dividiendo los datos en múltiples subconjuntos.

IA Generativa

- **Modelo Generativo:** Modelo que puede crear contenido nuevo (texto, imágenes, audio) a partir de patrones aprendidos.
- **Transformers:** Arquitectura de red neuronal que revolucionó el procesamiento de lenguaje natural (como la que utilizo).
- **Prompt:** Entrada que se le da a un modelo generativo para obtener una respuesta.
- **Fine-tuning (Ajuste Fino):** Proceso de entrenar un modelo preexistente con datos específicos para tareas concretas.

Ética y Seguridad

- **Sesgo Algorítmico:** Cuando un modelo refleja prejuicios presentes en los datos de entrenamiento.
- **Explicabilidad:** Capacidad de entender cómo y por qué un modelo toma decisiones.
- **Privacidad de Datos:** Protección de la información personal usada para entrenar modelos.

Glosario de IA en Medicina

Diagnóstico y Tratamiento

- **Diagnóstico Asistido por IA:** Uso de algoritmos para identificar enfermedades a partir de imágenes médicas, síntomas o historiales clínicos.
- **Radiología Computacional:** Aplicación de IA para analizar radiografías, tomografías y resonancias magnéticas.

- **Medicina Personalizada:** Uso de IA para adaptar tratamientos según el perfil genético y clínico del paciente.
- **Triage Automatizado:** Sistemas que priorizan pacientes según la gravedad de sus síntomas usando modelos predictivos.

Datos Biomédicos

- **Historia Clínica Electrónica (HCE):** Registro digital de la información médica de un paciente, usado como fuente de datos para entrenar modelos.
- **Omics Data:** Datos genómicos, proteómicos o metabolómicos que permiten entender enfermedades a nivel molecular.
- **Análisis Predictivo:** Uso de IA para anticipar complicaciones, brotes o evolución de enfermedades.

Modelos y Algoritmos

- **Procesamiento de Lenguaje Natural (PLN):** Tecnología que permite a la IA entender y generar texto médico, como notas clínicas o informes.
- **Redes Neuronales Convolucionales (CNN):** Especializadas en el análisis de imágenes médicas.
- **Modelos de Clasificación:** Algoritmos que asignan etiquetas como “benigno” o “maligno” a lesiones o tumores.
- **Modelos Generativos:** Capaces de simular datos médicos, como imágenes sintéticas para entrenamiento sin comprometer la privacidad.

Evaluación y Ética

- **Sensibilidad y Especificidad:** Métricas clave para evaluar la precisión de un modelo diagnóstico.
- **Validación Clínica:** Proceso de probar modelos en entornos reales antes de su adopción.
- **Consentimiento Informado Automatizado:** Sistemas que explican tratamientos o estudios clínicos usando IA.
- **Privacidad de Datos Médicos:** Normativas como GDPR o HIPAA que regulan el uso de datos sensibles en IA.

Aplicaciones Clínicas

- **Chatbots Médicos:** Asistentes virtuales que responden preguntas de pacientes o ayudan en el seguimiento.
- **Robótica Quirúrgica Asistida por IA:** Robots que ayudan en cirugías con precisión milimétrica.
- **Monitorización Remota:** IA que analiza datos de dispositivos portátiles para detectar signos de alerta.
- **Farmacogenómica:** Uso de IA para predecir cómo responderá un paciente a ciertos medicamentos según su genética.

12. REFERENCIAS

Referencias

- Adejumo P, Thangaraj PM, Dhingra LS, Aminorroaya A, Zhou X, Brandt C, et al. Natural language processing of clinical documentation to assess functional status in patients with heart failure. *JAMA Netw Open*. 2024;7(11): e2443925-e2443925.
- Afsharizadeh M, Ebrahimpour-Komleh H, Bagheri A. Automatic text summarization of COVID-19 research articles using recurrent neural networks and coreference resolution. *Front Biomed Technol*. 2020.
- Agencia Española de Protección de Datos. Recomendaciones para una inteligencia artificial confiable. Madrid: AEPD; 2020.
- Agrawal R, Srikant R. Fast algorithms for mining association rules. En: *Proceedings of the 20th International Conference on Very Large Data Bases, VLDB*; Santiago, Chile. 1994. p. 487-99.
- Akmal S, Tsoi E, Howard R, Osei E, Nicolaides KH. Investigation of occiput posterior delivery by intrapartum sonography. *Ultrasound Obstet Gynecol*. 2004;24(4):425-8.
- AlSaad R, Elhenidy A, Tabassum A, Odeh N, AboArqoub E, Odeh A, et al. Artificial Intelligence in Gestational Diabetes Care: A Systematic Review. *J Diabetes Sci Technol*. 2025;19322968251355967.
- Alsolamy S, Fayadh M, Qamar S, Siddiqui T, Chen X, Huang J, et al. Machine learning and deep learning methods for fetal health assessment from cardiotocography: A systematic review. *Comput Biol Med*. 2021;133: 104360.
- Amann J, Blasimme A, Vayena E, Frey D, Madai VI, Precise Qc. Explainability for artificial intelligence in healthcare: a multidisciplinary perspective. *BMC Med Inform Decis Mak*. 2020;20(1):310.
- American Diabetes Association Professional Practice C. 2. Diagnosis and Classification of Diabetes: Standards of Care in Diabetes-2025. *Diabetes Care*. 2025;48(1 Suppl 1): S27-49.
- Andrade Júnior VL, França MS, Santos RAF, Hatanaka AR, Cruz JJ, Hamamoto TEK, et al. A new model based on artificial intelligence to screening preterm birth. *J Matern Fetal Neonatal Med*. 2023;36(2):2241100.
- Andrey P, Boudier T. Adaptive active contours (snakes) for the segmentation of complex structures in biological images. *ImageJ Conf*. 2006.
- Arnaout R, Curran L, Zhao Y, Levine JC, Chinn E, Moon-Grady AJ. An ensemble of neural networks provides expert-level prenatal detection of complex congenital heart disease. *Nat Med*. 2021;27(5):882-91.
- Athalye C, Van Nisselrooij A, Rizvi S, Haak MC, Moon-Grady AJ, Arnaout R. Deep-learning model for prenatal congenital heart disease screening generalizes to community setting and outperforms clinical detection. *Ultrasound Obstet Gynecol*. 2024;63(1):44-52.
- Azad R, Kazerouni A, Heidari M, Aghdam EK, Molaei A, Jia Y, et al. Advances in medical image analysis with vision transformers: A comprehensive review. *arXiv preprint arXiv:2301.03505*. 2023. Disponible en: <https://arxiv.org/abs/2301.03505>
- Badlani S, Aditya T, Dave M, Chaudhari S. Multilingual healthcare chatbot using machine learning. En: *2021 2nd International Conference for Emerging Technology (INCET)*. IEEE; 2021. p. 1-6.
- Baeza-Yates R, Ribeiro-Neto B. Modern information retrieval. Vol. 463. New York: ACM press; 1999.
- Balaban B, Brison D, Calderón G, Catt J, Conaghan J, Cowan L, et al. The Istanbul consensus workshop on embryo assessment: Proceedings of an expert meeting. *Hum Reprod*. 2011;26(6):1270-83.
- Banik D, Paul R, Rathore RS, Jhaveri RH. Improving Access to Medical Information for Multilingual Patients using Pipelined Ensemble Average based Machine Translation. *ACM Trans Asian Low-Resour Lang Inf Process*. 2023.
- Bank D, Koenigstein N, Giryas R. Autoencoders. En: *Machine learning for data science handbook: data mining and knowledge discovery handbook*. 2023. p. 353-74.
- Barnes J, Brendel M, Gao VR, Rajendran S, Kim J, Li Q, et al. A non-invasive artificial intelligence approach for the prediction of human blastocyst ploidy: a retrospective model development and validation study. *Lancet Digit Health*. 2023;5(1): e28-40.
- Bashir Z, Lin M, Feragen A, Mikolaj K, Taksøe-Vester C, Christensen AN, et al. Clinical validation of explainable AI for fetal growth scans through multi-level, cross-institutional prospective end-user evaluation. *Sci Rep*. 2025;15(1):2074.
- Batra H, Jain A, Bisht G, Srivastava K, Bharadwaj M, Bajaj D, et al. CoVShorts: news summarization application based on deep NLP transformers for SARS-CoV-2. En: *2021 9th International conference on reliability, infocom technologies and optimization (Trends and Future Directions) (ICRITO)*. IEEE; 2021. p. 1-6.
- Baumgartner CF, Kamnitsas K, Matthew J, Fletcher TP, Smith A, Koch LM, et al. SonoNet: real-time detection and localisation of fetal standard scan planes in freehand ultrasound. *IEEE Trans Med Imaging*. 2017;36(11):2204-15.
- Beam AL, Kohane IS. Big data and machine learning in health care. *JAMA*. 2018;319(13):1317-8.

- Beam AL, Manrai AK, Ghassemi M. Challenges to the reproducibility of machine learning models in health care. *JAMA*. 2020;323(4):305–6.
- Bejnordi BE, Veta M, Van Diest PJ, Van Ginneken B, Karssemeijer N, Litjens G, et al. Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. *JAMA*. 2017;318(22):2199–210.
- Beksac MS, Tanacan A, Bacak HO, Leblebicioglu K. Computerized prediction system for the route of delivery (vaginal birth versus cesarean section). *J Perinat Med*. 2018;46(8):881–4.
- Belaghi RA. Prediction of preterm birth in multiparous women using logistic regression and machine learning approaches. *Sci Rep*. 2024;14(1):21967.
- Belcic I, Stryker C. What is supervised learning? IBM. 2024 dic 28 [citado 2024 may 15]. Disponible en: <https://www.ibm.com/think/topics/supervised-learning>
- Bellamy L, Casas JP, Hingorani AD, Williams D. Type 2 diabetes mellitus after gestational diabetes: a systematic review and meta-analysis. *Lancet*. 2009;373(9677):1773–9.
- Berard A, Kim ZM, Nikoulina V, Park EL, Gallé M. A Multilingual Neural Machine Translation Model for Biomedical Data. En: Workshop on NLP for COVID-19 (Part 2) at EMNLP. 2020.
- Bernard O, Lalande A, Zotti C, Cervenansky F, Yang X, Heng PA, et al. Deep learning techniques for automatic MRI cardiac multi-structures segmentation and diagnosis: is the problem solved? *IEEE Trans Med Imaging*. 2018;37(11):2514–25.
- Berrezueta S, Baldeon-Calisto M, Navarrete D, et al. Foundation Models for Medical Image Segmentation: A Literature Review. En: 2025 13th International Symposium on Digital Forensics and Security (ISDFS). IEEE; 2025:1–7.
- Bixby CJ, Miller B. Real-world use of an artificial intelligence–powered clinical decision support tool for ovarian stimulation. *FS Reports*. 2025;6(2):140–6.
- Bizzego A, Gabrielli L, Esposito G. Contributions of Artificial Intelligence to Obstetrics: A Review of Current State, Challenges, and Future Directions. *Healthcare (Basel)*. 2023;11(6):881.
- Bochkovskiy A, Wang CY, Liao HYM. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*. 2020.
- Brandão M, Mendes F, Martins M, et al. Revolutionizing Women's Health: A Comprehensive Review of Artificial Intelligence Advancements in Gynecology. *J Clin Med*. 2024;13(4):1061.
- Breiman L, Friedman J, Olshen RA, Stone CJ. Classification and Regression Trees. 1st ed. Chapman and Hall/CRC; 1984.
- Bülez A, Hansu K, Çağan ES, Şahin AR, Dokumacı HÖ. Artificial Intelligence in Early Diagnosis of Preeclampsia. *Niger J Clin Pract*. 2024;27: 383–8.
- Cai X, Liu S, Yang L, Lu Y, Zhao J, Shen D, et al. COVIDSum: A linguistically enriched SciBERT-based summarization model for COVID-19 scientific papers. *J Biomed Inform*. 2022;127: 103999.
- Chai J, Zeng H, Li A, Ngai EW. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Mach Learn Appl*. 2021; 6:100134.
- Chakraborty C, Pal S, Bhattacharya M, Dash S, Lee SS. Overview of Chatbots with special emphasis on artificial intelligence-enabled ChatGPT in medical science. *Front Artif Intell*. 2023; 6:1237704.
- Challen R, Denny J, Pitt M, Gompels L, Edwards T, Tsaneva-Atanasova K. Artificial intelligence, bias and clinical safety. *BMJ Qual Saf*. 2019;28(3):231–7.
- Chan L, Beers K, Yau AA, Chauhan K, Duffy A, Chaudhary K, et al. Natural language processing of electronic health records is superior to billing codes to identify symptom burden in hemodialysis patients. *Kidney Int*. 2020;97(2):383–92.
- Chandrajv AV, Gnanasigamani LJ. Transformer-Based Abstract Generation of Medical Case Reports. *Int J Eng Adv Technol*. 2022;12(1):110–3.
- Chang IC, Shih YS, Kuo KM. Why would you use medical chatbots? interview and survey. *Int J Med Inform*. 2022; 165:104827.
- Chatziantoniou C, Schoot RA, van Ewijk R, et al. Methodological considerations on segmenting rhabdomyosarcoma with diffusion-weighted imaging—What can we do better? *Insights Imaging*. 2023; 14:19.
- Chaurasia A, Curry G, Zhao Y, et al. Use of Artificial Intelligence in Obstetric and Gynaecological Diagnostics: A Protocol for a Systematic Review and Meta-Analysis. *BMJ Open*. 2024;14(5):e082287.
- Chase HS, Mitrani LR, Lu GG, Fulgieri DJ. Early recognition of multiple sclerosis using natural language processing of the electronic health record. *BMC Med Inform Decis Mak*. 2017;17(1):24.
- Chen H, Cao B, Yang J, Ren H, Xia X, Zhang X, et al. Construction and effect evaluation of prediction model for red blood cell transfusion requirement in cesarean section based on artificial intelligence. *BMC Med Inform Decis Mak*. 2023;23(1):213.
- Chen J, Lu Y, Yu Q, Luo X, Adeli E, Wang Y, et al. TransUNet: Transformers make strong encoders for medical image segmentation. *arXiv preprint arXiv:2102.04306*. 2021. Disponible en: <https://arxiv.org/abs/2102.04306>

- Chow JC, Sanders L, Li K. Impact of ChatGPT on medical chatbots as a disruptive technology. *Front Artif Intell.* 2023;6: 1166014.
- Christ PF, Elshaer MEA, Ettlinger F, Tataavarty S, Bickel M, Bilic P, et al. Automatic liver and lesion segmentation in CT using cascaded fully convolutional neural networks and 3D conditional random fields. En: *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2016: 19th International Conference; Athens, Greece.* 2016. p. 415-23.
- Coiera E. The last mile: where artificial intelligence meets reality. *J Med Internet Res.* 2019;21(11): e16323.
- Cohen J, Silvestri G, Paredes O, Martin-Alcala HE, Chavez-Badiola A, Alikani M, et al. Artificial intelligence in assisted reproductive technology: separating the dream from reality. *Reprod BioMed Online.* 2025;50(1):1-8.
- Collins FS, Varmus H. A new initiative on precision medicine. *N Engl J Med.* 2015;372(9):793-5.
- Collins GS, Moons KGM. Reporting of artificial intelligence prediction models. *Lancet.* 2019;393(10181):1577-9.
- Collins GS, Moons KGM, Dhiman P, Riley RD, Beam AL, Van Calster B, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ.* 2024;385: e078378.
- Correa N, Cerquides J, Arcos JL, Vassena R. Supporting first FSH dosage for ovarian stimulation with machine learning. *Reprod Biomed Online.* 2022;45(5):1039-45.
- Cortes C, Vapnik V. Support-vector networks. *Mach Learn.* 1995; 20:273-97.
- Cover T, Hart P. Nearest neighbor pattern classification. *IEEE Trans Inf Theory.* 1967;13(1):21-7.
- Curchoe CL. Proceedings of the first world conference on AI in fertility. *J Assist Reprod Genet.* 2023;40(1):215-22.
- Da Correggio KS, Santos LO, Muylaert Barroso FS, Galluzzo RN, Chaves TZL, Wangenheim AV, et al. AI-Driven Fetal Liver Echotexture Analysis: A New Frontier in Predicting Neonatal Insulin Imbalance. *J Ultrasound Med.* 2025.
- Dai Y, Gao Y. TransMed: Transformers advance multi-modal medical image classification. *arXiv preprint arXiv:2103.05940.* 2021. Disponible en: <https://arxiv.org/abs/2103.05940>
- De Ramón Fernández A, Ruiz Fernández D, Prieto Sánchez MT. Prediction of the mode of delivery using artificial intelligence algorithms. *Comput Methods Programs Biomed.* 2022;219: 106740.
- DeCamp M, Lindvall C. Latent bias and the implementation of artificial intelligence in medicine. *JAMA.* 2020;324(3):235-6.
- Del Campo Real A. Aportación de la ecografía en la predicción del resultado de la inducción de parto [tesis doctoral]. Universidad del País Vasco (UPV/EHU); 2021.
- del Arco de la Paz A, Giménez-Rodríguez C, Selntigia A, Meseguer M, Galliano D. Advancements and Challenges in Preimplantation Genetic Testing for Aneuploidies: In the Pathway to Non-Invasive Techniques. *Genes.* 2024;15(1):1-18.
- Denny JC, Ritchie MD, Basford MA, Pulley JM, Bastarache L, Brown-Gentry K, et al. PheWAS: demonstrating the feasibility of a phenome-wide scan to discover gene-disease associations. *Bioinformatics.* 2010;26(9):1205-10.
- Dharwadkar R, Deshpande NA. A medical chatbot. *Int J Comput Trends Technol (IJCTT).* 2018;60(1):41-5.
- Dhombres F, Bonnard J, Bailly K, et al. Contributions of Artificial Intelligence Reported in Obstetrics and Gynecology Journals: Systematic Review. *J Med Internet Res.* 2022;24(4): e35465.
- Diakiw SM, Hall JMM, VerMilyea MD, Amin J, Aizpurua J, Giardini L, et al. Development of an artificial intelligence model for predicting the likelihood of human embryo euploidy based on blastocyst images from multiple imaging systems during IVF. *Hum Reprod.* 2022;37(8):1746-59.
- Dick K, Humber J, Ducharme R, et al. The Transformative Potential of AI in Obstetrics and Gynaecology. *J Obstet Gynaecol Can.* 2024;46(3):102277.
- Dietterich TG. Ensemble methods in machine learning. En: *International workshop on multiple classifier systems.* Berlin, Heidelberg: Springer Berlin Heidelberg; 2000. p. 1-15.
- Dignum V. *Responsible Artificial Intelligence: Designing AI for Human Values.* Cham: Springer; 2019.
- Divya S, Indumathi V, Ishwarya S, Priyasankari M, Devi SK. A self-diagnosis medical chatbot using artificial intelligence. *J Web Dev Web Des.* 2018;3(1):1-7.
- Dos Santos GG. Using Artificial Intelligence as a Technological Gynecologic and Obstetric Health: A Narrative Literature Review. *Int J Gynaecol Obstet.* 2025.
- Dumais ST. Latent semantic analysis. *Annu Rev Inf Sci Technol (ARIST).* 2004; 38:189-230.
- Eck M, Vogel S, Waibel A. Improving statistical machine translation in the medical domain using the Unified Medical Language System. En: *Coling 2004: Proceedings of the 20th international conference on Computational Linguistics.* 2004. p. 792-8.
- Eisenhauer EA, Therasse P, Bogaerts J, et al. New response evaluation criteria in solid tumours: revised RECIST guideline (version 1.1). *Eur J Cancer.* 2009; 45:228-47.
- ElHuffPost. Inteligencia artificial y cáncer de mama: el sistema valenciano que mejora los diagnósticos. [Internet]. [citado 2024 may 15]. Disponible en: https://www.huffingtonpost.es/entry/inteligencia-artificial-y-cancer-de-mama-el-sistema-valenciano-que-mejora-los-diagnosticos_es_6633d7b8e4b09e205164f9b8

- EmbryoScan project. EmbryoScan: AI-based 3D Ultrasound for Early Prenatal Screening (Vall d'Hebron & Universitat Pompeu Fabra, Barcelona) [Internet]. [citado 2024 abr 24]. Disponible en: embryoscan.com
- Enlace Judío. Inteligencia Artificial en Obstetricia y Ginecología: Predicción de Preeclampsia y Hemorragias Postparto. [Internet]. [citado 2024 may 15]. Disponible en: <https://www.enlacejudio.com/2024/05/01/inteligencia-artificial-en-obstetricia-y-ginecologia-prediccion-de-preeclampsia-y-hemorragias-postparto/>
- Erdur AC, Rusche D, Scholz D, et al. Deep learning for autosegmentation for radiotherapy treatment planning: State-of-the-art and novel perspectives. *Strahlenther Onkol.* 2025; 201:236–54.
- Esuli A, Sebastiani F. SentiWordNet: a high-coverage lexical resource for opinion mining. *Evaluation.* 2007;17(1):26.
- Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature.* 2017;542(7639):115–8.
- Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. *Nat Med.* 2019;25(1):24–9.
- European Commission. Proposal for a Regulation laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). COM/2021/206 final.
- Fanton M, Nutting V, Rothman A, Maeder-York P, Hariton E, Barash O, et al. An interpretable machine learning model for individualized gonadotrophin starting dose selection during ovarian stimulation. *Reprod Biomed Online.* 2022;45(6):1152–9.
- Farrar D. Hyperglycemia in pregnancy: prevalence, impact, and management challenges. *Int J Womens Health.* 2016;8: 519–27.
- Feng X, Wang T, Yang X, Zhang M, Guo W, Wang W. ConvWin-UNet: UNet-like hierarchical vision transformer combined with convolution for medical image segmentation. *Math Biosci Eng.* 2023;20(1):128–44.
- Fergus P, Cheung P, Hussain A, Al-Jumeily D, Dobbins C, Iram S. Prediction of preterm deliveries from cardiotocogram data using machine learning models. *Comput Biol Med.* 2020;121: 103805.
- Ferreira I, Simões J, Pereira B, Correia J, Areia AL. Ensemble learning for fetal ultrasound and maternal–fetal data to predict mode of delivery after labor induction. *Sci Rep.* 2024; 14:15275.
- Fiorentino MC, Moccia S, Cosmo MD, Frontoni E, Giovanola B, Tiribelli S. Uncovering ethical biases in publicly available fetal ultrasound datasets. *npj Digit Med.* 2025;8(1):355.
- Floridi L, Cowls J, Beltrametti M, et al. AI4People—An ethical framework for a good AI society: Opportunities, risks, principles, and recommendations. *Minds Mach.* 2018; 28:689–707.
- Font-López KC, G-CM. Diagnóstico de diabetes gestacional en población mexicana. *Ginecol Obstet Mex.* 2017;85(2):116–24.
- Forgy EW. Cluster analysis of multivariate data: efficiency versus interpretability of classifications. *Biometrics.* 1965;21(3):768–9.
- Frankevich NA, Tokareva AO, Yuriev SY, Chagovets VV, Kutsenko AA, Novoselova AV, et al. Amino Acid Profile Alterations in the Mother-Fetus System in Gestational Diabetes Mellitus and Macrosomia. *Int J Mol Sci.* 2025;26(17).
- Fu C, Jiang X, He T, Jiang X. MDepressionKG: a knowledge graph for metabolism-depression associations. En: *Proceedings of the 2nd international symposium on artificial intelligence for medicine sciences.* 2021. p. 63–8.
- Gale C, et al. Neonatal brain injuries in England: Population-based incidence derived from routinely recorded clinical data. *Arch Dis Child Fetal Neonatal Ed.* 2018;103(4): F301–6.
- Gallardo-Rincon H, Rios-Blancas MJ, Ortega-Montiel J, Montoya A, Martinez-Juarez LA, Lomelin-Gascon J, et al. MIDO GDM: an innovative artificial intelligence-based prediction model for the development of gestational diabetes in Mexican women. *Sci Rep.* 2023;13(1):6992.
- Gandomkar Z, Brennan PC. Deep learning in medical imaging: an overview. *Med J Aust.* 2019;211(1):5–6.
- Gao C, Osmundson S, Velez Edwards DR, Jackson GP, Malin BA, Chen Y. Deep learning predicts extreme preterm birth from electronic health records. *J Biomed Inform.* 2019; 100:103334.
- García-Aguirre R, Navarro-López EM, Torres-Treviño L. Gen-CNN: A framework for the automatic generation of CNNs for image classification. *Neural Comput Appl.* 2025;37(1):149–68.
- García-Ferrero I, Agerri R, Salazar AA, Cabrio E, de la Iglesia I, Lavelli A, et al. MedMT5: An Open-Source Multilingual Text-to-Text LLM for the Medical Domain. En: *Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024).* 2024. p. 11165–77.
- Garg P, Mohanty A, Ramisetty S, et al. Artificial Intelligence and Allied Subsets in Early Detection and Preclusion of Gynecological Cancers. *Biochim Biophys Acta Rev Cancer.* 2023;1878(6):189026.
- Geis JR, Brady AP, Wu CC, Spencer J, Ranschaert E, Jaremko JL, et al. Ethics of artificial intelligence in radiology: summary of the joint European and North American multisociety statement. *Radiology.* 2019;293(2):436–40.
- Georgieva A, Payne SJ, Redman CWG. Artificial intelligence for intrapartum fetal monitoring: Progress and challenges. *Semin Fetal Neonatal Med.* 2017;22(2):91–9.

- Geysels A, Garofalo G, Timmerman S, et al. Artificial Intelligence Applied to Ultrasound Diagnosis of Pelvic Gynecological Tumors: A Systematic Review and Meta-Analysis. *Gynecol Obstet Invest.* 2025;1–22.
- Ghassemi M, Oakden-Rayner L, Beam AL. The false hope of current approaches to explainable artificial intelligence in health care. *Lancet Digit Health.* 2021;3(11): e745–50.
- Gichoya JW, Banerjee I, Bhimireddy AR, et al. AI recognition of patient race in medical imaging: a modelling study. *Lancet Digit Health.* 2022;4(6): e406–14.
- Gilboa I, Gabbai D, Attali E, Hiersch L, Lavie A, Yogev Y. Prediction model for intrapartum cesarean delivery among women with gestational diabetes mellitus. *Arch Gynecol Obstet.* 2025.
- Gluck A, von der Wense K, Pacheco ML. Clix: Cross-lingual explanations of idiomatic expressions. *arXiv preprint arXiv:2501.03191.* 2025.
- Gomez Fernandez C, Mitsigiorgi R, Fochini M, Leung A, Fernandez Perez C, Nicolaides KH. Continuous glucose monitoring: criteria for the diagnosis of type 2 diabetes mellitus with clinical obesity after gestational diabetes. *Am J Obstet Gynecol.* 2025.
- Gonzalez RC. Digital image processing. Pearson Education India; 2009.
- Graham EM, Ruis KA, Hartman AL, Northington FJ, Burd I. A systematic review of the role of intrapartum hypoxia-ischemia in the causation of neonatal encephalopathy. *Am J Obstet Gynecol.* 2020;199(6):587–95.
- Greene A, Greene CC, Greene C. Artificial intelligence, chatbots, and the future of medicine. *Lancet Oncol.* 2019;20(4):481–2.
- Grobman WA, Hausman N, Edelstein R, Stamilio DM, Marder SJ. Predicting outcomes of trials of labor in women attempting vaginal birth after cesarean delivery: a comparison of multivariate methods with neural networks. *Am J Obstet Gynecol.* 2001;184: 409–13.
- Grobman WA, Sandoval G, Rice MM, Bailit JL, Chauhan SP, Costantine MM, et al. Prediction of vaginal birth after cesarean in term gestations: A calculator without race and ethnicity. *Am J Obstet Gynecol.* 2021; 225: 664.e1–664.e7.
- Grobman WA, Sandoval GJ, Rice MM, Chauhan SP, Clifton RG, Costantine MM, et al. Prediction of vaginal birth after cesarean using information at admission for delivery: A calculator without race and ethnicity. *Am J Obstet Gynecol.* 2023 jul 13.
- Grosser J, Düvel J, Hasemann L, Schneider E, Greiner W. Estudio de los efectos potenciales de la inteligencia artificial en los médicos Autonomía: Revisión del alcance. Departamento de Economía de la Salud y Gestión de la Atención Sanitaria, Facultad de Salud Pública, Universidad de Bielefeld, Bielefeld, Alemania Centro de Investigación Electrónica en Salud Pública (CePHR), Facultad de Salud Pública, Universidad de Bielefeld, Bielefeld, Alemania.
- Gu H, Dong H, Yang J, et al. How to build the best medical image segmentation algorithm using foundation models: a comprehensive empirical study with Segment Anything Model. *Mach Learn Biomed Imaging.* 2025; 3:88–120.
- Guedalia J, Lipschuetz M, Cohen SM, Sompolsky Y, Walfisch A, Sheiner E, et al. Transporting an Artificial Intelligence Model to Predict Emergency Cesarean Delivery: Overcoming Challenges Posed by Interfacility Variation. *J Med Internet Res.* 2021;23(12): e28120.
- Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA.* 2016;316(22):2402–10.
- Guni A, Sounderajah V, Whiting P, et al. Revised Tool for the Quality Assessment of Diagnostic Accuracy Studies Using AI (QUADAS-AI): Protocol for a Qualitative Study. *JMIR Res Protoc.* 2024;13: e58202.
- Guo PF, Mei YQ, Zhou JY, Jiang SS, Patel VM. ReconFormer: Accelerated MRI reconstruction using recurrent transformer. *arXiv preprint arXiv:2201.09376.* 2022. Disponible en: <https://arxiv.org/abs/2201.09376>
- Hackelöer M, Schmidt L, Verlohren S. New advances in prediction and surveillance of preeclampsia: role of machine learning approaches and remote monitoring. *Arch Gynecol Obstet.* 2023;308(6):1663–77.
- Hammer HL, Thambawita V, Riegler MA. Foundation models: the next level of AI in ART. *Hum Reprod.* 2025;39(12):2850–60.
- Han L, Gladkoff S, Erofeev, G, Sorokina I, Galiano B, Nenadic G. Neural machine translation of clinical text: an empirical investigation into multilingual pre-trained language models and transfer-learning. *Front Digit Health.* 2024;6: 1211564.
- Han Q, Qian X, Xu H, Wu K, Meng L, Qiu Z, et al. DM-CNN: Dynamic multi-scale convolutional neural network with uncertainty quantification for medical image classification. *Comput Biol Med.* 2024; 168:107758.
- Han S, Zhang RF, Shi L, Richie R, Liu H, Tseng A, et al. Classifying social determinants of health from unstructured electronic health records using deep learning-based natural language processing. *J Biomed Inform.* 2022;127: 103984.
- Han X, Yu J, Yang X, Chen C, Zhou H, Qiu C, et al. Artificial intelligence assistance for fetal development: evaluation of an automated software for biometry measurements in the mid-trimester. *BMC Pregnancy Childbirth.* 2024;24(1):158.

- Hariton E, Chi EA, Chi G, Morris JR, Braatz J, Rajpurkar P, et al. A machine learning algorithm can optimize the day of trigger to improve in vitro fertilization outcomes. *Fertil Steril*. 2021;116(5):1227–35.
- Hariton E, Pavlovic Z, Fanton M, Jiang VS. Applications of artificial intelligence in ovarian stimulation: a tool for improving efficiency and outcomes. *Fertil Steril*. 2023;120(1):8–16.
- Hashimoto DA, Rosman G, Rus D, Meireles OR. Artificial intelligence in surgery: promises and perils. *Ann Surg*. 2018;268(1):70–6.
- He K, Gan C, Li Z, Rekik I, Yin Z, Ji W, et al. Transformers in medical image analysis: A review. *arXiv preprint arXiv:2202.12165*. 2022. Disponible en: <https://arxiv.org/abs/2202.12165>
- He K, Gkioxari G, Dollár P, Girshick R. Mask r-cnn. En: *Proceedings of the IEEE international conference on computer vision*. 2017. p. 2961–9.
- He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. p. 770–8.
- Healio. AI holds ‘transformative potential’ for gynecology, obstetrics and menopause care. [Internet]. Wong J, et al. [citado 2024 may 15]. Disponible en: <https://www.healio.com/news/ob-gyn/20240422/ai-holds-transformative-potential-for-gynecology-obstetrics-and-menopause-care>
- Himel GMS, Hasan MS, Salsabil US, Islam MM. MedLingua: A conceptual framework for a multilingual medical conversational agent. *MethodsX*. 2024;12: 102614.
- Holback C, Jarosz R, Prior F, et al. The Cancer Genome Atlas Ovarian Cancer Collection (TCGA-OV) (Version 4) [Data set]. *Cancer Imaging Arch*. 2016.
- Holzinger A, Langs G, Denk H, Zatloukal K, Müller H. Causability and explainability of artificial intelligence in medicine. *Wiley Interdiscip Rev Data Min Knowl Discov*. 2019;9(4): e1312.
- Hong J, Atkinson J, Mitchell AR, et al. Comparison of maternal labor-related complications and neonatal outcomes following elective induction of labor at 39 weeks of gestation vs expectant management: a systematic review and meta-analysis. *JAMA Netw Open*. 2023;6(5): e2313162.
- Hosmer DW, Lemeshow S. *Applied Logistic Regression*. 2nd ed. Wiley; 2000.
- Houssein EH, Mohamed RE, Ali AA. Heart disease risk factors detection from electronic health records using advanced NLP and deep learning techniques. *Sci Rep*. 2023;13(1):7173.
- Howard A, Sandler M, Chu G, Chen LC, Chen B, Tan M, et al. Searching for mobilenetv3. En: *Proceedings of the IEEE/CVF international conference on computer vision*. 2019. p. 1314–24.
- Huang C, Long X, van der Ven M, et al. Predicting preterm birth using electronic medical records from multiple prenatal visits. *BMC Pregnancy Childbirth*. 2024; 24:843.
- Huang QF, Hu YC, Wang CK, Huang J, Shen MD, Ren LH. Clinical First-Trimester Prediction Models for Gestational Diabetes Mellitus: A Systematic Review and Meta-Analysis. *Biol Res Nurs*. 2023;25(2):185–97.
- Huang Z, Yang J, van Harmelen F, Hu Q. Constructing knowledge graphs of depression. En: *International conference on health information science*. Cham: Springer International Publishing; 2017. p. 149–61.
- Hudelson P, Chappuis F. Using voice-to-voice machine translation to overcome language barriers in clinical communication: an exploratory study. *J Gen Intern Med*. 2024;39(7):1095–102.
- Hu T, Du S, Li X, et al. Establishment of a model for predicting the outcome of induced labor in full-term pregnancy based on machine learning algorithm. *Sci Rep*. 2022; 12:19063.
- Hu X, Hu X, Yu Y, Wang J. Prediction model for gestational diabetes mellitus using the XG Boost machine learning algorithm. *Front Endocrinol (Lausanne)*. 2023;14: 1105062.
- Hung AJ, et al. Robotic surgery: role of artificial intelligence. *Urol Clin North Am*. 2020;47(3):359–66.
- Iratni M, Abdullah A, Aldhaheiri M, et al. Transformers for Neuroimage Segmentation: Scoping Review. *J Med Internet Res*. 2025;27: e57723.
- Isensee F, Rokuss M, Krämer L, et al. nnInteractive: Redefining 3D Promptable Segmentation. 2025 mar 11.
- Jaruenpunyasak J, Maneelert P, Nawae M, Choksuchat C. Artificial intelligence model for the assessment of unstained live sperm morphology. *Reprod Fertil*. 2025;6(2):1–10.
- Jezewski J, Horoba K, Wrobel J, Matonia A, Kupka T. Hybrid system for the prediction of fetal hypoxia risk. *Comput Biol Med*. 2018; 100:77–86.
- Jun D, Guo D, Ho T-Y, et al. DeepTarget: Gross tumor and clinical target volume segmentation in esophageal cancer radiotherapy. *Med Image Anal*. 2021;68: 101909.
- Jun Y, Chandra M, Verma G, Hu Y, De Choudhury M, Kumar S. Better to ask in english: Cross-lingual evaluation of large language models for healthcare queries. En: *Proceedings of the ACM Web Conference 2024*. 2024. p. 2627–38.
- Johnson L, et al. Personalized Medicine in Gynecology: The Role of AI. *Int J Womens Health*. 2019;11: 345–52.
- Jurafsky D, Martin JH. *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models*. 3a ed. Manuscrito en línea; 2025.

- Kaswan KS, Gaur L, Dhatteval JS, Kumar R. AI-based natural language processing for the generation of meaningful information electronic health record (EHR) data. En: *Advanced AI techniques and applications in bioinformatics*. CRC Press; 2021. p. 41-86.
- Kazi H, Chowdhry BS, Memon Z. MedChatBot: an UMLS based chatbot for medical students. 2012.
- Keefe D, Liu L, Wang W, Silva C. Imaging meiotic spindles by polarization light microscopy: Principles and applications to IVF. *Reprod Biomed Online*. 2003;7(1):24-9.
- Kelly CJ, Karthikesalingam A, Suleyman M, Corrado G, King D. Key challenges for delivering clinical impact with artificial intelligence. *BMC Med*. 2019;17(1):195.
- Khalafallah A, Phuah E, Al-Barazan AM, Nikakis I, Radford A, Clarkson W, et al. Glycosylated haemoglobin for screening and diagnosis of gestational diabetes mellitus. *BMJ Open*. 2016;6(4): e011059.
- Khalil A, Bellesia G, Norton ME, et al. The role of cell-free DNA biomarkers and patient data in the early prediction of preeclampsia: an artificial intelligence model. *Am J Obstet Gynecol*. 2024;231(5): 554.e1-18.
- Khan S, Naseer M, Hayat M, Zamir SW, Khan FS, Shah M. Transformers in vision: A survey. *ACM Comput Surv (CSUR)*. 2022;54(10s):1-41.
- Khan W, Zaki N, Ghenimi N, Ahmad A, Bian J, Masud MM, et al. Predicting preterm birth using explainable machine learning in a prospective cohort of nulliparous and multiparous pregnant women. *PLoS One*. 2023;18(12): e0293925.
- Khosravi P, Cao A, Tabrizi S, et al. Machine learning-assisted embryo selection in IVF: a systematic review. *Reprod Biomed Online*. 2021;43(3):588-600.
- Khosravi P, Kazemi E, Imielinski M, Elemento O, Hajirasouliha I. Deep convolutional neural networks enable discrimination of heterogeneous digital pathology images. *EBioMedicine*. 2018;27: 317-28.
- Kılıç Ş. Deep feature engineering for accurate sperm morphology classification using CBAM-enhanced ResNet50. Shaikh A, editor. *PLoS One*. 2025;20(9): e0330914.
- Kirillov A, Mintun E, Ravi N, et al. Segment Anything. *Proc IEEE Int Conf Comput Vis*. 2023.
- Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection. En: *Ijcai*. 1995. p. 1137-45.
- Kokori E, Olatunji G, Aderinto N, Muogbo I, Ogiewu IJ, Isarinade D, et al. The role of machine learning algorithms in detection of gestational diabetes; a narrative review of current evidence. *Clin Diabetes Endocrinol*. 2024;10(1):18.
- Komorowski M, Celi LA, Badawi O. The artificial intelligence clinician learns optimal treatment strategies for sepsis in intensive care. *Nat Med*. 2018;24(11):1716-20.
- Kong D, Tao Y, Xiao H, Xiao W, Wei W, Cai M. Predicting preterm birth using auto-ML frameworks: a large observational study using electronic inpatient discharge data. *Front Pediatr*. 2024;12: 1330420.
- Koplin JJ, Johnston M, Webb ANS, Whittaker A, Mills C. Ethics of artificial intelligence in embryo assessment: mapping the terrain. *Hum Reprod*. 2025;40(1):179-85.
- Krithika alias AnbuDevi M, Suganthi K. Review of Semantic Segmentation of Medical Images Using Modified Architectures of UNET. *Diagnostics*. 2022;12: 3064.
- Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Adv Neural Inf Process Syst*. 2012;25: 1097-105.
- Krsman A, Grujić Z, Čapko D, et al. Ultrasound assessment of cervical status compared to the Bishop score – predicting the success of labor induction using a machine learning-based model. *Eur Rev Med Pharmacol Sci*. 2023;27: 6332-42.
- Ku CW, Zheng RT, Tan HY, Lim JYQ, Chen LW, Cheung YB, et al. Early continuous glucose monitoring-derived glycemic patterns are associated with subsequent insulin resistance and gestational diabetes mellitus development during pregnancy. *Diabetol Metab Syndr*. 2024;16(1):271.
- Kurata Y, Nishio M, Moribata Y, et al. Automatic segmentation of uterine endometrial cancer on multi-sequence MRI using a convolutional neural network. *Sci Rep*. 2021; 11:14440.
- Landon MB, Hauth JC, Leveno KJ, et al. Maternal and perinatal outcomes associated with a trial of labor after prior cesarean delivery. *N Engl J Med*. 2004; 351:2581-9.
- Lawson McLean A, Yen TL. Machine Translation for Multilingual Cancer Patient Education: Bridging Languages, Navigating Challenges. *J Cancer Educ*. 2024;39(5):477-8.
- Layton AT. Artificial Intelligence and Machine Learning in Preeclampsia. *Arterioscler Thromb Vasc Biol*. 2025;45(2):165-71.
- Leduc D, Biringer A, Lee L, Dy J; Clinical Practice Obstetrics Committee. Induction of labour. *J Obstet Gynaecol Can*. 2013;35(9):840-57.
- Lee J, Yoon W, Kim S, Kim S, So CH, et al. BioBERT: a pre-trained biomedical language representation model for biomedical text mining. *Bioinformatics*. 2020;36(4):1234-40.
- Lee KS, Ahn KH. Application of Artificial Intelligence in Early Diagnosis of Spontaneous Preterm Labor and Birth. *Diagnostics (Basel)*. 2020;10(9):733.

- Lee T, Natalwala J, Chapple V, Liu Y. A brief history of artificial intelligence embryo selection: From black-box to glass-box. *Hum Reprod.* 2024;39(2):285–92.
- Lee S-W, Kim A, Lee SJ, et al. Intensity-Modulated Radiation Therapy for Uterine Cervical Cancer to Reduce Toxicity and Enhance Efficacy - an Option or a Must?: A Narrative Review. *Cancer Res Treat.* 2024;56:1–17.
- Letterie G. Artificial intelligence and assisted reproductive technologies: 2023. Ready for prime time? Or not. *Fertil Steril.* 2023;120(1):32–7.
- Letterie G, MacDonald A, Shi Z. An artificial intelligence platform to optimize workflow during ovarian stimulation and IVF: process improvement and outcome-based predictions. *Reprod Biomed Online.* 2022;44(2):254–60.
- Li J, Liu X, He S, Ren Y. Interpretable Machine Learning for Predicting Adverse Pregnancy Outcomes in Gestational Diabetes: Retrospective Cohort Study. *JMIR Med Inform.* 2025;13: e71539.
- Li S, Wang Z, Vieira LA, Zheutlin AB, Ru B, Schadt E, et al. Improving preeclampsia risk prediction by modeling pregnancy trajectories from routinely collected electronic medical record data. *npj Digit Med.* 2022;5(1):68.
- Li T, Sahu AK, Talwalkar A, Smith V. Federated learning: Challenges, methods, and future directions. *IEEE Signal Process Mag.* 2020;37(3):50–60.
- Liang X, Liang J, Zeng F, Lin Y, Li Y, Cai K, et al. Evaluation of oocyte maturity using artificial intelligence quantification of follicle volume biomarker by three-dimensional ultrasound. *Reprod Biomed Online.* 2022;45(6):1197–206.
- Lin M, Zhou Q, Lei T, Shang N, Zheng Q, He X, et al. Deep learning system improved detection efficacy of fetal intracranial malformations in a randomized controlled trial. *npj Digit Med.* 2023;6(1):191.
- Lipschuetz M, Guedalia J, Rottenstreich A, et al. Prediction of vaginal birth after cesarean deliveries using machine learning. *Am J Obstet Gynecol.* 2020;222: 613.e1–613.e12.
- Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal.* 2017; 42:60–88.
- Liu G, Huang W, Li Y, Zhang Q, Fu J, Tang H, et al. A weakly-supervised follicle segmentation method in ultrasound images. *Sci Rep.* 2025;15(1):1–12.
- Liu H, Peng S, Huang J, Chen Z, Huang T, Yang K, et al. Machine learning approaches for predicting postpartum hemorrhage: a systematic review and meta-analysis. *J Matern Fetal Neonatal Med.* 2023;36(6):1142–52.
- Liu J, Yang C, Liu B, Kim R, Philis-Tsimikas A, Isasi C, et al. Factors Associated with Progression to Type 2 Diabetes among Women with Gestational Diabetes. *J Urban Health.* 2025.
- Liu M, Yang X, Chen G, Ding Y, Shi M, Sun L, et al. Development of a prediction model on preeclampsia using machine learning-based method: a retrospective cohort study in China. *Front Physiol.* 2022;13: 896969.
- Liu X, Cruz Rivera S, Moher D, Calvert MJ, Denniston AK; CONSORT-AI Steering Group. Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension. *Nat Med.* 2020;26(9):1364–74.
- Liu X, Faes L, Kale AU, Wagner SK, Fu DJ, Bruynseels A, et al. A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *Lancet Digit Health.* 2019;1(6): e271–97.
- Liu X, The SPIRIT-AI and CONSORT-AI Study Group. SPIRIT-AI and CONSORT-AI: new reporting guidelines for clinical trials involving artificial intelligence. *Lancet Digit Health.* 2020;2(10): e538–9.
- Liu Y, et al. Early prediction of preeclampsia with machine learning. *Am J Obstet Gynecol.* 2019;220(4): 382.e1–382.e11.
- Liu Z, Lin Y, Cao Y, Hu H, Wei Y, Zhang Z, et al. Swin transformer: Hierarchical vision transformer using shifted windows. En: *Proceedings of the IEEE/CVF international conference on computer vision.* 2021. p. 10012–22.
- Lo BP, Donnelly MR, Barisano G, et al. A standardized protocol for manually segmenting stroke lesions on high-resolution T1-weighted MR images. *Front Neuroimaging.* 2022;1.
- Looney P, Hwang M, Dalal S, Lees CC, Hayat T, Thangaratinam S. Artificial intelligence (AI) for the detection of fetal heart anomalies: a systematic review. *Ultrasound Obstet Gynecol.* 2020;55(6):806–14.
- Lowe WL Jr, Scholtens DM, Lowe LP, Kuang A, Nodzenski M, Talbot O, et al. Association of Gestational Diabetes With Maternal Disorders of Glucose Metabolism and Childhood Adiposity. *JAMA.* 2018;320(10):1005–16.
- Lundberg SM, LS-I. A Unified Approach to Interpreting Model Predictions. *Adv Neural Inf Process Syst.* 2017;30: 4765–74.
- Luo Y, Thompson WK, Herr TM, Zeng Z, Berendsen MA, Jonnalagadda SR, et al. Natural language processing for EHR-based pharmacovigilance: a structured review. *Drug Saf.* 2017;40(11):1075–89.
- Macones GA, Hausman N, Edelstein R, Stamilio DM, Marder SJ. Predicting outcomes of trials of labor in women attempting vaginal birth after cesarean delivery: a comparison of multivariate methods with neural networks. *Am J Obstet Gynecol.* 2001;184(4):409–13.
- MacQueen J. Some methods for classification and analysis of multivariate observations. En: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics.* University of California Press; 1967. p. 281–98.

- Ma J, He Y, Li F, et al. Segment anything in medical images. *Nat Commun*. 2024; 15:654.
- Malvasi A, Malgieri LE, Stark M, Tinelli A. Dystocia, delivery, and artificial intelligence in labor management: perspectives and future directions. *J Clin Med*. 2024;13(21):6410.
- Malvasi A, Stark M, Ghi T, et al. Intrapartum sonography for fetal head asynclitism and transverse position: sonographic signs and comparison of diagnostic performance between transvaginal and digital examination. *J Matern Fetal Neonatal Med*. 2012;25(5):508-12.
- Mapari SA, Shrivastava D, Bedi GN, Pradeep U, Gupta A, Kasat PR, et al. Revolutionizing Reproduction: The Impact of Robotics and Artificial Intelligence (AI) in Assisted Reproductive Technology: A Comprehensive Review. *Cureus*. 2024.
- Marin I, Pavaloioiu B, Marian C-V, Racovita V, Goga N. Early detection of preeclampsia based on a machine learning approach. *E-Health Bioeng Conf*. 2019. p. 1-4.
- Martinez AR. Part-of-speech tagging. *Wiley Interdiscip Rev Comput Stat*. 2012;4(1):107-13.
- Martinez-Juarez LA, Gallardo-Rincon H, Saucedo-Martinez R, Mujica-Rosales R, Reyes-Munoz E, Alvarez-Hernandez DA, et al. A strategic framework for managing gestational diabetes in Mexico. *Glob Health Res Policy*. 2025;10(1):12.
- McCradden MD, Joshi S, Mazwi M, Anderson JA. Ethical limitations of algorithmic fairness solutions in health care machine learning. *Lancet Digit Health*. 2020;2(5): e221-3.
- Medina Ruiz L, Chahla RE, Vega IM, Ortega ES, Barrenechea GG, Ferre Contreras M. Inteligencia artificial: precisión diagnóstica de lesiones preneoplásicas de cérvix uterino. *Medicina (Buenos Aires)*. 2024; 84:459-67.
- Meseguer M, Rubio I, Martínez F, Remohí J, Pellicer A. Embryo selection by time-lapse imaging and morphokinetic scoring: a prospective multicentre randomized controlled trial. *Hum Reprod*. 2020;35(12):2708-16.
- Mesko B, Gyorffy Z. The rise of the empowered physician in the digital health era: Viewpoint. *J Med Internet Res*. 2019;21(3): e12490.
- Meyer R, Hendin N, Zamir M, Mor N, Levin G, Sivan E, et al. Implementation of machine learning models for the prediction of vaginal birth after cesarean delivery. *J Matern Fetal Neonatal Med*. 2020;35(19):3677-83.
- Michalitsi K, Metallinou D, Diamanti A, et al. Artificial intelligence in predicting the mode of delivery: a systematic review. *Cureus*. 2024;16(9): e69115.
- Mienye ID, Swart TG, Obaido G, Jordan M, Ilono P. Deep convolutional neural networks in medical image analysis: A review. *Information*. 2025;16(3):195.
- Mikolov T, Sutskever I, Chen K, Corrado GS, Dean J. Distributed representations of words and phrases and their compositionality. *Adv Neural Inf Process Syst*. 2013;26.
- Miller GA. WordNet: a lexical database for English. *Commun ACM*. 1995;38(11):39-41.
- Ministerio de Salud de México. Ley Federal de Protección de Datos Personales en Posesión de los Particulares (LFPDPPP). *Diario Oficial de la Federación*. 2010.
- Mitchell TM. *Machine learning*. 1st ed. McGraw Hill; 1997.
- Mittelstadt BD. Principles alone cannot guarantee ethical AI. *Nat Mach Intell*. 2019;1(11):501-7.
- Moons KGM, Wolff RF, Riley RD, Whiting PF, Westwood M, Collins GS, et al. PROBAST: A Tool to Assess Risk of Bias and Applicability of Prediction Model Studies: Explanation and Elaboration. *Ann Intern Med*. 2019;170(1): W1-33.
- Moor MPJ, de Bruin K, van Ginneken B, de Jonge GA, Benders MJNL, de Vries LS. Artificial intelligence in fetal ultrasound imaging: Current status and future perspectives. *Ultrasound Obstet Gynecol*. 2021;57(2):174-84.
- Moldt JA, Festl-Wietek T, Madany Mamlouk A, Nieselt K, Fuhl W, Herrmann-Werner A. Chatbots for future docs: exploring medical students' attitudes and knowledge towards artificial intelligence and medical chatbots. *Med Educ Online*. 2023;28(1):2182659.
- Montjean D, Godin Pagé MH, Pacios C, Calvé A, Hamiche G, Benkhalifa M, et al. Automated Single-Sperm Selection Software (SiD) during ICSI: A Prospective Sibling Oocyte Evaluation. *Med Sci (Basel)*. 2024;12(2):1-13.
- Morley J, Luciano F. Designing a multi-stakeholder governance framework for the ethical implementation of AI in healthcare. *AI Soc*. 2022;37(1):85-97.
- Moro F, Cancia M, Zace D, et al. Role of Artificial Intelligence Applied to Ultrasound in Gynecology Oncology: A Systematic Review. *Int J Cancer*. 2024;155(10):1832-45.
- Moro F, Giudice MT, Cancia M, et al. Application of Artificial Intelligence to Ultrasound Imaging for Benign Gynecological Disorders: Systematic Review. *Ultrasound Obstet Gynecol*. 2025;65(3):295-302.
- Moro S, et al. Application of artificial intelligence to ultrasound imaging for benign gynecological disorders: systematic review. *Ultrasound in Obstetrics & Gynecology*. 2025.
- Murali L, Gopakumar G, Viswanathan DM, Nedungadi P. Towards electronic health record-based medical knowledge graph construction, completion, and applications: A literature study. *J Biomed Inform*. 2023;143: 104403.
- Murillo F, Fanton M, Baker VL, Loewke K. Causal inference indicates that poor responders have similar outcomes with the antagonist protocol compared with flare. *Fertil Steril*. 2023;120(2):289-96.

- Mysona DP, Kapp DS, Rohatgi A, et al. Applying Artificial Intelligence to Gynecologic Oncology: A Review. *Obstet Gynecol Surv.* 2021;76(5):292-301.
- Nagelkerke N, Overdevest JB, de Vries H, Louwman M, van Trigt M, Verhoef C, et al. Machine learning to identify factors associated with progression to high-grade serous ovarian cancer. *Gynecol Oncol.* 2021;161(1):141-7.
- Naik N, Roth B, Lundy SD. Artificial Intelligence for Clinical Management of Male Infertility, a Scoping Review. *Curr Urol Rep.* 2025;26(1):1-10.
- Narayanaswamy A, Peng J, Zepeda I, Stumpe MC. Regulatory considerations for AI-based medical devices: the path ahead. *Nat Med.* 2021;27(5):802-3.
- Narasimha Murty M, Susheela Devi V. *Pattern Recognition: An Algorithmic Approach.* Springer; 2011.
- National Institute for Health and Care Excellence. Intrapartum care for healthy women and babies. NICE Clinical Guideline CG190. London: NICE; 2014.
- Ng SK, Krishnan T, McLachlan GJ. The EM Algorithm. En: Gentle J, Härdle W, Mori Y, editores. *Handbook of Computational Statistics.* Springer Handbooks of Computational Statistics. Berlin, Heidelberg: Springer; 2012.
- NHS Resolution. Annual Report and Accounts 2017/18 [Internet]. 2018 [citado 2019 jul 5]. Disponible en: <https://resolution.nhs.uk/wp-content/uploads/2018/08/NHS-Resolution-Annual-Report-2017-2018.pdf>
- Njeh CF. Tumor delineation: The weakest link in the search for accuracy in radiotherapy. *J Med Phys.* 2008; 33:136-40.
- Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. *Science.* 2019;366(6464):447-53.
- O'Gorman N, Wright D, Syngelaki A, Akolekar R, Wright A, Poon LC, et al. Competing risks model in screening for preeclampsia by maternal factors and biomarkers at 11-13 weeks gestation. *Am J Obstet Gynecol.* 2016;214(1):103.e1-103.e12.
- Olawade DB, Teke J, Adeleye KK, Weerasinghe K, Maidoki M, David-Olawade AC. Artificial intelligence in in-vitro fertilization (IVF): A new era of precision and personalization in fertility treatments. *J Gynecol Obstet Hum Reprod.* 2025;54(1):102872.
- Owusu-Adjei M, Ben Hayfron-Acquah J, Frimpong T, Gaddafi AS. An AI-based approach to predict delivery outcome based on measurable factors of pregnant mothers. *PLOS Digit Health.* 2025;4(2): e0000543.
- Paiboonborirak C, Abu-Rustum NR, Wilailak S. Artificial Intelligence in the Diagnosis and Management of Gynecologic Cancer. *Int J Gynaecol Obstet.* 2025.
- Panch T, Mattie H, Atun R. Artificial intelligence and algorithmic bias: implications for health systems. *J Glob Health.* 2019;9(2):020318.
- Panigutti C, Perotti A, Guidotti R, Giannotti F. Explaining deep learning models through rule-based approximations. *Knowl Based Syst.* 2021;221: 106923.
- Pareto D, Naval-Baudin P, Pons-Escoda A, et al. Image analysis research in neuroradiology: bridging clinical and technical domains. *Neuroradiology.* 2025.
- Park H, Lee HJ, Kim HG, et al. Endometrium segmentation on transvaginal ultrasound image using key-point discriminator. *Med Phys.* 2019;46: 3974-84.
- Pengpun P, Tiankanon K, Chinkamol A, Kinchagawat J, Chairuengjitjaras P, Supholkhan P, et al. On Creating an English-Thai Code-switched Machine Translation in Medical Domain. *arXiv preprint arXiv:2410.16221.* 2024.
- Povoa C, Machado J, Sampaio P, Martins C, Rodrigues D, Nunes A. Artificial intelligence in obstetric triage: automated detection of high-risk pregnancies using administrative and clinical data. *BMC Pregnancy Childbirth.* 2022;22(1):31.
- Pu Q, Xi Z, Yin S, Zhao Z, Zhao L. Advantages of transformer and its application for medical image segmentation: A survey. *BioMed Eng Online.* 2024;23(1):14.
- Qaderi K, Sharifipour F, Dabir M, Shams R, Behmanesh A. Artificial intelligence (AI) approaches to male infertility in IVF: a mapping review. *Eur J Med Res.* 2025;30(1):1-14.
- Quaas AM. Ovarian stimulation protocols: Don't immediately change a losing team. *Fertil Steril.* 2021;116(3):664-5.
- Raimundo JM, Cabrita P. Artificial intelligence at assisted reproductive technology. En: *Procedia Computer Science.* Elsevier B.V.; 2021. p. 442-7.
- Rajkomar A, Dean J, Kohane I. Machine learning in medicine. *N Engl J Med.* 2019;380(14):1347-58.
- Rajkomar A, Hardt M, Howell MD, Corrado G, Chin MH. Ensuring fairness in machine learning to advance health equity. *Ann Intern Med.* 2018;169(12):866-72.
- Rajkomar A, Oren E, Chen K, Dai AM, Hajaj N, Hardt M, et al. Scalable and accurate deep learning with electronic health records. *NPJ Digit Med.* 2018; 1:18.
- Rajpurkar P, Irvin J, Zhu K, Yang B, Mehta H, Duan T, et al. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225.* 2017.
- Ramirez Zegarra R, Conversano F, Dall'Asta A, et al. A deep learning approach to identify the fetal head position using transperineal ultrasound during labor. *Eur J Obstet Gynecol Reprod Biol.* 2024; 301:147-53.

- Ranzani OT, Nascimento JM, de Almeida-Neto C, Carvalho F, Soares M. Machine learning for prognostication in critical care: a systematic review of methodology and reporting. *Crit Care*. 2020;24(1):5.
- Rarhi K, Bhattacharya A, Mishra A, Mandal K. Automated medical chatbot. *SSRN Electron J*. 2017;10(9):1-6.
- Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo (RGPD). *Diario Oficial de la Unión Europea*, L119/1, 2016.
- Rennie J, Tognini A, Carty C, McNally E, Burke G, Thomson A, et al. Artificial intelligence in gynecologic oncology: radiomics, deep learning and beyond. *Gynecol Oncol*. 2022;167(2):335-46.
- Riegler MA, Stensen MH, Witczak O, Andersen JM, Hicks SA, Hammer HL, et al. Artificial intelligence in the fertility clinic: Status, pitfalls and possibilities. *Hum Reprod*. 2021;36(9):2429-42.
- Roberts M, Driggs D, Thorpe M, Gilbey J, Yeung M, Ursprung S, et al. Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans. *Nat Mach Intell*. 2021;3(3):199-217.
- Robert C, Munoz A, Moreau D, et al. Clinical implementation of deep-learning based auto-contouring tools-Experience of three French radiotherapy centers. *Cancer Radiother*. 2021; 25:607-16.
- Rodríguez-Ruiz A, Krupinski E, Mordang JJ, Schilling K, Heywang-Köbrunner SH, Sechopoulos I, et al. Detection of breast cancer with mammography: effect of an artificial intelligence support system. *Radiology*. 2019;290(2):305-14.
- Rolnik DL, Wright D, Poon LC, O’Gorman N, Syngelaki A, de Paco M C, et al. Aspirin versus placebo in pregnancies at high risk for preterm preeclampsia. *N Engl J Med*. 2017;377(7):613-22.
- Romano M, Costamagna M, Giansanti A. Wearable monitoring systems for fetal well-being: A review of the state-of-the-art. *Sensors (Basel)*. 2021;21(2):485.
- Ronan I, Tabirca S. Fine-Tuning Generative Pre-Trained Transformers for Clinical Dialogue Summarization. En: 2024 International Conference on Frontiers of Information Technology (FIT). Islamabad, Pakistan. IEEE; 2024. p. 1-6.
- Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. En: *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference; Munich, Germany*. Springer International Publishing; 2015. p. 234-41.
- Rovira A, Corral JF, Auger C, et al. Assessment of automatic decision-support systems for detecting active T2 lesions in multiple sclerosis patients. *Mult Scler*. 2022;28: 1209-18.
- Royal College of Midwives. Position statement: Vaginal examination in labour. London: RCM; 2012.
- Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nat Mach Intell*. 2019;1(4):206-15.
- Russell S, Norvig P. *Artificial Intelligence: A Modern Approach*. 4a ed. Pearson; 2021.
- Safi Z, Abd-Alrazaq A, Khalifa M, Househ M. Technical aspects of developing chatbots for medical applications: scoping review. *J Med Internet Res*. 2020;22(12): e19127.
- Schmidt LJ, Rieger O, Neznansky M, Hackelöer M, Dröge LA, Henrich W, et al. A machine-learning-based algorithm improves prediction of preeclampsia-associated adverse outcomes. *Am J Obstet Gynecol*. 2022;227(1):77. e1-77. e30.
- Seong D, Espinosa C, Aghaeepour N. Computational Approaches for Predicting Preterm Birth and Newborn Outcomes. *Clin Perinatol*. 2024;51(2):461-73.
- Sengupta P, Dutta S, Bagchi S, Rathore RS, Jhaveri RH. Strategic Guidelines to Integrate Artificial Intelligence in Obstetrics and Gynecology: Best Practices and Ethical Considerations. *Reprod Sci*. 2025.
- Shahiri SH, et al. Machine Learning Approach for Preterm Birth Prediction Using Health Records: systematic review. *JMIR Med Inform*. 2022;10(4): e33875.
- Shah NR, Weadock WJ, Williams KM, et al. Use of modern three-dimensional imaging models to guide surgical planning for local control of pediatric extracranial solid tumors. *Pediatr Blood Cancer*. 2024;71 :e30933.
- Shapiro BS, Rasouli MA, Verma K, Raman A, Garner FC, Aguirre M, et al. The effect of ovarian follicle size on oocyte and embryology outcomes. *Fertil Steril*. 2022;117(6):1170-6.
- Sharp G, Fritscher KD, Pekar V, et al. Vision 20/20: perspectives on automated image segmentation for radiotherapy. *Med Phys*. 2014;41: 050902.
- Shazly SA, Trabuco EC, Ngufor CG, Famuyide AO. Introduction to Machine Learning in Obstetrics and Gynecology. *Obstet Gynecol*. 2022;139(4):669-79.
- Sheller MJ, Edwards B, Reina GA, Martin J, Pati S, Kotrotsou A, et al. Federated learning in medicine: facilitating multi-institutional collaborations without sharing patient data. *Sci Rep*. 2020;10(1):12598.
- Sherer DM, Miodovnik M, Bradley KS, Langer O. Intrapartum fetal head position II: comparison between transvaginal digital examination and transabdominal ultrasound during the second stage of labor. *Ultrasound Obstet Gynecol*. 2002;19(3):264-8.
- Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. *J Big Data*. 2019;6(1):60.
- Shortliffe EH, Sepúlveda MJ. Clinical decision support in the era of artificial intelligence. *JAMA*. 2018;320(21):2199-200.

- Shvets AA, Rakhlin A, Kalinin AA, Iglovikov VI. Automatic instrument segmentation in robot-assisted surgery using deep learning. En: 2018 17th IEEE international conference on machine learning and applications (ICMLA). IEEE; 2018. p. 624-8.
- Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556. 2014.
- Singleton J, Li C, Akpunonu PD, Abner EL, Kucharska-Newton AM. Using natural language processing to identify opioid use disorder in electronic health record data. *Int J Med Inform.* 2023;170: 104963.
- Smith J, et al. Artificial Intelligence in Gynecology: Current Applications and Future Directions. *J Gynecol Surg.* 2020;36(4):123-30.
- Solomon MD, Tabada G, Allen A, Sung SH, Go AS. Large-scale identification of aortic stenosis and its severity using natural language processing on electronic health records. *Cardiovasc Digit Health J.* 2021;2(3):156-63.
- Spilka J, Chudáček V, Burša M, Janků P, Lhotská L. Using nonlinear features for fetal heart rate classification. *Biomed Signal Process Control.* 2012;7(4):350-7.
- Srivastava P, Singh N. Automatized medical chatbot (medibot). En: 2020 International Conference on Power Electronics & IoT Applications in Renewable Energy and its Control (PARC). IEEE; 2020. p. 351-4.
- Sterne JA, White IR, Carlin JB, Spratt M, Royston P, Kenward MG, et al. Multiple imputation for missing data in epidemiological and clinical research: potential and pitfalls. *BMJ.* 2009;338: b2393.
- Suarez-Cruz MG, Rivas-Ruiz R, Sarmiento-Galvan DK, Martinez-Valle PG, Mondragon-Sandoval EX, Lopez-Farias MA, et al. [Effect of weight gain on the development of gestational diabetes]. *Rev Med Inst Mex Seguro Soc.* 2023;61(Suppl 3): S460-7.
- Suchanek FM, Kasneci G, Weikum G. Yago: a core of semantic knowledge. En: Proceedings of the 16th international conference on World Wide Web. 2007. p. 697-706.
- Sun H, et al. Machine Learning-Based Prediction Model of Preterm Birth Using Electronic Health Record. *J Healthc Eng.* 2022;2022: 9635526.
- Sun K, Xue S, Sun F, Sun H, Luo Y, Wang L, et al. Medical Multimodal Foundation Models in Clinical Diagnosis and Treatment: Applications, Challenges, and Future Directions. arXiv preprint arXiv:2412.02621. 2024.
- Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the inception architecture for computer vision. En: Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. p. 2818-26.
- Tan M, Le Q. Efficientnet: Rethinking model scaling for convolutional neural networks. En: International conference on machine learning. PMLR; 2019. p. 6105-14.
- Tan M, Li Z, Qiu Y, et al. A New Approach to Evaluate Drug Treatment Response of Ovarian Cancer Patients Based on Deformable Image Registration. *IEEE Trans Med Imaging.* 2016; 35:316-25.
- Titano JJ, Badgeley M, Schefflein J, Pain M, Su A, Cai M, et al. Automated deep-neural-network surveillance of cranial images for acute neurologic events. *Nat Med.* 2018;24(9):1337-41.
- Tjoa E, Guan C. A survey on explainable artificial intelligence (xai): Toward medical xai. *IEEE Trans Neural Netw Learn Syst.* 2020;32(11):4793-813.
- Topol E. Deep medicine: how artificial intelligence can make healthcare human again. Hachette UK; 2019.
- Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med.* 2019;25(1):44-56.
- Torchin H, Ancel PY. Epidemiology and risk factors of preterm birth. *J Gynecol Obstet Biol Reprod.* 2016; 45:1213-20.
- Tran D, Cooke S, Illingworth PJ. Artificial intelligence-assisted embryo selection: a systematic review. *Hum Reprod Update.* 2021;27(4):599-619.
- Tran MN, Wang Y, Walle CV, McClendon J, Vinters HV, Haskell JP, et al. Radiomics and machine learning for the classification of adnexal masses on MRI: a multi-center study. *Eur Radiol.* 2022;32(3):1825-35.
- Tsai VFS, Zhuang B, Pong YH, Hsieh JT, Chang HC. Web- And artificial intelligence-based image recognition for sperm motility analysis: Verification study. *JMIR Med Inform.* 2020;8(11): e20790.
- Utunen H, Staubitz T, George R, Zhao YU, Serth S, Tokar A. Scale up multilingualism in health emergency learning: developing an automated transcription and translation tool. En: Caring is sharing—exploiting the value in data for health and innovation. IOS Press; 2023. p. 408-12.
- Van den Heuvel JFM, Lely AT, Huisman JJ, Trappenburg JCA, Franx A, Bekker MN. SAFE@HOME: digital health platform facilitating a new care path for women at increased risk of preeclampsia – a case-control study. *Pregnancy Hypertens.* 2020;22: 30-6.
- Van Timmeren JE, Cester D, Tanadini-Lang S, et al. Radiomics in medical imaging—“how-to” guide and critical reflection. *Insights Imaging.* 2020; 11:91.
- Van Veen D, Van Uden C, Blankemeier L, Delbrouck JB, Aali A, Bluethgen C, et al. Adapted large language models can outperform medical experts in clinical text summarization. *Nat Med.* 2024;30(4):1134-42.
- Vapnik V. Support-vector networks. *Mach Learn.* 1995;20(3):273-97.

- Vasudevan L, Kibria MG, Kucirka LM, Shieh K, Wei M, Masoumi S, et al. Machine Learning Models to Predict Risk of Maternal Morbidity and Mortality From Electronic Medical Record Data: Scoping Review. *J Med Internet Res*. 2025;27: e68225.
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. Attention is all you need. *Adv Neural Inf Process Syst*. 2017;30.
- Venturini L, Budd S, Farruggia A, Wright R, Matthew J, Day TG, et al. Whole examination AI estimation of fetal biometrics from 20-week ultrasound scans. *npj Digit Med*. 2025;8(1):22.
- Viterbi A. Error bounds for convolutional codes and an asymptotically optimum decoding algorithm. *IEEE Trans Inf Theory*. 2003;13(2):260-9.
- Wald K, Hariton E, Morris JR, Chi EA, Jaswa EG, Cedars MI, et al. Changing stimulation protocol on repeat conventional ovarian stimulation cycles does not lead to improved laboratory outcomes. *Fertil Steril*. 2021;116(3):757-65.
- Walss M, Anzengruber F, Arafa A, Djamei V, Navarini AA. Implementing medical chatbots: an application on hidradenitis suppurativa. *Dermatology*. 2021;237(5):712-8.
- Wang H, Zu Q, Lu M, Chen R, Yang Z, Gao Y, et al. Application of medical knowledge graphs in cardiology and cardiovascular medicine: a brief literature review. *Adv Ther*. 2022;39(9):4052-60.
- Wang Q, Zhou X, Wu J, et al. Research Progress of Artificial Intelligence in the Early Screening, Diagnosis, Precise Treatment and Prognosis Prediction of Three Central Gynecological Malignancies. *Front Oncol*. 2025; 15:1648407.
- Wang Y, Tong H, Zhu Z, Hou F, Li Y. Enhancing biomedical named entity recognition with parallel boundary detection and category classification. *BMC Bioinformatics*. 2025;26(1):63.
- Warrick PA, Hamilton EF, Precup D, Kearney RE. Classification of normal and hypoxic fetuses from systems modeling of intrapartum cardiotocography. *IEEE Trans Biomed Eng*. 2010;57(4):771-9.
- Warrick PA, Hamilton EF, Precup D, Kearney RE. Classification of normal and hypoxic fetuses using temporal differences of fetal heart rate features. *Med Biol Eng Comput*. 2010;48(9):873-83.
- Watanabe M, Eguchi A, Sakurai K, Yamamoto M, Mori C, Japan Environment Children's Study G. Prediction of gestational diabetes mellitus using machine learning from birth cohort data of the Japan Environment and Children's Study. *Sci Rep*. 2023;13(1):17419.
- Weinert LS. International Association of Diabetes and Pregnancy Study Groups recommendations on the diagnosis and classification of hyperglycemia in pregnancy: comment to the International Association of Diabetes and Pregnancy Study Groups Consensus Panel. *Diabetes Care*. 2010;33(7): e97.
- WHO. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: World Health Organization; 2021.
- Wiens J, Saria S, Sendak M, Ghassemi M, Liu VX, Doshi-Velez F, et al. Do no harm: a roadmap for responsible machine learning for health care. *Nat Med*. 2019;25(9):1337-40.
- Wiens J, Shenoy ES. Machine learning for healthcare: on the verge of a major shift in healthcare delivery? *JAMA*. 2018;319(13):1317-8.
- Williams K, et al. Ethical Considerations in AI-Assisted Gynecological Treatments. *Bioethics*. 2021;35(2):89-98.
- Wolff RF, Moons KGM, Riley RD, Whiting PF, Westwood M, Collins GS, et al. PROBAST: A Tool to Assess the Risk of Bias and Applicability of Prediction Model Studies. *Ann Intern Med*. 2019;170(1):51-8.
- World Health Organization. WHO recommendations: intrapartum care for a positive childbirth experience. Geneva: WHO; 2018.
- Wu YC, Chia-Yu Su E, Hou JH, Lin CJ, Lin KB, Chen CH. Artificial intelligence and assisted reproductive technology: A comprehensive systematic review. *Taiwan J Obstet Gynecol*. 2025;64(1):11-26.
- XIAO J, TAN Y, LI W, et al. Tumor volume reduction rate is superior to RECIST for predicting the pathological response of rectal cancer treated with neoadjuvant chemoradiation: Results from a prospective study. *Oncol Lett*. 2015; 9:2680-6.
- Yang CC, Wang CF, Lin WM, Chen SW, Hu HW. Evaluating the performance of an AI-powered VBAC prediction system within a decision-aid birth choice platform for shared decision-making. *Digit Health*. 2024; 10:20552076241235478.
- Yao W, Bai J, Liao W, Chen Y, Liu M, Xie Y. From CNN to transformer: A review of medical image segmentation models. *J Imaging Inform Med*. 2024;37(4):1529-47.
- Ye Y, Xiong Y, Zhou Q, Wu J, Li X, Xiao X. Comparison of Machine Learning Methods and Conventional Logistic Regressions for Predicting Gestational Diabetes Using Routine Clinical Data: A Retrospective Cohort Study. *J Diabetes Res*. 2020;2020: 4168340.
- Yoon HJ, Lee JB, Lee GS, Kim JW, Park BJ, Lee N, et al. Federated learning for predicting clinical outcomes in patients with COVID-19: multicenter development and validation study. *J Med Internet Res*. 2021;23(6):e24207.
- Yousefpour Shahrivar R, Karami F, Karami E. Enhancing Fetal Anomaly Detection in Ultrasonography Images: A Review of Machine Learning-Based Approaches. *Biomimetics (Basel)*. 2023;8(7):519.

- Zeng Z, Deng Y, Li X, Naumann T, Luo Y. Natural language processing for EHR-based computational phenotyping. *IEEE/ACM Trans Comput Biol Bioinform.* 2018;16(1):139-53.
- Zera CA, Seely EW. Controversies in Gestational Diabetes. *TouchREV Endocrinol.* 2021;17(2):102-7.
- Zhang F, Tong L, Shi C, Zuo R, Wang L, Wang Y. Deep Learning in Predicting Preterm Birth: A Comparative Study of Machine Learning Algorithms. *Matern Fetal Med.* 2024;6(3):141-6.
- Zhang L, et al. Cervical cancer diagnosis using deep learning and CNNs. *J Biomed Inform.* 2020;103:103383.
- Zhang Y, Wang J, Gorriz JM, Wang S. Deep learning and vision transformer for medical image analysis. *J Imaging.* 2023;9(6):147.
- Zheng S, Jayasumana S, Romera-Paredes B, Vineet V, Su Z, Du D, et al. Conditional random fields as recurrent neural networks. En: *Proceedings of the IEEE international conference on computer vision.* 2015. p. 1529-37.
- Zhou Z, Sodha V, Rahman Siddiquee MM, Feng R, Tajbakhsh N, Gotway MB, et al. Models genesis: Generic autodidactic models for 3d medical image analysis. En: *Medical Image Computing and Computer Assisted Intervention-MICCAI 2019: 22nd International Conference; Shenzhen, China.* Springer International Publishing; 2019. p. 384-93.
- Zhu H, Lin M, Xu Z, Yao Z, Chen H, Alhudhaif A, et al. Deconv-transformer (DECT): A histopathological image classification model for breast cancer based on color deconvolution and transformer architecture. *Inf Sci.* 2022; 608:1093-112.
- Zieliński K, Pukszta S, Mickiewicz M, Kotlarz M, Wygocki P, Zielen M, et al. Personalized prediction of the secondary oocytes number after ovarian stimulation: A machine learning model based on clinical and genetic data. *PLoS Comput Biol.* 2023;19(4): e1011037.

Autores



Luis Cabero Roura

- Especialidad en Ginecología y Obstetricia.
- Doctorado en Medicina y Cirugía y en Ciencias Biológicas.
- Director del Servicio de Obstetricia y Ginecología del Hospital Quirónsalud, Barcelona.
- Catedrático de Ginecología y Obstetricia, Universitat Autònoma de Barcelona.



Abel Guzmán López

- Especialidad en Ginecología y Obstetricia, UANL.
- Subespecialidad en Perinatología, UANL.
- Doctorado en Ciencias de la Salud con Disciplina en Salud Materno Infantil.
- Jefe y Profesor del Departamento de Ginecología y Obstetricia, Hospital Universitario “Dr. José Eleuterio González” de la UANL.
- Subdirector de la Torre HU, Facultad de Medicina y Hospital Universitario de la UANL.

	Manuel Albi ● Especialista vía MIR en Ginecología y Obstetricia, Universidad Complutense de Madrid. ● Profesor Asociado de Medicina y Cirugía, Universidad Rey Juan Carlos. ● Jefe del Departamento de Ginecología y Obstetricia, Hospitales con asistencia pública del grupo Quironsalud en Madrid.
	Cristina Caramés Sánchez ● Especialista en Oncología Médica, Hospital Universitario Fundación Jiménez Díaz, Universidad Autónoma de Madrid. ● Doctora en Medicina por la Universidad Autónoma de Madrid. ● Colaboradora docente, Universidad Autónoma de Madrid.
	Alba Farras Llobet ● Especialidad de Obstetricia y Ginecología, Hospital Universitari Vall d'Hebron. ● Doctorado, Universidad Autónoma de Barcelona. ● Colaboradora de proyectos de investigación en el área de Medicina Materna y Fetal, Hospital Universitari Vall d'Hebron.
	Sara Elena Garza Villarreal ● Maestría en Ciencias con especialidad en Sistemas Inteligentes, ITESM. ● Doctorado en Tecnologías de Información y Comunicaciones, ITESM. ● Profesora e Investigadora de la Facultad de Ingeniería Mecánica y Eléctrica.
	Luis Abel Guzmán Ochoa ● Especialidad en Ginecología y Obstetricia, UANL. ● Subespecialidad en Medicina Materno Fetal, UANL. ● Posgrado en Medicina Materno Fetal en Medicina Fetal Barcelona, Universidad de Barcelona. ● Profesor del Departamento de Ginecología y Obstetricia, Facultad de Medicina y Hospital Universitario “Dr. José Eleuterio González” de la UANL.

	Omar Alberto Hernández Barboza ● Especialidad en Ginecología, UANL. ● Curso de Alta Especialidad en Endoscopia Ginecológica, Hospital Universitario “Dr. José Eleuterio González” de la UANL. ● Profesor e Investigador del Departamento de Ginecología y Obstetricia, Facultad de Medicina y Hospital Universitario “Dr. José Eleuterio González” de la UANL.
	Leonardo Mancillas Adame ● Especialidad en Medicina Interna, Consejo Mexicano de Medicina Interna. ● Especialidad en Endocrinología, UNAM. ● Coordinador y Profesor del Servicio de Endocrinología, Facultad de Medicina y Hospital Universitario “Dr. José Eleuterio González” de la UANL.
	Miquel Martra Celma ● Especialidad Ginecología y Obstetricia. ● Postgrado en Medicina Fetal. ● Máster en Endoscopia Ginecológica. ● Médico Adjunto del Equipo Cabero i Roura, Obstetricia y Ginecología, Centro Médico Quirónsalud, Barcelona.
	Esther Martínez ● Especialista en Anestesiología, Reanimació i Clínica del Dolor. ● Master in Donation and Transplantation of Organs, Tissues and Cells. ● Directora Gerente Hospital Quirónsalud Barcelona.
	Nasser Mohamed Noriega ● Maestría en Ciencias de la Ingeniería Mecánica con Especialidad en Materiales, UANL. ● Doctor Rerum Naturalium, Technische Universität Dresden. ● Profesor Titular e Investigador de la Facultad de Ingeniería Mecánica y Eléctrica, UANL. ● Director de Innovación y Alianzas Estratégicas, UANL.

	Pablo Naval Baudín ● Doctorado en Medicina Traslacional: Neurociencias, Universitat de Barcelona. ● Neuroradiólogo e Investigador clínico, Bellvitge Hospital Universitari. ● Translational Imaging Biomarkers Group (IDIBELL). ● Radiólogo especialista, Hospital Quironsalud Barcelona. ● Departamento de Ciencias Clínicas, Universitat de Barcelona.
	Hilda Cristina Ochoa Bayona ● Doctorado por el Departamento de Medicina Preventiva y Salud Pública de la Universidad Complutense de Madrid. ● Jefe y Profesora del Departamento de Medicina Preventiva y Salud Pública, Facultad de Medicina y Hospital Universitario “Dr. José Eleuterio González” de la UANL. ● Titular de “Introducción a la Medicina” y “Estrategias de Promoción para la Salud”, Facultad de Medicina de la UANL.
	Erick de Jesús Ordaz Rivas ● Maestría en Ciencias de la Ingeniería Eléctrica, UANL. ● Doctorado en Ingeniería Eléctrica, UANL. ● Investigador de la Facultad de Ingeniería Mecánica y Eléctrica, UANL.
	Rodrigo Orozco Fernández ● Máster en Obstetricia y Ginecología, Universitat de Barcelona. ● Doctorado en Ginecología Oncológica, Universidad de Murcia. ● Jefe del Servicio de Obstetricia y Ginecología, Hospital Quirónsalud Málaga. ● Profesor Colaborador, Universidad de Málaga.
	Nadine Romera Lobato ● Jefe de Servicio de Diagnóstico por la Imagen, Hospital Quirónsalud Barcelona. ● Translational Imaging Biomarkers Group (IDIBELL). ● Departamento de Ciencias Clínicas, Universidad de Barcelona.

	Romeo Sánchez Nigenda ● Doctorado en Ciencias Computacionales, Arizona State University. ● Profesor Investigador de la Facultad de Ingeniería Mecánica y Eléctrica, UANL.
	María Ángeles Sánchez ● Especialidad de Obstetricia y Ginecología, Hospital Vall d'Hebron. ● Profesora asociada, Universidad Autónoma de Barcelona. ● Responsable de la Unidad de Diagnóstico Prenatal, Hospital Universitario Vall d'Hebron.
	Juan Antonio Soria López ● Especialidad en Ginecología y Obstetricia. ● Subespecialidad Perinatología. ● Jefe y Profesor del Servicio de Obstetricia, Facultad de Medicina y Hospital Universitario "Dr. José Eleuterio González" de la UANL.
	Luis Martín Torres Treviño ● Maestría en Ingeniería Eléctrica, UASLP. ● Doctorado en Inteligencia Artificial, ITESM. ● Investigador de la Facultad de Ingeniería Mecánica y Eléctrica, UANL.
	Emilio Modesto Treviño Salinas ● Especialidad en Ginecología y Obstetricia, UANL. ● Subespecialidad Oncología Ginecológica. ● Doctorado en Medicina. ● Jefe y Profesor del Servicio de Ginecología, Facultad de Medicina y Hospital Universitario "Dr. José Eleuterio González" de la UANL.



Javier de la Torre Fernández de Vega

- Especialidad en Ginecología y Obstetricia.
- Médico Adjunto al Servicio de Ginecología y Obstetricia, Hospital Vall d'Hebron.



IA. Medicina e ingeniería algoritmos que salvan vidas, de Luis Cabero Roura y Abel Guzmán López, terminó de imprimirse en octubre de 2022, en los talleres de Litográfica Ingramex, S.A. de C.V., Centeno 162-1, Col. Granjas Esmeralda, C.P. 09810, Ciudad de México. En su composición se utilizaron los tipos NewBskvll BT 8, 9, 10, 12, 13, 14, 15 y 48. El cuidado de la edición y diseño editorial estuvieron a cargo de la Dirección de Editorial Universitaria UANL. Diseño de portada de Verónica Rodríguez.



MEDICINA

ISBN 978-607-27-2720-5



9 786072 727205

La inteligencia artificial ya es parte de la consulta médica. ¿Estás listo para integrarla?

Este libro te lleva por un recorrido claro y accesible sobre cómo la IA está revolucionando la ginecología y obstetricia y demás especialidades. Desde apoyos en diagnóstico hasta asistentes en cirugía o predicción de riesgos, descubrirás cómo estas herramientas están cambiando la forma de cuidar la salud de la mujer y las personas gestantes. Ideal para profesionales, estudiantes y curiosos que quieren entender —sin tecnicismos— cómo la medicina y la tecnología se están encontrando.

