

UNIVERSIDAD AUTONOMA DE NUEVO LEON

FACULTAD DE MEDICINA



**“MODELO DE INTELIGENCIA ARTIFICIAL PARA LA ESTADIFICACIÓN
DE FRACTURAS DE RADIO DISTAL EN LA CLASIFICACIÓN DE LA AO”**

Por

DR. ABRAHAM VÁZQUEZ SALAS

**COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE
ESPECIALISTA EN ORTOPEDIA Y TRAUMATOLOGIA**


ENERO 2025

**“MODELO DE INTELIGENCIA ARTIFICIAL PARA LA ESTADIFICACIÓN
DE FRACTURAS DE RADIO DISTAL EN LA CLASIFICACIÓN DE LA AO”**

Aprobación de la tesis:



**Dr. Med Eduardo Álvarez Lozano
Director de la tesis**



**Dr. Med Santiago de la Garza Castro
Coordinador de Enseñanza**



**Dr. Med Carlos Acosta Olivo
Coordinador de Investigación**



**Dr. Med Víctor Manuel Peña Martínez
Jefe de Servicio o Departamento**



**Dr. med. Felipe Arturo Morales Martínez
Subdirector de Estudios de Posgrado**

DEDICATORIA Y AGRADECIMIENTOS

Con gratitud y entusiasmo, quiero dedicar estas palabras a quienes han sido pilares fundamentales en mi formación y en la realización de este trabajo.

En primer lugar, a mis padres, Abraham y Juany, por su amor incondicional y apoyo constante. Gracias por enseñarme el valor del esfuerzo, la perseverancia y la dedicación. Sin su guía no sería la persona que soy hoy en día. Su paciencia y sacrificio han sido mi mayor inspiración en la vida.

A mi asesor de tesis, quien a su vez es mi mentor, el Dr. Eduardo Álvarez Lozano, por su invaluable orientación. Su experiencia y consejos han sido clave tanto para el desarrollo de este trabajo como mi desarrollo como ortopedista. Aprecio profundamente su tiempo, sus enseñanzas y su confianza en mis capacidades. Gracias por ayudarme a crecer como profesional y como persona.

A Claudia por siempre estar disponible y contar con su apoyo, paciencia y palabras de ánimo en tiempos necesarios.

Finalmente, a los ingenieros Jorge, Julio, Jaime, Gerardo y Christopher, agradezco de su tiempo y sus conocimientos los cuales han contribuido a este proceso, y Alexa por su tiempo y disposición.

Con gratitud infinita, Abraham

TABLA DE CONTENIDO

Capítulo I	Página
1. RESÚMEN	1
Capítulo II	
2. INTRODUCCIÓN	1
Capítulo III	
3. OBJETIVO	
OBJETIVO GENERAL	6
DESCRIPCION DEL ALCANCE	6
JUSTIFICACION	7
Capítulo IV	
4. METODOLOGIA	8
Capítulo V	
5. RESULTADOS	10
Capítulo VI	
6. DISCUSION.	12
Capítulo VII	
7. CONCLUSION	13
ABREVIATURAS	15

ANEXOS	16
FIGURAS	19
BIBLIOGRAFIA	24

Capítulo I. Resumen

Las clasificaciones de fracturas han evolucionado desde tiempos antiguos hasta la actualidad. En 1987, la fundación AO creó su clasificación para estandarizar la manera en que comunicamos los distintos tipos de fracturas. Con el avance de la inteligencia artificial (IA), se han logrado avances en la interpretación de imágenes médicas. Este proyecto busca desarrollar un modelo de inteligencia artificial para clasificar fracturas de radio distal, siguiendo la clasificación AO.

El modelo se basó en un popular algoritmo para la detección de imágenes, utilizando radiografías de radio distal para entrenar el modelo. Tras varias iteraciones de prueba y error, el modelo alcanzó una precisión de hasta el 74%. Sin embargo, se identificaron limitaciones en la calidad de las bases de datos y la experiencia en IA del equipo. Este trabajo marca la pauta para el futuro desarrollo de este modelo y su posterior implementación en la práctica médica y la educación.

Capítulo II. Introducción

Las clasificaciones de fracturas han existido casi por tanto tiempo como desde que hemos podido identificarlas, inclusive desde antes del uso de las radiografías. Incluso en el texto médico más antiguo, el papiro de Edwin Smith, se describe una clasificación rudimentaria de fracturas que las clasificaba en cerradas o expuestas. A través de los años, las clasificaciones han cumplido varios propósitos: agrupar

las fracturas de acuerdo con sus características anatómicas, guiar tratamiento o predecir resultados de tratamiento. (1)

Actualmente la mayor parte de las clasificaciones se basan en observadores analizando radiografías del hueso fracturado, el observador debe tener la habilidad de identificar por completo y de manera precisa las líneas de fractura, entender el origen y naturaleza de los fragmentos fracturados y analizar la relación entre los fragmentos consigo mismos. (1)

Existen diferentes escalas para clasificar las fracturas de los huesos, el problema era que estas clasificaciones eran desorganizadas y no ayudaban para hacer comparaciones, por lo que era necesario una clasificación universalmente aplicable y aceptada por lo que Maurice E Müller y asociados aceptaron la monumental tarea de hacer una clasificación que resolviera estos problemas. (3)

Previo a 1958 el manejo de las fracturas carecía de un enfoque estandarizado, una práctica rudimentaria que variaba ampliamente entre regiones y tratantes, basándose ampliamente en el "tratamiento conservador", método popularizado y documentado por el Dr. Lorenz Böhler, el cual consistía en el uso de tracciones e inmovilización con férulas y moldes de yeso, los cuales tenían como objetivo lograr la consolidación, no así la recuperación de la funcionalidad y la congruencia anatómica, por lo que los resultados clínicos no siempre eran los mejores. (4)

Esta situación fue abordada por un grupo de cirujanos austriacos y suizos, encabezados por Maurice Müller, Robert Schneider, Hans Willenegger y Martin Allgöwer, quienes ante la falta de difusión de conocimientos sobre principios biomecánicos y biológicos de la consolidación los llevo a fundar en 1958 en la ciudad de Biel, Suiza la fundación AO (Arbeitsgemeinschaft für

Osteosynthesefragen, asociación para el estudio de la fijación interna, por sus siglas en alemán) la cual inicio como un grupo con una corriente de pensamiento encaminada a las técnicas quirúrgicas ortopédicas y la cual, a través de la investigación, educación y desarrollo tecnológico buscaba estandarizar y revolucionar las prácticas en la ortopedia para mejorar los resultados funcionales y reducir las tasas de complicaciones en el tratamiento de las fracturas. (5)

La fundación AO tiene así mismo un enfoque educativo y de investigación, organizando cursos y talleres que tienen vigencia hoy en día, los cuales contribuyen en gran medida a la difusión de sus principios en todo el mundo. (4)

Como parte del objetivo de la estandarización del tratamiento de las fracturas se creó la clasificación AO de fracturas, previo a la creación de esta, los médicos se enfrentaban a la falta de un lenguaje en común debido a que la terminología para describir las fracturas era muy heterogénea, especialmente en el contexto internacional, sin una estructura para agrupar las fracturas, era difícil valorar la magnitud de la lesión, lo que resultaba en estrategias de tratamiento inconsistentes, lo cual arrojaba resultados clínicos impredecibles y a su vez entorpecía la investigación clínica y la educación. Como se mencionó previamente en respuesta a estos problemas, Müller y colaboradores se dieron a la tarea de crear en 1987 la "Clasificación integral de fracturas de huesos largos", la cual consiste en un código alfanumérico de 5 elementos que nos permite dar una descripción detallada y constante de una fractura. (4, 2)

Esta clasificación fue unificada y extendida con el Comité de Codificación y Clasificación de la Asociación de Trauma Ortopédica (OTA por sus siglas en ingles) en 1996 siguiendo los principios de clasificación originales para el resto de

los huesos del cuerpo. Esta ha sido revisada en 2006, agregando clasificaciones pediátricas y nuevamente en 2018 perfeccionando la clasificación a como la conocemos hoy en día, proporcionando un instrumento universal que no solo mejora la práctica clínica con relación a las fracturas, sino que mejora también la manera en que hacemos investigación y enseñanza. (2)

La inteligencia artificial (IA) es un término general que implica el uso de un modelo computacional con comportamiento inteligente con mínima intervención humana, la inteligencia artificial, particularmente el Deep Learning, ha hecho grandes pasos en el procesamiento de imágenes, permitiendo una mejor representación e interpretación de datos complejos (6). El uso de inteligencia artificial en el sector público ha crecido y tiene un gran impacto en cada aspecto de la atención médica (7).

La aplicación de la inteligencia artificial en medicina tiene dos ramas: virtual y física. El componente virtual está representado por el Deep Learning, que este compuesto por los algoritmos matemáticos que mejoran el aprendizaje a través de la experiencia. La rama física de aplicación de la inteligencia artificial en medicina incluye objetos físicos, dispositivos médicos y robots que forman parte de la prestación del servicio de salud (8).

El Deep Learning es una familia de métodos el cual forma parte del campo del Machine Learning, que a su vez forma parte de un más amplio campo de la inteligencia artificial. Estos algoritmos se rigen bajo la idea de aprender a través de la experiencia en lugar de seguir instrucciones precisas (6).

Cada capa primaria está compuesta por un número de neuronas que hasta cierto punto imitan la actividad de una célula neuronal, cada neurona tiene su

propio peso, y cada peso define que tanta influencia tiene sobre el resultado. La capa donde cada conexión posible entre entrada y salida se juntan se llama la "capa densa". Existen otros tipos de capas como la "capa convolucional", "capa marginal", "capa de agrupación", todas estas capas forman parte del Deep Learning y ayudan a resolver problemas utilizando algoritmos de optimización. El proceso descrito representa 1 ciclo de entrenamiento de red neuronal. Durante el proceso de entrenamiento del modelo cada imagen de la base de datos de entrenamiento contribuye a la optimización del proceso. Por lo tanto, el modelo de Deep Learning resuelve los problemas aprendiendo de los datos (6).

Trabajos previos que utilizaron redes neuronales de Deep Learning para asistir en el diagnostico medico han mostrado resultados prometedores en áreas como clasificación de lesiones mamarias en mamografías, detección de tuberculosis pulmonar en radiografías de tórax, clasificación de retinopatía diabética, y categorización de lesiones cutáneas (9, 10).

Varios estudios han trabajado con algoritmos para identificar fracturas y comparándolo contra médicos especialistas y no especialistas, estos estudios han demostrado un nivel de precisión adecuado, inclusive a niveles casi perfecto. La precisión reportada en una serie de 7 estudios fue de un 83% hasta un 98% para fracturas de cadera y humero proximal (11). Otro estudio demostró una sensibilidad significativamente menor para identificar fracturas no desplazadas, esto probablemente se daba a que la detección se basa en una proporción menor de pixeles en la imagen entera (9).

La utilización de algoritmos de inteligencia artificial para la identificación y diagnóstico de fracturas relativamente obvias puede ser de utilidad en casos en

los que las fracturas pueden ser pasadas por alto, por ejemplo, en pacientes politraumatizados en los cuales las prioridades diagnosticas pueden ser otras, o en los casos de atención primaria o de urgencias en los cuales un especialista pudiera no estar disponible inmediatamente (11).

Capitulo III. Objetivo

Objetivo general

Se trata de un trabajo de desarrollo tecnológico el cual tiene como objetivo general crear un modelo de inteligencia artificial que desde una radiografía pueda clasificar los tipos de fractura de radio distal (extraarticular, articular parcial y articular completa) de manera simple y rápida. Este modelo se corresponde con un nivel de madurez tecnológica 3.

Descripción del Alcance

Este trabajo representa la primera etapa de un proyecto cuya finalidad es un software que clasifique las fracturas de los diferentes huesos del esqueleto apendicular dentro de la clasificación de la AO, en esta primera etapa se trabajara específicamente con fracturas de radio distal. Dentro de los límites cubiertos se abarca el desarrollo de un modelo de detección de objetos para la clasificación de fracturas de radio distal según la clasificación AO de adulto utilizando radiografías simples en proyección anteroposterior y lateral de muñeca.

En cuanto a los límites no cubiertos la clasificación de fracturas de otras partes del cuerpo humano, y la comparación del desempeño del modelo de inteligencia artificial contra el desempeño por el ojo experto.

Justificación

Una de las causas más comunes de errores diagnósticos en los servicios de urgencias son fracturas no diagnosticadas, y previamente se han diseñado modelos de detección de imágenes que detectan fracturas, no obstante, nuestro trabajo marcará la pauta y estadificará las fracturas según la clasificación descrita por la AO, mejorando así la calidad de la atención médica. (12)

Así mismo, en los últimos años, el uso de inteligencia artificial ha aumentado y con gran impacto en el ámbito educativo, en la cual ha contribuido en importantes avances, mejorando los procesos administrativos, personalizando la enseñanza y optimizando el aprendizaje de los estudiantes, y tiene el potencial de eliminar barreras para la educación, automatizar los procesos educativos y fomentar la toma de decisiones basada en evidencia. (13)

Uno de los campos en la educación con mayor impacto por la inteligencia artificial es el área administrativa, la cual se refiere a la revisión de proyectos, calificar, dar retroalimentación a los estudiantes en trabajos con el uso de plataformas inteligentes, detección de plagio mediante herramientas como TurnItIn. Realizando lo anterior en una fracción de tiempo y esfuerzo que le tomaría al instructor sin estas herramientas. (13)

En la enseñanza no es muy diferente, mediante herramientas o plataformas que facilitan el aprendizaje, como el uso de instrucción basada en la simulación, que

se puede apoyar del uso de dispositivos de realidad virtual que expone al estudiante a una experiencia educacional practica revolucionaria e integral. Otro uso es la interacción con chatbots para consultar dudas rutinarias o incluso para distribuir material bibliográfico, siempre a la mano, incluso fuera del salón de clases. (13)

Finalmente, desde la perspectiva del estudiante, el aprendizaje también ha sufrido influencia por la inteligencia artificial, con el uso de diferentes plataformas para personalizar la educación de acuerdo al perfil del estudiante pasando por la detección de rubros en los cuales el estudiante pudiera estar rezagado con posterior refuerzo en la materia, otras aplicaciones que usan algoritmos machine Learning pueden hacer en tiempo real recomendaciones a los estudiantes basados en sus estilos de aprendizaje descifrados por estos mismos modelos. (13)

En concreto podemos aseverar que la inteligencia artificial ha tenido y seguirá teniendo un gran impacto en todos los ámbitos de la educación, teniendo el potencial de transformar los procesos educativos a como los conocemos ahora, a medida que el número de estudiantes y el número de instituciones educativas crece, la inteligencia artificial quita un gran peso de encima y facilita las tareas de los educadores, permitiendo que estos se concentren en áreas de oportunidad y en aquellos alumnos que necesiten una atención más personalizada. (13)

Capitulo IV. Metodología

El inicio de nuestro proyecto se basó en una búsqueda tecnológica usada para asistir el diagnóstico médico por estudios de imagen mediante inteligencia artificial, dentro de lo encontrado, lo más parecido a nuestro proyecto es una patente que describe un modelo que utiliza radiografías de tórax, que previo etiquetado por un médico radiólogo puede detectar fracturas vertebrales (Anexo técnico 1), metodología similar a la llevada a cabo en este proyecto.

Para la creación de un sistema de Deep Learning se describen clásicamente tres etapas: preprocesamiento; esta etapa se refiere al manejo de la base de datos que servirá para entrenar nuestro modelo, significa que estos archivos deberán ser modificados para que el aprendizaje del sistema se lleve a cabo de la mejor manera posible, la siguiente etapa es la de entrenamiento; en esta etapa vamos a seleccionar un modelo predictivo el cual se adapte mejor a nuestras necesidades y exponerlo a nuestra base de datos para entrenarlo, finalmente, la etapa de evaluación; posterior a entrenar nuestro modelo, podemos utilizar el set de datos de prueba para estimar el rendimiento de nuestro modelo y si estamos satisfechos con el mismo, entonces estamos listos para predecir datos futuros. (figura 1) (14)

Actualmente nos encontramos en la etapa de preprocesamiento de nuestro trabajo, se comenzó utilizando como base de datos una serie de radiografías con fractura de radio distal esqueléticamente maduro, esto último, comúnmente definido como la mineralización de la placa de crecimiento y fusión de la epífisis con la metáfisis (13), posteriormente estas radiografías son etiquetadas según la clasificación de la AO como "2R3A" (extraarticulares), "2R3B" (articular parcial) o "2R3C" (articular completa), este etiquetado será realizado por el investigador principal y el tesista por medio de la plataforma supervisely.

Son definidas como fracturas extraarticulares aquellas en las cuales el trazo de fractura no involucre la superficie articular, fractura articular parcial la cual involucra una parte de la articulación, mientras que la porción no afectada se encuentra conectada a la metáfisis y diáfisis sana y fractura articular completa es aquella con una disrupción en la superficie articular y esta se encuentra completamente separada de la diáfisis (2).

Para la etapa de entrenamiento se trabajará con YOLOv5 que es la 5ta versión de un modelo popular de detección de objetos dentro de una imagen con un enfoque de una sola etapa y que estima clasificaciones con un puntaje directo desde la imagen aportada con la ayuda de una red neuronal convolucional simple, la cual cuenta con, 24 capas convolucionales y 2 capas completamente conectadas (16). La base de datos de la etapa de preprocesamiento será dividida en dos grupos: el grupo de datos de entrenamiento (80% de los datos), utilizada para hacer que el modelo aprenda por su propia cuenta y el grupo de datos de prueba (20% de los datos) que será utilizado en la etapa de evaluación.

Finalmente en la etapa de evaluación utilizaremos el grupo de datos de prueba para validar nuestro modelo según la métrica precisión promedio (mAP), la cual es la métrica más comúnmente usada para medir el desempeño de los modelos de detección de objetos (17, 18), en caso de que nuestro modelo cumpla con los estándares esperados significa que está listo para clasificar nuevas imágenes de fracturas de radio distal, en caso de que no sea así, nos regresaremos a las de preprocesamiento y entrenamiento para cambiar la estrategia.

Capitulo V. Resultados

Se realizo la primera versión entrenando el modelo con radiografías en proyección anteroposterior (AP) y lateral de muñeca con fracturas de radio distal para un total de 110 imágenes con la siguiente distribución: extraarticulares 65 imágenes, articular completas 30 y articular parcial 12, destinados 80% para entrenamiento y 20% para la validación. Los resultados obtenidos fueron malos, por lo que se decidió cambiar ciertas partes de la metodología.

Para la segunda versión del modelo se cambio a la plataforma Roboflow, la cual es una plataforma en línea para desarrolladores de modelos de inteligencia artificial, esta nos ofrece más herramientas para mejorar el desempeño de nuestro modelo. Para esta versión incluimos un mayor número de radiografías para un total de 110 imágenes distribuidas de la siguiente manera: extraarticulares 65, articular completas 30 y articular parcial 12, así mismo para esta versión incluimos estrategias para aumentación de datos (data augmentation) como lo son voltear horizontal y verticalmente y la rotación, para simular diferentes posiciones en que el modelo puede leer una radiografía. Los resultados obtenidos de esta segunda versión fueron mejores que los obtenidos en la primera versión, sin embargo, aún no estábamos satisfechos con los mismos.

Para la tercer y final versión cambiamos la estrategia utilizando solo radiografías en proyección AP y aumentamos nuestra base de datos a 360 radiografías, incluyendo también radiografías de radio distal sin fractura, con una mediana de dimensiones de 283x432 pixeles y un promedio de tamaño de 0.12

megapíxeles, las radiografías distribuidas de la siguiente manera: 112 radiografías de fracturas articulares completas, 108 radiografías de fracturas extraarticulares, 58 radiografías de fracturas parcialmente articulares y 82 radiografías sin fractura (figura 2), nuevamente se utilizaron estrategias de aumentación de datos como voltear la imagen horizontal y verticalmente y la rotación. Se utilizó una distribución de 88% para entrenar el modelo, 8% para validar el mismo y 4% para ponerlo a prueba (figura 3).

Para esta nueva versión, el modelo YOLOv5 fue entrenado con la base de datos previamente descrita a 100 ciclos, obtenido mejores y aceptables resultados: precisión de 57.7% y una precisión promedio de 65%. Entre clases, la precisión promedio para las radiografías con fracturas extraarticulares fue de 70%, para las radiografías con fracturas parcialmente articulares fue de 52% y la precisión promedio para fracturas completamente articulares fue tan alta como de 74% (Figuras 4 y 5).

Capítulo VI. Discusión

Una limitante importante es la calidad de la base de datos con la que se trabajó, en primer lugar con la cantidad de radiografías disponibles: a pesar de que los números son buenos, no se puede trabajar con cualquier radiografía y se tienen que descartar cualquier imagen que pueda confundir nuestro modelo, por ejemplo, fracturas consolidadas, fracturas en no unión, radiografías con material de osteosíntesis en la fractura, radiografías que elementos radiopacos que se

interpongan en la fractura, radiografías en las cuales la placa de crecimiento del radio distal sea visible, dando por resultado una base de datos más limitada en tamaño.

Otra limitante es el conocimiento y experiencia previa limitada en el rubro de la inteligencia artificial por parte del tesista y del investigador principal, que, a pesar de contar con asesoría de un equipo experto en el tema, se requiere de cierto grado de conocimiento y entrenamiento, esta inexperiencia condiciona un desarrollo más basado en el ensayo y error, provocando que el desarrollo del proyecto sea más tórpido y lento.

Se pretende seguir con esta línea de trabajo, los planes a futuro son extendernos a clasificar, no solo la parte distal del radio, si no, otras partes dentro del mismo radio y posteriormente otros huesos hasta completar toda la economía del sistema musculoesquelético para poder complementar lo realizado y llevar el proyecto a un nivel más grande.

Capítulo VII. Conclusión

En el presente trabajo se expone una herramienta que tiene el potencial de clasificar fracturas no solo de radio distal, si no otras partes de la economía del sistema esquelético, exponiendo sus posibles aplicaciones dentro del ámbito asistencial y más importantemente en la enseñanza médica, teniendo en cuenta que es posible aumentar su precisión, otros autores nos dejan en claro que este tipo de herramientas con el uso de inteligencia artificial pueden competir con el ojo

experto, trabajos a futuro deben validar esta herramienta, al comparar el desempeño de este modelo frente al ojo humano en diferentes jerarquías académicas. Concluimos que es un proyecto con un potencial de explotación para innovar en las maneras en que procesamos la información hoy en día en los ámbitos previamente mencionados.

LISTA DE ABREVIATURAS

AO: Arbeitsgemeinschaft für Osteosynthesefragen, asociación para el estudio de la fijación interna, por sus siglas en alemán.

IA: inteligencia artificial.

OTA: Asociación de Trauma Ortopédica por sus siglas en inglés.

AP: anteroposterior.

mAP: precisión promedio.

ANEXOS

Anexo 1

REPORTE DE BÚSQUEDA TECNOLÓGICA

Folio _____
 Fecha 3 mayo 2022
 No. Páginas _____
 Realizada por: Jorge A. Bernal Chávez

Título del proyecto Algoritmo de identificación de facturas en la clasificación AO en fracturas de radio distal

Inventores _____

Objetivo de la búsqueda Identificar los algoritmos de IA para la identificación de fracturas de radio distal

Descripción de la invención Algoritmo de inteligencia artificial para la clasificación rápida y precisa de fracturas bajo la nomenclatura de la AO

CIP (Clasificación Internacional de Patentes) G06K9/62, G06K9/00; G06N20/00; G06N3/08; G06T7/00 G06N3/02; G06T7/00; G06T7/70; G16H30/40

Bases de datos donde se realizó la búsqueda ESPACENET, LENS

Estrategia de búsqueda machine learning AND fractures AND bones OR distal radius

ID	Categoría*	Documentos citados, con indicación de partes relevantes	Relevante en rev. no.	CIP (cuando aplique)	Fecha
US2022198230A1	Y	AUXILIARY DETECTION METHOD AND IMAGE RECOGNITION METHOD FOR RIB FRACTURES BASED ON DEEP LEARNING	2, 4, 5 y 8-10	G06K9/62	Jun, 2022

US 10475182 B1	Y	Application of deep learning for medical imaging evaluation	1, 3 y 5	G06K9/00; G06N20/00 ; G06N3/08; G06T7/00	Nov, 2019
<u>US20213</u> <u>83536A1</u>	Y	SPINAL FRACTURE DETECTION IN X-RAY IMAGES	1, 6, 17	G06K9/62; G06N3/02; G06T7/00; G06T7/70; G16H30/40 ;	Dic, 2021

* A L O	Categorías especiales de documentos citados: Documento que define el estado general de la técnica no considerado como particularmente relevante. Documento que puede plantear dudas sobre una reivindicación de una prioridad o que se cita para determinar la fecha de publicación de otra cita o por una razón especial (como la indicada) Documento que se refiere a una divulgación oral, a una utilización, a una exposición o cualquier otro medio.	X	Documento particularmente relevante; la invención reivindicada no puede considerarse nueva o que implique una actividad inventiva por referencia al documento aisladamente considerado.
		Y	Documento particularmente relevante; la invención reivindicada no puede considerarse que implique una actividad inventiva cuando el documento se asocia a otro u otros documentos de la misma naturaleza, cuya combinación resulta evidente para un experto en la materia.

Observaciones, recomendaciones y/o conclusiones.	<p>En base con la información proporcionada, se entiende que el presente dispositivo consiste en un algoritmo de inteligencia artificial para la detección de fracturas de radio distal en base a la clasificación de la AO para su clasificación, con las características que es rápido y preciso en la identificación y clasificación</p> <p>De acuerdo con la búsqueda tecnológica realizada, se encontraron:</p> <ul style="list-style-type: none"> Se implementa un modelo de segmentación basado en una red neuronal denominada UNET donde de entrada se marca el área de fractura de costilla tomada de una imagen de TAC de tórax simple. Emplea parámetros de píxel para determinar la distancia real de la fractura, además se entrena con imágenes en espejo para expandir su entrenamiento en busca de un umbral de confianza grande. Se presenta un método para desarrollar un sistema de aprendizaje profundo para detectar y localizar anomalías en
--	--

	<p>TC de cabeza sin contraste. Utiliza una arquitectura que se modifica con múltiples capas interconectadas de una red neuronal. Las anomalías médicas que comprende son, entre muchas otras, fracturas de cráneo y fracturas calvariales.</p> <ul style="list-style-type: none"> • Comprende un método que recibe la imagen de rayos X de tórax, identifica la pluralidad de vértebras las cuales serán segmentadas en "parches" donde podemos etiquetar si hay una vértebra fractura o una vértebra no fracturada. Se utiliza una radiografía de tórax frontal y una radiografía de tórax lateral para su entrenamiento. Es de importancia realizar un "parchado" correcto por el radiólogo ya que se tiene que hacer hincapié en la morfología de las vértebras para el entrenamiento profundo para la identificación de fracturas de vértebras. <p>Cabe aclarar que la información presentada en este reporte de búsqueda está sujeta a los comentarios que se presenten por el inventor, por lo que se le invita a realizar retroalimentación respecto a éstos, por el medio que usted considere.</p>
<p>Resolución obtenida por el comité</p>	

Notas:

*: El presente documento se refiere a una búsqueda tecnológica, lo que NO significa que el proyecto en cuestión ya se encuentra en proceso de solicitud de patente.

* La información derivada de la búsqueda no substituye ni exenta de ninguna forma a la que se realiza en el examen de fondo de la solicitud

FIGURAS

Figura 1

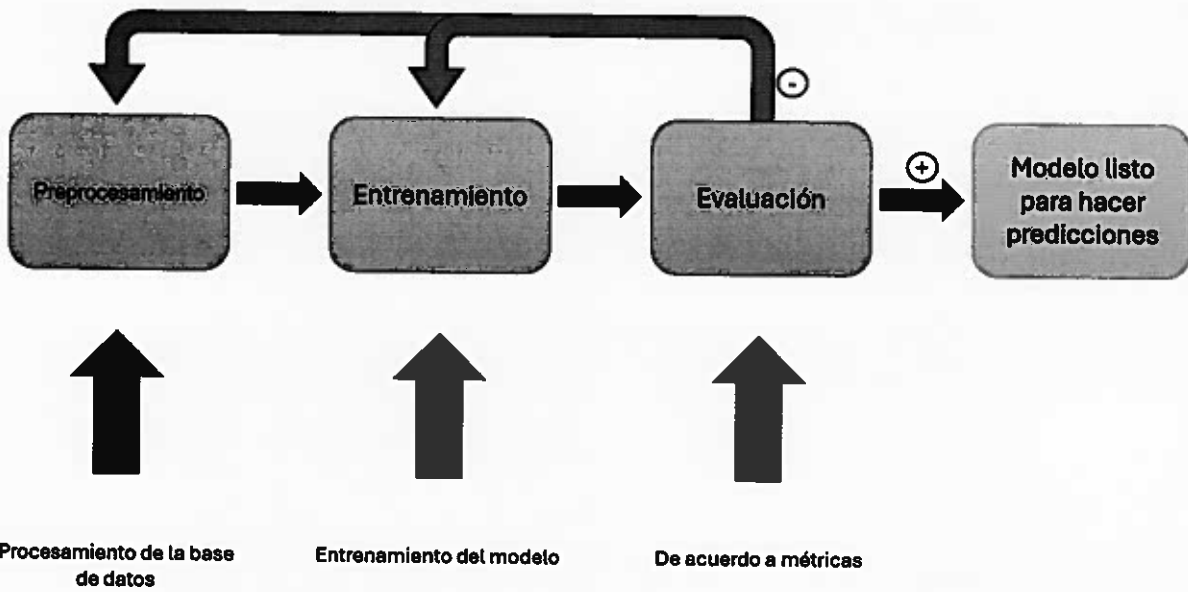


Figura 2




Figura 3

Dataset Split



Figura 4

Average Precision by Class (mAP50)



Figura 5



BIBLIOGRAFÍA

1. Court-Brown C. M. Heckman J. D. McQueen M. M. Ricci W. M. Tornetta P. & McKee M. D. (2015). *Rockwood and green's fractures in adults* (Eighth). Wolters Kluwer Health.
2. Meinberg, E. G., Agel, J., Roberts, C. S., Karam, M. D., & Kellam, J. F. (2018). Fracture and Dislocation Classification Compendium-2018. *Journal of orthopaedic trauma*, 32 Suppl 1, S1–S170. <https://doi.org/10.1097/BOT.0000000000001063>
3. Buckley, R.E., Moran, C.G. and Apivatthakakul, T. (2017) in *Ao principles of fracture management*. Davos Platz, Switzerland: AO Foundation.
4. Hirschfeld, Beryl, "The History of the treatment by extension of fractures of long bones" (1938). MD Theses. 663.
5. Colton, C.. (2002). The AO phenomenon: foundation and early years of the Association for the Study of Internal Fixation (ASIF).: Edited by Urs F. A. Heim. Pp 246. Bern, etc: Verlag Hans Huber, 2002.
6. Kalmet, P. H. S., Sanduleanu, S., Primakov, S., Wu, G., Jochems, A., Refaee, T., Ibrahim, A., Hulst, L. V., Lambin, P., & Poeze, M. (2020). Deep learning in fracture detection: a narrative review. *Acta orthopaedica*, 91(2), 215–220. <https://doi.org/10.1080/17453674.2019.1711323>
7. Amisha, Malik, P., Pathania, M., & Rathaur, V. K. (2019). Overview of artificial intelligence in medicine. *Journal of family medicine and primary care*, 8(7), 2328–2331. https://doi.org/10.4103/jfmpc.jfmpc_440_19
8. Hamet, P. and Tremblay, J. (2017) 'Artificial Intelligence in medicine', *Metabolism*, 69.
9. Thian YL, Li Y, Jagmohan P, Sia D, Chan VEY, Tan RT. Convolutional Neural Networks for Automated Fracture Detection and Localization on Wrist Radiographs. *Radiol Artif Intell*. 2019 Jan 30;1(1):e180001. doi: 10.1148/ryai.2019180001. PMID: 33937780; PMCID: PMC8017412.
10. Kim, D. H., & MacKinnon, T. (2018). Artificial intelligence in fracture detection: transfer learning from deep convolutional neural networks. *Clinical radiology*, 73(5), 439–445.
11. Langerhuizen D. W. G., Janssen, S. J., Mallee, W. H., van den Bekerom, M. P. J., Ring, D., Kerkhoffs, G. M. M. J., Jaarsma, R. L., & Doornberg, J. N. (2019). What Are the Applications and Limitations of Artificial Intelligence for Fracture Detection and Classification in Orthopaedic Trauma Imaging? A Systematic Review. *Clinical orthopaedics and related research*, 477(11), 2482-2491.
12. Pinto, A., Reginelli, A., Pinto, F., Lo Re, G., Midiri, F., Muzj, C., Romano, L., & Brunese, L. (2016). Errors in imaging patients in the emergency setting. *The British journal of radiology*, 89(1061), 20150914. <https://doi.org/10.1259/bjr.20150914>
13. L. Chen, P. Chen and Z. Lin. (2020). "Artificial Intelligence in Education: A Review," in *IEEE Access*, vol. 8, pp. 75264-75278
14. Raschka, S. (2015). "Giving Computers the Ability to Learn from Data". In *Python Machine Learning* (pp. 1–16). essay, Birmingham, UK: Packt Publishing.
15. Aja-Fernández, S., De Luis-García, R., Martín-Fernández, M. A., & Alberola-López, C. (2004). A computational TW3 classifier for skeletal maturity assessment. A Computing with Words approach. *Journal of biomedical informatics*, 37(2), 99–107.

16. Sultana, F., Sufian, A., & Dutta, P. (2020). A review of object detection models based on convolutional neural network. *Intelligent Computing: Image Processing Based Applications*, 1-16
17. R. Padilla, S. L. Netto and E. A. B. da Silva, "A Survey on Performance Metrics for Object-Detection Algorithms," 2020 International Conference on Systems, Signals and Image Processing (IWSSIP), Niteroi, Brazil, 2020, pp. 237-242
18. Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*