

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE MEDICINA Y HOSPITAL UNIVERSITARIO “DR JOSÉ
ELEUTERIO GONZÁLEZ”.



UANL

PRECISIÓN DE LOS ALGORITMOS DEEP LEARNING EN EL
DIAGNÓSTICO DE ESQUIZOFRENIA: REVISIÓN SISTEMÁTICA Y
METAANÁLISIS

Por

DR. ANDONI GOGASCOECHEA HERNÁNDEZ

Como requisito parcial para obtener el Grado de ESPECIALIDAD EN
PSIQUIATRÍA

Diciembre, 2025



UANL

**PRECISIÓN DE LOS ALGORITMOS DEEP LEARNING EN EL
DIAGNÓSTICO DE ESQUIZOFRENIA: REVISIÓN SISTEMÁTICA Y
METAANÁLISIS**

Por

DR. ANDONI GOGASCOECHEA HERNÁNDEZ

**COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE
ESPECIALIDAD EN PSIQUIATRÍA**

DR. MED. ERASMO SAUCEDO URIBE

DIRECTOR DE TESIS

DR. MED. ALFREDO BERNARDO CUELLAR BARBOZA

COORDINADOR DE ENSEÑANZA

DR. MED. ERASMO SAUCEDO URIBE

COORDINADOR DE INVESTIGACIÓN

DR. STEFAN MAURICIO FERNÁNDEZ ZAMBRANO

JEFE DEL DEPARTAMENTO

DR. MED. FELIPE ARTURO MORALES MARTÍNEZ

SUBDIRECTOR DE ESTUDIOS DE POSGRADO



UANL

**PRECISIÓN DE LOS ALGORITMOS DEEP LEARNING EN EL
DIAGNÓSTICO DE ESQUIZOFRENIA: REVISIÓN SISTEMÁTICA Y
METAANÁLISIS**

**Este trabajo fue realizado en el Hospital Universitario “Dr. José Eleuterio
González” en el departamento de Psiquiatría y el campus universitario de la salud
de la Universidad Autónoma de Nuevo León, bajo la dirección del Dr. med Erasmo
Saucedo Uribe**

Dr. med Erasmo Saucedo Uribe

Director de tesis

AGRADECIMIENTOS

Al Departamento de Psiquiatría, por enseñarme a dudar con inteligencia, a escuchar con humildad y a trabajar con responsabilidad.

A la Universidad Autónoma de Nuevo León, por una formación sólida y por el espacio donde desarrollé criterio y disciplina.

A mis profesores y mentores, gracias por las exigencias que marcaron mi forma de trabajar.

A mis padres, Antonio y Raquel, no existen palabras para expresar lo que les debo. Su forma de enfrentar la vida y de mantenerse firmes en sus principios ha sido un modelo en mi desarrollo personal y profesional. Gracias por estar ahí siempre, incluso cuando no sabía cómo pedir ayuda, y por enseñarme que uno no se rinde, aunque cueste.

A Tony, que siempre ha estado un paso adelante, abriendo camino para todos sin esperar reconocimiento. La mayoría de mis decisiones y mi forma de trabajar nacen del ejemplo que me has dado y tu vida me ha servido de guía más veces de las que te imaginas.

A Antonella, gracias porque siempre has sabido decir lo que se necesita, incluso cuando no es lo que quiero oír. Me has confrontado con verdades que necesitaba escuchar. Tus consejos y tu forma de ver el mundo han sido un regalo en los días buenos y un salvavidas en los días malos.

A Tavo, Armando, Óscar, David y Javier, porque su amistad ha sido un soporte en distintas etapas. Gracias por la lealtad; siempre van a tener un espacio en mi mesa.

A Monserratt, tu presencia trajo tanta claridad y paz a mi vida que me diste ese impulso para seguir adelante. Gracias por tu ternura, por tu compañía y por tu amor sin juicios.

Por recordarme que incluso en medio del caos, hay alguien que cree en mí y camina conmigo. Tu presencia representa un antes y un después en mi vida.

DEDICATORIA

*A mi familia,
todo por y para ustedes.*

ÍNDICE

Índice

1. Lista de Abreviaturas	8
2. Lista de Tablas	9
3. Resumen	10
4. Abstract	11
5. Introducción	12
6. Marco Teórico / Justificación	14
6.1 Bases neurobiológicas de la esquizofrenia.	14
6.2 Modalidades de neuroimagen relevantes para el diagnóstico asistido.	14
6.3 Inteligencia artificial y Deep Learning en neuroimagen.	15
6.4 Utilidad clínica y retos actuales.	16
6.5 Justificación del estudio.	16
7. Materiales y Métodos	18
7.1 Diseño del estudio.	18
7.2 Criterios de elegibilidad.	18
7.3 Estrategia de búsqueda.	18
7.4 Selección de estudios.	19
7.5 Extracción de datos.	19
7.6 Evaluación de calidad metodológica.	19
7.7 Síntesis estadística y metaanálisis diagnóstico.	20
7.8 Software utilizado.	20
7.9 Consideraciones éticas.	20
8. Resultados	21
8.1 Descripción general del proceso de búsqueda y selección.	21
8.2 Características de los estudios incluidos.	21
8.3 Revisión Sistemática	22
8.4 Resultados del metaanálisis diagnóstico.	24
8.4.1 <i>Electroencefalograma (EEG).</i>	25

8.4.2 <i>Resonancia magnética estructural (sMRI).</i>	29
8.4.3 <i>Resonancia magnética funcional (fMRI).</i>	32
8.5 Comparación entre modalidades.	35
8.6 Hallazgos principales.	35
9. Discusión	36
9.1 Interpretación general de los hallazgos	36
9.2 Comparación con la literatura previa.	37
9.3 Implicaciones clínicas.	37
9.4 Limitaciones del estudio.	38
9.5 Fortalezas del estudio.	38
9.6 Líneas de investigación futura.	39
10. Conclusiones	40
11. Anexos	41
12. Referencias	52

LISTA DE ABREVIATURAS

AUC: Área Bajo la Curva

BOLD: Blood-Oxygen-Level-Dependent

CNN: Convolutional Neural Network

DL: Deep Learning

DSM: *Diagnostic and Statistical Manual of Mental Disorders*

EEG: Electroencefalografía

fMRI: Resonancia Magnética Funcional

FN: Falso Negativo

FP: Falso Positivo

GCN: Graph Convolutional Network

ICA: Independent Component Analysis

LSTM: Long Short-Term Memory

MRI: Magnetic Resonance Imaging

PRISMA: *Preferred Reporting Items for Systematic Reviews and Meta-Analyses*

QUADAS-2: *Quality Assessment of Diagnostic Accuracy Studies – 2*

REML: *Restricted Maximum Likelihood*

ROC: Receiver Operating Characteristic

ROI: Región de Interés

sMRI: Resonancia Magnética Estructural

SROC: *Summary Receiver Operating Characteristic*

TN: Verdadero Negativo

TP: Verdadero Positivo

LISTA DE TABLAS

- Tabla 1. Características generales de los estudios incluidos
- Tabla 2. Métricas diagnósticas por estudio.
- Tabla 3. Resultados del metaanálisis por modalidad
- Tabla 4. Evaluación de riesgo de sesgo mediante QUADAS-2

RESUMEN

La esquizofrenia es un trastorno psiquiátrico complejo que continúa representando retos importantes para su diagnóstico oportuno. En los últimos años, el uso de inteligencia artificial, en particular, de las redes neuronales convolucionales, ha cobrado relevancia como posible herramienta complementaria en el análisis de EEG, resonancia magnética estructural (sMRI) y funcional (fMRI).

El objetivo de esta tesis fue evaluar la precisión diagnóstica de estos modelos mediante una revisión sistemática y un metaanálisis diagnóstico. Se incluyeron 35 estudios publicados entre 2019 y 2024. Los análisis se realizaron con modelos bivariados y curvas SROC para estimar sensibilidad y especificidad agrupadas.

Los resultados muestran que los modelos aplicados a EEG obtuvieron el mejor desempeño, con estimaciones altas y consistentes. La sMRI presentó también resultados favorables, aunque con una variabilidad importante entre estudios. La fMRI, en comparación, mostró valores más modestos y una heterogeneidad considerable.

En conjunto, los hallazgos indican que la inteligencia artificial tiene un papel prometedor como apoyo diagnóstico, especialmente utilizando EEG, aunque aún se requieren estudios con mayor estandarización, muestras amplias y validación externa.

ABSTRACT

Schizophrenia remains a major diagnostic challenge due to its heterogeneous presentation and reliance on clinical assessment. Recent advances in artificial intelligence, particularly convolutional neural networks, have opened the possibility of using EEG, structural MRI (sMRI), and functional MRI (fMRI) as complementary diagnostic tools.

This thesis conducted a systematic review and diagnostic meta-analysis to evaluate the accuracy of these models. Thirty-five studies published between 2019 and 2024 were included. Pooled sensitivity and specificity were estimated using a bivariate random-effects model, accompanied by SROC analyses.

Models based on EEG achieved the highest diagnostic performance, showing robust and consistent results. Structural MRI also demonstrated good performance but with considerable heterogeneity. Functional MRI presented more modest and variable outcomes.

Overall, findings suggest that deep learning offers promising diagnostic assistance, particularly when applied to EEG, although future research must address issues of standardization, external validation, and interpretability.

5. INTRODUCCIÓN

La esquizofrenia es un trastorno mental grave y altamente discapacitante que continúa representando uno de los retos clínicos más complejos dentro de la psiquiatría. Aunque su prevalencia global se mantiene cercana al 1% de la población, su impacto trasciende esa cifra: suele iniciar en etapas tempranas de la vida adulta, interfiere con el desarrollo personal, social y laboral, y con frecuencia provoca deterioro funcional progresivo. Todo ello contribuye a una carga significativa para los pacientes, sus familias y los sistemas de salud [1–3].

A lo largo de las últimas décadas, se ha ampliado la comprensión de la esquizofrenia como un espectro heterogéneo más que como una entidad única. Diversas líneas de investigación han descrito alteraciones estructurales, funcionales y electrofisiológicas que se relacionan con sus manifestaciones clínicas. Entre estas, se han documentado cambios en la estructura cortical y subcortical, patrones atípicos de conectividad funcional y anomalías en ritmos neuronales, especialmente en bandas gamma y beta [4–9]. Estos hallazgos han llevado a considerar la posibilidad de identificar biomarcadores que ayuden a complementar el diagnóstico clínico tradicional.

A pesar de estos avances, el diagnóstico de esquizofrenia sigue dependiendo, en esencia, de la evaluación clínica directa. Las entrevistas psiquiátricas, el análisis del curso de la enfermedad y la observación conductual continúan siendo los pilares del proceso diagnóstico. Esta forma de valoración, aunque indispensable, presenta limitaciones: la variabilidad interobservador, la superposición de síntomas con otros trastornos y la ausencia de marcadores biológicos validados contribuyen a retrasos diagnósticos y a una menor precisión en etapas tempranas.

La neuroimagen y el registro electroencefalográfico han cobrado relevancia como métodos complementarios para explorar la fisiopatología del trastorno. El EEG permite observar la dinámica eléctrica cerebral con alta resolución temporal; la resonancia magnética estructural (sMRI) ofrece información anatómica precisa; y la resonancia magnética funcional (fMRI) facilita el estudio de la organización funcional de redes

cerebrales. Cada modalidad aporta perspectivas distintas sobre los procesos neurobiológicos subyacentes [5–9].

En paralelo, el desarrollo acelerado de la inteligencia artificial y, en particular, del Deep Learning ha transformado la forma en que se analizan datos biomédicos. Las redes neuronales convolucionales (CNN) han demostrado una capacidad destacada para identificar patrones complejos en imágenes médicas y en señales de alta dimensionalidad sin necesidad de seleccionar características manualmente [10,11]. En los últimos años, esta tecnología se ha aplicado con creciente frecuencia al análisis de EEG, sMRI y fMRI en esquizofrenia, reportando resultados alentadores y, en algunos casos, superiores a los de técnicas tradicionales de machine learning [12–14].

Sin embargo, aunque la literatura ha crecido de forma considerable, los estudios muestran una notable heterogeneidad: utilizan arquitecturas distintas, tamaños de muestra variables, modalidades diversas y aproximaciones metodológicas que no siempre son comparables entre sí. Esta variación ha dificultado obtener una impresión clara y generalizable del desempeño real de estos modelos.

Frente a ello, surge la necesidad de una síntesis rigurosa que no solo recopile la evidencia, sino que la evalúe de manera sistemática. El metaanálisis diagnóstico permite estimar de forma integrada la sensibilidad, especificidad y capacidad discriminativa de los modelos, y comparar el rendimiento entre modalidades.

Con base en esto, el objetivo de esta tesis es ofrecer una evaluación actualizada y estructurada del desempeño de las CNN aplicadas a EEG, sMRI y fMRI para el diagnóstico de esquizofrenia. A través de una revisión sistemática y un metaanálisis diagnóstico, se busca identificar qué modalidades y enfoques presentan los mejores resultados, cuáles son las principales limitaciones metodológicas y qué implicaciones tienen estos hallazgos para la integración futura de la inteligencia artificial en la práctica psiquiátrica.

6. MARCO TEÓRICO / JUSTIFICACIÓN

6.1 Bases neurobiológicas de la esquizofrenia

La esquizofrenia es un trastorno complejo que afecta distintos niveles de organización cerebral. Las investigaciones más recientes han demostrado de manera consistente alteraciones estructurales, sobre todo en regiones frontotemporales, así como variaciones en la sustancia blanca y en la morfología cortical. Estos hallazgos se han relacionado con déficits cognitivos, dificultades en la regulación emocional y la aparición de síntomas característicos del trastorno [5–7]. En el plano funcional, la resonancia magnética funcional ha permitido describir patrones anómalos de conectividad en diversas redes cerebrales que participan en procesos ejecutivos, atención, integración perceptual y regulación emocional. Estas alteraciones se han observado tanto en reposo como durante tareas cognitivas, lo que sugiere una disfunción persistente en la comunicación entre regiones cerebrales [7].

En el ámbito electrofisiológico, la electroencefalografía ha documentado alteraciones en ritmos neuronales, con mayor evidencia en bandas gamma y beta, que se han asociado con dificultades en la integración perceptual, el procesamiento de estímulos y ciertas funciones cognitivas centrales en el trastorno [8,9]. La ventaja del EEG es su capacidad para capturar la actividad neuronal con una resolución temporal de milisegundos, lo que lo convierte en una herramienta particularmente útil para estudiar la dinámica de las redes cerebrales.

En conjunto, esta evidencia refuerza la idea de que la esquizofrenia involucra múltiples niveles de disfunción neurológica. Esta característica, aunque compleja, abre la puerta a identificar patrones o biomarcadores capaces de complementar el proceso diagnóstico tradicional.

6.2 Modalidades de neuroimagen relevantes para el diagnóstico asistido

Las diferentes modalidades de neuroimagen y electrofisiología ofrecen perspectivas complementarias sobre el funcionamiento cerebral. El EEG permite observar la actividad eléctrica cerebral con alta precisión temporal, lo que facilita el análisis de patrones dinámicos relacionados con procesos cognitivos. La resonancia magnética estructural

proporciona información detallada sobre la anatomía cerebral y permite identificar cambios volumétricos o morfológicos que han sido descritos en diversos estudios como características asociadas al trastorno. Por su parte, la resonancia magnética funcional ofrece la posibilidad de estudiar la organización y dinámica de las redes neuronales mediante la señal BOLD, que refleja cambios en la oxigenación sanguínea vinculados a la actividad neuronal.

Cada una de estas modalidades constituye una ventana distinta para comprender la fisiopatología de la esquizofrenia. Su análisis mediante herramientas avanzadas permite integrar información estructural, funcional y temporal, algo que hasta hace algunos años era difícil de lograr con aproximaciones convencionales [5–9].

6.3 Inteligencia artificial y Deep Learning en neuroimagen

Antes de que el Deep Learning se volviera dominante, los estudios en neuroimagen dependían de la extracción manual de características y del uso de algoritmos tradicionales de aprendizaje automático. Aunque estas técnicas aportaron evidencia valiosa, también presentaban limitaciones relevantes: requerían seleccionar de manera explícita cuáles características analizar —lo cual podía introducir sesgos importantes— y tenían dificultades para captar relaciones complejas en datos de alta dimensionalidad [10–12].

El surgimiento de las redes neuronales convolucionales transformó este panorama. Las CNN permiten aprender representaciones jerárquicas directamente de los datos, sin necesidad de especificar manualmente qué patrones deben buscarse. Esto ha resultado especialmente útil en imágenes médicas, señales temporales y datos volumétricos. Su capacidad para identificar relaciones no lineales y para combinar información espacial y temporal ha permitido lograr desempeños superiores a muchos métodos convencionales [10,11].

En el campo de la esquizofrenia, las CNN se han aplicado con creciente frecuencia al análisis de EEG, sMRI y fMRI, con resultados prometedores. Diversos estudios han reportado sensibilidades y especificidades altas, aunque también se ha observado una gran variedad de enfoques metodológicos, arquitecturas y procedimientos de validación [12–

14]. Esta heterogeneidad ha dificultado comparar los resultados entre estudios y extraer conclusiones claras sobre el rendimiento real de cada modalidad.

6.4 Utilidad clínica y retos actuales

Aunque los avances en Deep Learning son alentadores, su implementación en la práctica clínica todavía enfrenta desafíos importantes. Uno de ellos es la gran variabilidad en los procedimientos de adquisición y preprocesamiento de datos, lo que provoca diferencias notables en los resultados entre estudios. Otro aspecto crítico es la falta de validación externa rigurosa: en muchos estudios, los modelos se evalúan únicamente en los mismos datos que se utilizaron para entrenarlos, lo que limita su generalización y puede inflar artificialmente las métricas diagnósticas. A esto se suma el riesgo de sobreajuste que se presenta con frecuencia en muestras pequeñas, donde el modelo puede aprender patrones específicos del conjunto de entrenamiento en lugar de características generalizables del trastorno.

También existen dificultades relacionadas con la interpretabilidad de los modelos. Aunque las CNN pueden alcanzar desempeños altos, no siempre es claro qué características del cerebro están influyendo en sus decisiones, lo cual representa un reto importante para su adopción clínica. Finalmente, la heterogeneidad entre estudios —particularmente en sMRI y fMRI— sigue siendo uno de los principales obstáculos para evaluar con precisión el verdadero potencial de estas tecnologías.

A pesar de estas limitaciones, la posibilidad de utilizar modelos que integren información neurobiológica objetiva y que complementen la entrevista psiquiátrica representa una oportunidad valiosa para mejorar la precisión diagnóstica y la detección temprana en psiquiatría.

6.5 Justificación del estudio

El rápido crecimiento de estudios que aplican Deep Learning al diagnóstico de esquizofrenia ha generado un campo de literatura amplio, pero con una notable variabilidad metodológica. Esto hace necesario un análisis sistemático que permita

evaluar de manera rigurosa la evidencia disponible, identificar patrones consistentes y comparar el rendimiento entre modalidades.

El presente estudio surge de esta necesidad. A través de una revisión sistemática y un metaanálisis diagnóstico, se busca sintetizar la información más reciente sobre el desempeño de las CNN aplicadas a EEG, sMRI y fMRI, identificar las fortalezas y limitaciones más frecuentes, y evaluar su potencial utilidad en el contexto clínico. El propósito es ofrecer una visión clara, actualizada y fundamentada que permita orientar tanto la práctica clínica como futuras líneas de investigación en el campo de la inteligencia artificial aplicada a la psiquiatría.

7. MATERIALES Y MÉTODOS

7.1 Diseño del estudio

Este trabajo se desarrolló como una revisión sistemática y un metaanálisis diagnóstico enfocados en evaluar el desempeño de modelos de Deep Learning, en particular redes neuronales convolucionales (CNN), aplicados a EEG, resonancia magnética estructural (sMRI) y funcional (fMRI) para el diagnóstico de esquizofrenia.

La revisión se llevó a cabo conforme a las recomendaciones de la declaración PRISMA 2020 [52], y el protocolo fue registrado previamente en PROSPERO (CRD42024550691). Esto permitió asegurar un procedimiento transparente y reproducible desde el inicio.

7.2 Criterios de inclusión

Se incluyeron estudios realizados en adultos con diagnóstico de esquizofrenia confirmado por DSM o CIE, comparados con controles sanos. Se consideraron trabajos que emplearan EEG, sMRI o fMRI, y que aplicaran modelos de Deep Learning basados explícitamente en arquitecturas tipo CNN o variantes relacionadas. Para poder ser analizados, los estudios debían reportar información suficiente para reconstruir matrices de confusión, es decir, valores de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos.

Se excluyeron los estudios que carecían de datos diagnósticos suficientes, los trabajos sin modelos de red neuronal, investigaciones en animales, revisiones narrativas y publicaciones que no utilizaran neuroimagen o EEG.

7.3 Estrategia de búsqueda

La búsqueda bibliográfica se realizó en las bases de datos PubMed, Scopus, Web of Science e IEEE Xplore, abarcando todos los registros disponibles hasta diciembre de 2024. Se emplearon términos relacionados con esquizofrenia, Deep Learning, CNN, EEG, resonancia magnética y diagnóstico asistido, combinados mediante operadores booleanos.

Adicionalmente, se revisaron referencias de artículos relevantes identificados durante la búsqueda primaria con el objetivo de localizar trabajos potencialmente pasados por alto.

7.4 Selección de estudios

Todos los registros fueron exportados a un gestor bibliográfico para eliminar duplicados. Posteriormente, dos revisores evaluaron de manera independiente los títulos y resúmenes, y cuando fue necesario, analizaron el texto completo. Cualquier discrepancia se resolvió por consenso.

El proceso completo se organizó y documentó siguiendo el flujo de PRISMA 2020 [52].

7.5 Extracción de datos

La extracción se realizó mediante un formato previamente diseñado para este estudio. Se recopiló información sobre el año de publicación, país, tamaño de muestra, modalidad de neuroimagen utilizada, arquitectura del modelo de Deep Learning, procedimientos de preprocesamiento, tipo de validación y valores específicos de TP, FP, TN y FN. También se registraron las métricas diagnósticas reportadas, incluyendo sensibilidad, especificidad y área bajo la curva.

Cada registro fue revisado por dos personas de forma independiente para asegurar la coherencia y exactitud de los datos.

7.6 Evaluación de calidad metodológica

La calidad de los estudios incluidos se valoró con la herramienta QUADAS-2, adaptada para estudios que emplean inteligencia artificial [53]. Este instrumento permite identificar riesgos de sesgo en la selección de participantes, en la aplicación del estándar de referencia, en la interpretación de las pruebas índice y en el flujo general del estudio.

Para estudios de Deep Learning se añadieron consideraciones específicas, como el riesgo de *data leakage*, el tamaño de la muestra y la claridad en la separación entre conjuntos de entrenamiento, validación y prueba, dado que estos elementos influyen directamente en el riesgo de sobreajuste.

7.7 Síntesis estadística y metaanálisis diagnóstico

El metaanálisis se realizó utilizando el modelo bivariado de Reitsma, que permite estimar simultáneamente la sensibilidad y especificidad y modelar la correlación entre ambas [54]. Las métricas fueron transformadas mediante logit para estabilizar varianzas y posteriormente se ajustaron modelos de efectos aleatorios con máxima verosimilitud restringida (REML), lo cual es apropiado para datos con heterogeneidad entre estudios.

Además, se generaron curvas ROC resumen (SROC) para cada modalidad (EEG, sMRI y fMRI) y se calcularon intervalos de confianza del 95 %. La heterogeneidad se evaluó mediante τ^2 e I^2 , lo que permitió describir la variabilidad entre estudios más allá del error muestral.

7.8 Software utilizado

Todos los análisis se realizaron en R versión 4.4.3 (2025-02-28) [54]. Para los procedimientos estadísticos se utilizaron los paquetes metafor [55] y mada [56], mientras que la elaboración de gráficas y visualizaciones se realizó con ggplot2 [57].

7.9 Consideraciones éticas

No fue necesaria la aprobación de un comité de ética, ya que este estudio se basó exclusivamente en datos previamente publicados y no involucró información identificable de participantes.

8. RESULTADOS

8.1 Descripción general del proceso de búsqueda y selección

La búsqueda sistemática inicial identificó un total de 2,915 registros provenientes de las cuatro bases de datos consultadas. Tras eliminar duplicados y revisar títulos y resúmenes, se seleccionaron 203 artículos para lectura a texto completo. Finalmente, 35 estudios cumplieron con los criterios de elegibilidad y fueron incluidos tanto en la síntesis cualitativa como en el metaanálisis diagnóstico (15–51), abarcando publicaciones entre 2019 y 2024.

En términos generales, la distribución temporal de los estudios mostró un incremento importante en los últimos cuatro años, lo cual coincide con el crecimiento del uso de Deep Learning en investigación neuropsiquiátrica. Los trabajos incluidos provinieron principalmente de Asia, Europa y Norteamérica, con predominio de centros académicos especializados en neuroimagen y análisis computacional.

8.2 Características de los estudios incluidos

Los 35 estudios presentaron una amplia variedad en sus tamaños de muestra, con investigaciones pequeñas que incluían menos de 40 participantes y otras que empleaban bases de datos más amplias con varios cientos de imágenes. La mayoría comparó pacientes con esquizofrenia confirmada clínicamente con controles sanos, sin coexistencia de trastornos psiquiátricos.

En cuanto a las modalidades utilizadas, el EEG fue la más frecuente, seguido por la resonancia magnética estructural. La resonancia magnética funcional apareció en menor proporción, aunque varios trabajos la emplearon junto con modelos basados en grafos o arquitecturas destinadas al análisis de conectividad funcional. La diversidad también estuvo presente en las arquitecturas de las redes neuronales, que incluyeron CNN bidimensionales, CNN tridimensionales, modelos híbridos como CNN-LSTM, y redes basadas en grafos y transformers.

Los enfoques metodológicos fueron igualmente variados. Mientras algunos estudios emplearon validaciones cruzadas exhaustivas, otros usaron divisiones simples de entrenamiento y prueba. Solo unos pocos reportaron validación externa, lo que refleja un área que aún debe fortalecerse dentro de este campo.

8.3 Revisión Sistemática

En la muestra final del metaanálisis se incluyeron 35 estudios que aplicaron modelos de deep learning basados en CNN para el diagnóstico de esquizofrenia utilizando tres modalidades principales de neuroimagen: EEG, fMRI y sMRI. Al analizar la distribución por tipo de dato, quince estudios emplearon EEG como estudio principal, lo que representa aproximadamente 42.9 % del total; catorce utilizaron fMRI (40.0 %) y seis se basaron en sMRI (17.1 %). En varios trabajos, especialmente aquellos centrados en fMRI y sMRI, la clasificación de la modalidad se realizó de acuerdo con el tipo de dato predominante utilizado en el modelo índice considerado para el metaanálisis, aun cuando en el artículo original se reportaran análisis adicionales con combinaciones multimodales. De este modo, la síntesis cuantitativa se centró en tres categorías claramente definidas: EEG, sMRI y fMRI.

Los tamaños de muestra mostraron una variabilidad considerable entre estudios. El número de participantes por artículo osciló entre 28 y 1,642 sujetos, con una mediana de 128 y un total acumulado de 9,550 participantes. Con base en las matrices de confusión reportadas, se estimó que, en conjunto, los modelos se entrenaron y evaluaron sobre aproximadamente 4,909 casos de esquizofrenia y 4,611 controles sanos. La mayoría de los trabajos incluyó únicamente población adulta, generalmente adultos jóvenes y de mediana edad, de manera coherente con la epidemiología típica de la enfermedad. Aunque algunos estudios distinguieron subgrupos clínicos específicos —por ejemplo, primeros episodios psicóticos—, esta información no se reportó de forma homogénea y rara vez se presentaron análisis estratificados por edad o sexo, lo que limita la posibilidad de comparar de manera sistemática el desempeño de los modelos entre distintos subgrupos demográficos.

En cuanto a las arquitecturas de deep learning utilizadas, todos los estudios incluyeron alguna variante de CNN como componente central del modelo, aunque con diferencias importantes en profundidad, dimensionalidad y configuraciones adicionales. En el conjunto de estudios analizados se identificaron CNN bidimensionales aplicadas a mapas derivados de neuroimagen, CNN tridimensionales diseñadas para explotar la información volumétrica de sMRI o fMRI, y modelos híbridos que combinaban CNN con componentes recurrentes tipo LSTM. También se encontraron arquitecturas inspiradas en transformers —como variantes tipo Vision Transformer o LeViT—, así como modelos de tipo graph CNN aplicados a matrices de conectividad funcional. Un número relevante de trabajos empleó CNN preentrenadas (por ejemplo, basadas en arquitecturas como VGG, ResNet o AlexNet) como extractores de características que posteriormente se adaptaban a la tarea de clasificación de esquizofrenia. Paralelamente, varios grupos desarrollaron arquitecturas personalizadas optimizadas para su base de datos y modalidad específica, incluyendo redes diseñadas ad hoc para EEG o sMRI.

De forma complementaria, la mayoría de los artículos incorporó modelos de aprendizaje automático tradicional como comparadores, aun cuando el foco principal del estudio se centrara en CNN u otras arquitecturas de deep learning. Entre los algoritmos más utilizados se encontraron máquinas de vectores de soporte, regresión logística, bosques aleatorios y, con menor frecuencia, métodos basados en boosting como XGBoost. De manera consistente, los modelos basados en CNN superaron el desempeño de estos algoritmos tradicionales en prácticamente todos los estudios incluidos, con muy pocas excepciones. Además, los trabajos que combinaron CNN con componentes recurrentes o con mecanismos de atención tipo transformer tendieron a reportar las métricas diagnósticas más altas, lo que sugiere que las arquitecturas híbridas, capaces de integrar información espacial, temporal y de conectividad, podrían representar la línea de desarrollo más prometedora dentro del campo de la neuroimagen aplicada al diagnóstico de esquizofrenia.

Los estudios que utilizaron EEG reportaron resultados particularmente consistentes y superiores en comparación con otras modalidades. Esto podría deberse a que la señal

eléctrica, al tener una estructura temporal rica y estable, facilita la identificación de patrones mediante filtros convolucionales.

Los estudios basados en sMRI mostraron un desempeño elevado, pero con una heterogeneidad mucho mayor entre ellos. Las diferencias entre escáneres, protocolos de adquisición, algoritmos de segmentación y pipelines de preprocesamiento probablemente influyeron en estas variaciones.

Por su parte, los modelos basados en fMRI presentaron el desempeño más variable. La señal funcional se ve influida por factores fisiológicos, cognitivos y metodológicos, lo que aumenta la complejidad del análisis. Aun así, algunos trabajos que emplearon arquitecturas especializadas en conectividad, como redes basadas en grafos, lograron resultados competitivos.

8.4 Resultados del metaanálisis.

Se realizó un metaanálisis para evaluar la precisión diagnóstica de las modalidades de neuroimagen (EEG, fMRI y sMRI) en la identificación de esquizofrenia. Se extrajeron los datos a nivel de estudio, incluyendo verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN) y falsos negativos (FN). Para cada estudio, se calcularon la sensibilidad y la especificidad, y posteriormente se transformaron mediante logit para estabilizar las varianzas.


Los metaanálisis de efectos aleatorios se llevaron a cabo por separado para cada modalidad utilizando el método de máxima verosimilitud restringida (REML) implementado en el paquete metafor, con el cual se estimaron las sensibilidades y especificidades agrupadas con intervalos de confianza del 95 %, así como los índices de heterogeneidad (τ^2 , I^2). Con el fin de modelar la distribución conjunta de sensibilidad y especificidad y considerar la correlación entre ambas, se ajustó un modelo bivariado de Reitsma utilizando el paquete mada.

Para cada modalidad se generaron curvas ROC resumen (SROC), y también se construyeron gráficos combinados para comparar visualmente el rendimiento diagnóstico entre los distintos tipos de neuroimagen. En las figuras se mostraron los puntos correspondientes a cada estudio individual, las estimaciones agrupadas y las curvas SROC derivadas del modelo, con el objetivo de ilustrar la variabilidad diagnóstica tanto dentro de cada modalidad como entre ellas.


8.4.1 EEG

El EEG fue la modalidad con mejor desempeño. La sensibilidad agrupada alcanzó un valor de 0.906, mientras que la especificidad se estimó en 0.903. La curva SROC correspondiente mostró un AUC de 0.959, lo cual refleja un desempeño discriminativo muy alto. La heterogeneidad observada fue moderada, lo que sugiere estabilidad relativa entre los estudios incluidos.



EEG Sensitivity



EEG Specificity




EEG Meta-analytic SROC




8.4.2 Resonancia magnética estructural (sMRI)



La sMRI también mostró un desempeño robusto, con una sensibilidad de 0.894 y una especificidad de 0.885, acompañadas de un AUC de 0.946. Sin embargo, la heterogeneidad entre estudios fue considerablemente más alta que en el EEG. Esta variabilidad probablemente se debe a diferencias en equipos, parámetros de adquisición, métodos de segmentación, y en general, a la falta de estandarización entre estudios.



sMRI Specificity




sMRI Meta-analytic SROC




8.4.3 Resonancia magnética funcional (fMRI)



La fMRI fue la modalidad con el desempeño más modesto. La sensibilidad agrupada fue de 0.822 y la especificidad de 0.841, con un AUC de 0.898. Además, presentó una heterogeneidad notablemente mayor que la encontrada en EEG y sMRI. Esta variabilidad coincide con la complejidad inherente al análisis de la señal BOLD, así como con las diferencias metodológicas entre estudios funcionales.



fMRI Specificity



fMRI Meta-analytic SROC



8.5 Comparación entre modalidades

El contraste entre las tres modalidades permitió identificar una tendencia clara. Los modelos basados en EEG no sólo fueron los más precisos, sino también los más consistentes. La sMRI mostró un rendimiento elevado, aunque con mayor dispersión en sus resultados. La fMRI, aunque informativa desde un punto de vista fisiológico, mostró un desempeño menos uniforme, influido por la variabilidad en paradigmas, artefactos y métodos analíticos.

Estos patrones coinciden con trabajos recientes que señalan que cada modalidad aporta un tipo de información diferente y que el EEG, por su naturaleza accesible y por la estructura de sus señales, suele ofrecer un mejor equilibrio entre precisión y robustez [12–14].

8.6 Hallazgos principales

Los resultados del presente estudio permiten afirmar que las redes neuronales convolucionales muestran un desempeño prometedor en el diagnóstico asistido de esquizofrenia, especialmente al analizar señales de EEG. La sMRI ofrece también un rendimiento elevado, aunque su heterogeneidad limita la posibilidad de extrapolar conclusiones sin una estandarización más estricta. Finalmente, la fMRI continúa siendo una modalidad valiosa para investigar la fisiopatología del trastorno, pero su precisión diagnóstica es más variable y depende fuertemente de factores metodológicos.

En conjunto, estos hallazgos muestran que la inteligencia artificial tiene un papel potencial como herramienta complementaria en el diagnóstico, pero también subrayan la necesidad de fortalecer los diseños metodológicos, ampliar las muestras y aumentar los estudios con validación externa para lograr una integración clínica real.

9. DISCUSIÓN

9.1 Interpretación general.

El análisis realizado en esta tesis permite obtener una visión clara sobre el desempeño de los modelos basados en redes neuronales convolucionales aplicados al EEG, a la resonancia magnética estructural y a la resonancia magnética funcional para el diagnóstico de esquizofrenia. Los resultados muestran que el Deep Learning ha logrado avances significativos en este campo, especialmente cuando se utiliza información proveniente del EEG. Esta modalidad, al capturar de manera directa la actividad eléctrica cerebral con alta resolución temporal, parece ofrecer un terreno particularmente favorable para los modelos convolucionales, que son capaces de identificar patrones temporales y espaciales difíciles de reconocer por métodos convencionales.

En cambio, aunque los modelos basados en resonancia magnética estructural también alcanzaron una precisión elevada, su desempeño fue más variable. Esta variabilidad probablemente se relaciona con diferencias entre escáneres, secuencias empleadas, parámetros de adquisición y procesos de preprocesamiento que influyen directamente en la imagen final. Además, la sMRI representa un tipo de señal más estática, lo que limita la posibilidad de capturar aspectos dinámicos del funcionamiento cerebral.

Por su parte, la resonancia magnética funcional mostró el desempeño más modesto entre las modalidades evaluadas. Esto no resulta sorprendente, ya que la señal BOLD presenta fluctuaciones complejas relacionadas con múltiples factores fisiológicos y metodológicos. A ello se suman diferencias notables entre los estudios en cuanto a paradigmas utilizados, duración de las adquisiciones, eliminación de artefactos y estrategias de análisis. Aun así, algunos trabajos recientes con arquitecturas especializadas en conectividad funcional lograron resultados competitivos, lo que indica que el campo todavía tiene un margen de desarrollo importante.

9.2 Comparación con la literatura previa

Los resultados del presente estudio coinciden con observaciones previamente reportadas en la literatura internacional. Diversas revisiones han señalado que, dentro Deep Learning aplicado a la esquizofrenia, las señales de EEG suelen ser especialmente adecuadas para los modelos convolucionales debido a su estructura temporal rica y a la posibilidad de representar la información en distintos dominios, como tiempo-frecuencia o mapas topográficos. La estabilidad relativa de estas señales podría explicar el rendimiento más consistente que se observó en este metaanálisis.

En cuanto a la sMRI y la fMRI, la variabilidad encontrada en este estudio también refleja lo reportado en investigaciones anteriores. La falta de estandarización entre centros de adquisición, la diversidad en los procesos de segmentación y normalización, y la variedad de arquitecturas utilizadas dificultan la comparación directa entre estudios. En el caso de la fMRI, la complejidad inherente de la señal BOLD se suma a estas variaciones metodológicas, lo que tiende a generar resultados menos uniformes. A pesar de ello, algunas líneas de investigación recientes han mostrado que modelos basados en grafos y arquitecturas híbridas son capaces de aprovechar la información dinámica y de conectividad, lo que podría abrir nuevas posibilidades para esta modalidad.

9.3 Implicaciones clínicas

Uno de los aspectos más relevantes de estos hallazgos es su posible aplicación en la práctica clínica. Aunque el diagnóstico de esquizofrenia sigue dependiendo del juicio clínico, de la entrevista psiquiátrica y del análisis longitudinal de los síntomas, existe un interés creciente por incorporar herramientas objetivas que puedan complementar este proceso, especialmente en etapas tempranas o en casos de presentación atípica. En este sentido, los modelos basados en EEG destacan como los candidatos más sólidos para facilitar una integración clínica futura. Su costo accesible, su portabilidad y su uso extendido en múltiples entornos clínicos ofrecen ventajas claras sobre otras modalidades de neuroimagen.

La sMRI podría servir como herramienta complementaria cuando se cuente con infraestructura adecuada, aunque su variabilidad actual limita su uso directo en entornos clínicos sin una estandarización más rigurosa. La fMRI, por su parte, enfrenta desafíos prácticos importantes: su alto costo, sus requerimientos técnicos y la sensibilidad de la señal a factores externos dificultan su implementación rutinaria. Aun así, su valor para comprender la fisiopatología del trastorno y para desarrollar modelos predictivos complejos sigue siendo significativo.

9.4 Limitaciones del estudio

A pesar de la rigurosidad de la metodología empleada, este estudio presenta varias limitaciones que deben considerarse al interpretar los resultados. Una de las más importantes es la heterogeneidad entre los estudios incluidos. Las diferencias en tamaños de muestra, características de los participantes, parámetros de adquisición y arquitecturas de red influyen directamente en las métricas diagnósticas. Esto fue especialmente evidente en los modelos basados en sMRI y fMRI.

Otra limitación relevante es la falta de validación externa en la mayoría de los trabajos analizados. La práctica común de evaluar el modelo únicamente con divisiones internas del mismo conjunto de datos puede inflar artificialmente las métricas de desempeño, lo que limita la capacidad de los modelos para generalizar a nuevas poblaciones. Además, algunos estudios presentaron tamaños de muestra muy reducidos, lo cual incrementa el riesgo de sobreajuste y afecta la estabilidad de las estimaciones.

Finalmente, existe una falta de estandarización en la forma en que los estudios reportan sus resultados y describen sus modelos. La ausencia de información detallada sobre los procesos de entrenamiento, validación y prueba dificulta la replicación de los resultados y la comparación entre investigaciones.

9.5 Fortalezas del estudio

A pesar de estas limitaciones, el presente trabajo cuenta con varias fortalezas. La primera es el uso de una metodología transparente y rigurosa, respaldada por el cumplimiento de

las directrices PRISMA 2020 [52] y la aplicación de la herramienta QUADAS-2 [53] adaptada a estudios que utilizan inteligencia artificial. Esto permitió valorar de manera crítica el riesgo de sesgo en cada trabajo incluido.

Otra fortaleza importante es la utilización del modelo bivariado de Reitsma [54] para el metaanálisis diagnóstico, lo que permitió obtener estimaciones robustas de sensibilidad y especificidad y capturar la relación entre ambas. Asimismo, el uso de *metafor* [55] y *mada* [56] garantiza la reproducibilidad del análisis y la transparencia en los procedimientos estadísticos.

La integración comparativa entre modalidades constituye también un aporte relevante. Al analizar de manera conjunta estudios basados en EEG, sMRI y fMRI, este trabajo ofrece una visión más amplia del potencial real del Deep Learning en el diagnóstico asistido de esquizofrenia.

9.6 Direcciones de la Investigación actual

A partir de los hallazgos obtenidos, es posible identificar varias direcciones que podrían guiar investigaciones futuras. Entre las más relevantes se encuentra la necesidad de realizar estudios con validación externa multicéntrica, capaces de evaluar la generalización real de los modelos. También será necesario avanzar hacia la estandarización de protocolos de adquisición y preprocesamiento, especialmente en sMRI y fMRI, donde la variabilidad afecta de manera considerable el rendimiento de los modelos.

Asimismo, la integración multimodal representa una línea de investigación particularmente prometedora. La combinación de EEG, sMRI y fMRI en un mismo modelo podría permitir capturar tanto aspectos estructurales como funcionales y dinámicos del cerebro, lo que potencialmente elevaría la precisión diagnóstica. Finalmente, será fundamental desarrollar modelos más interpretables, que permitan comprender qué características están influyendo en la clasificación y cómo estas se relacionan con la fisiopatología del trastorno.

10. CONCLUSIONES

El presente estudio ofrece una síntesis amplia y actualizada sobre el desempeño de modelos de Deep Learning aplicados a EEG, resonancia magnética estructural y resonancia magnética funcional para el diagnóstico de esquizofrenia. A partir de una revisión sistemática y un metaanálisis diagnóstico, fue posible evaluar de manera comparativa la precisión de estas modalidades y describir sus principales fortalezas y limitaciones.

Los resultados muestran que el EEG es la modalidad con mejor desempeño y mayor consistencia entre estudios. Su naturaleza accesible, su bajo costo y la riqueza temporal de sus señales lo convierten en un candidato especialmente adecuado para modelos basados en redes neuronales convolucionales. La resonancia magnética estructural también presentó un rendimiento elevado; sin embargo, su variabilidad metodológica sigue siendo un obstáculo para su generalización. En cuanto a la resonancia magnética funcional, aunque aporta información relevante para comprender la fisiopatología del trastorno, sus resultados diagnósticos fueron más variables y sensibles a diversos factores técnicos.

A partir de estos hallazgos, se puede concluir que la inteligencia artificial tiene un papel prometedor como herramienta auxiliar en el diagnóstico de la esquizofrenia, pero aún no sustituye la evaluación clínica directa. Su mayor utilidad radica en complementar el juicio clínico mediante indicadores cuantitativos que podrían resultar útiles en etapas tempranas del trastorno o en casos de presentación atípica. Sin embargo, para avanzar hacia una integración real en la práctica clínica es indispensable fortalecer la estandarización de los procedimientos, incrementar el número de estudios con validación externa y desarrollar modelos más interpretables desde el punto de vista clínico.

En resumen, los resultados de esta tesis confirman que los algoritmos Deep Learning son una alternativa viable y con alto potencial para apoyar el diagnóstico de esquizofrenia. El campo aún se encuentra en desarrollo, pero los avances recientes sugieren que, con investigación más sólida y estandarizada, la inteligencia artificial podría convertirse en una herramienta valiosa dentro de la psiquiatría del futuro.

11. ANEXOS

Tabla 1. Características de los estudios incluidos

	AUTHOR, YEAR	MULTI-CENTRE	COUNTRY	STUDY TYPE	CONTROL	TYPE OF DATA	INDEX TEST	DEFINITION OF CASES	N	AGE (MEAN)	DEFINITION OF CONTROLS	N	AGE (MEAN)	AIM	REFERENCE STANDARD
1	Barros et al, 2022	Yes	Portugal, USA	Observational, case-control	Yes	EEG	CNN (SzNet)	Clinical diagnosis	65	NR	Healthy control	63	NR	Classification	Random Forest
2	Haiman et al, 2023	No	China, USA, Japan	Observational, case-control	Yes	sMRI	2D CNN + 3D CNN	Clinical diagnosis	140	34.22	Healthy control	205	32.51	Classification	2D CNN-based models
3	Oh et al, 2022	Yes	Korea	Observational, case-control	Yes	fMRI	BrainNet-GA CNN	Clinical diagnosis (DSM-IV)	171	34.38 ±10.61	Healthy control	161	33.73 ±10.96	Classification	SVM, SVM-PCA, FNNs, CNNs, SENet
4	Hu et al, 2021	Yes	Singapore	Observational, case-control	Yes	sMRI	Pretrained 2D CNN and naive 3D CNN	Clinical diagnosis	289	35.06 ±12.78	Healthy control	210	32.88 ±14.05	Classification	SVM
5	Oh et al, 2019	No	Korea	Observational, case-control	Yes	fMRI	3D-CAE-based CNN	Clinical diagnosis (DSM-IV)	103	NR	Healthy control	41	NR	Classification	SVM, 3D-CNN, 3D-CAE + CNNM
6	Qureshi et al, 2019	No	Canada, South Korea	Observational, case-control	Yes	fMRI	3D CNN	Clinical diagnosis (DSM-IV)	72	38.167 ± 13.894	Healthy control	72	35.875 ± 11.74	Classification	3D CNN, ELM, SVM, LDA
7	Sattiraju et al, 2023	No	Poland, USA	Observational, case-control	Yes	EEG	CNN-CD	Clinical diagnosis	14	NR	Healthy control	14	NR	Classification	CNN
8	Bi et al, 2023	Yes	USA, China	Observational, case-control	Yes	fMRI	3D CNN (MultiViT)	Clinical diagnosis	839	38.70±13.14	Healthy control	803	38.76 ± 13.39	Classification	Unimodal - 3DCNN, 3DViT, Cross ViT3D, MLP, ViT - Multimodal - 3DCNN- CNN, 3DViT-ViT, 3DViT-MLP
9	Ghosh et al, 2023	No	USA	Observational, case-control	Yes	fMRI	GCNN	Clinical diagnosis (DSM-IV)	27	NR	Healthy control	27	NR	Classification	KNN, Logistic regression, K means clustering, SVC.
10	Ellis et al, 2022	No	USA	Observational, case-control	Yes	fMRI	CNN + LRP + MCBN	Clinical diagnosis	151	NR	Healthy control	160	NR	Classification	CNN + LRP
11	Ellis et al, 2022	No	USA	Observational, case-control	Yes	fMRI	MCBN	Clinical diagnosis	151	NR	Healthy control	160	NR	Classification	MCD, MCBN
12	Xu et al, 2024	No	China	Observational, case-control	Yes	EEG	STRGCN	Clinical diagnosis (DSM-IV)	78	NR	Healthy control	47	NR	Classification	CNN-LSTM, SVM, KNN, LDA
13	Shen et al, 2024	No	Australia	Observational, case-control	Yes	EEG	3D CNN	NR	45	NR	Healthy control	39	NR	Classification	CNN, SVM, KNN,DT

14	Zhang et al, 2023	Yes	USA	Observational, case-control, retrospective	Yes	sMRI	3D SE-VGG-11BN CNN	Clinical diagnosis	450	NR	Healthy control	437	NR	Classification	VGG-11BN, VGG-13BN, SE-VGG-13BN, DenseNet, ResNe
15	Siuly et al, 2022	Yes	Australia, Turkey	Observational, case-control	Yes	EEG	CNN (SchizoGoogLeNet)	Clinical diagnosis	49	39	Healthy control	32	39	Classification	SVM, KNN, DT, LDA
16	Bagherzadeh et al, 2022	No	Poland	Observational, case-control	Yes	EEG	CNN-LSTM	Clinical diagnosis (ICD-10)	14	NR	Healthy control	14	NR	Classification	CNN
17	Shoeibi et al, 2021	Yes	Iran, Spain, Australia, UK	Observational, case-control	Yes	EEG	CNN-LSTM	Clinical diagnosis	14	28.1 (27.9 F/28.3 M)	Healthy control	14	28.1 (27.9 F/28.3 M)	Classification	Conventional ML (SVM, KNN, DT, FR, Naive Bayes, ERT, Bagging)
18	Zheng et al, 2021	No	China	Observational, case-control	Yes	fMRI	VGG-16 TL	NR	98	37.46 ± 12.99	Healthy control	102	36.85 ± 11.86	Classification	AlexNet, ResNet50
19	Yan et al, 2019	Yes	China	Observational, case-control, retrospective	Yes	fMRI	Multi-scale RNN	DSM-IV-TR	582	NR	Healthy control	524	NR	Classification	Adaboost, RandomForest, SVM, GRU_1_last, GRU_1_ave, GRU_2_ave, Multi_CNN_MLP, Simple_CNN_GRU_2_ave, Multi_CNN_GRU_1_ave, Multi_CNN_GRU_2_ave, Multi_CNN_LSTM_2_ave
20	Zhang et al, 2023	Yes	USA	Observational, case-control, retrospective	Yes	sMRI	SE-VGG-11BN (3D-CNN)	Clinical	450	NR	Healthy controls	437	NR	Classification	Benchmark Model
21	Ko et al, 2022	No	Corea	Observational, case-control	Yes	EEG	CNN	DSM-5	49	NR	Healthy controls	32	NR	Classification	Recurrence plot, Gramian Angular Field, EEG Graph, LSTM, Previous Research
22	Oh et al, 2019	No	Singapur, USA	Observational, case-control	Yes	EEG	CNN	paranoid SZ	14	27.9 ± 3.3 M / 28.3 ± 4.1 F	Healthy controls	14	27.9 ± 3.3 M / 28.3 ± 4.1 F	Classification	SVM
23	Masoudi et al, 2022	No	Iran, UK	Observational, case-control	Yes	fMRI	GRU-CNN based DMMF	Clinical	64	38.92	Healthy controls	81	37.98	Classification	fMRI: AAI-FC, ALFF; AAI-FC, fALFF; AAI-FC, VMHC; AAI-FC, ReHo.

															DTI: AAI-FC, FA; AAI-FC, MD; AAI-FC, MO. CNN, ViT, Swin-T, Transfer Learning
24	Li et al, 2023	No	China	Observational, case-control	Yes	EEG	LeVit (CNN + Transformers)	ICD-10, Paranoid SZ	14	NR	Healthy controls	14	NR	Classification	
25	Kanyal et al, 2024	Yes	USA	Observational, case-control	Yes	sMRI	1D CNN LRP XGBoost	clinical	219	37.19 ± 10.60, 38.89 ± 13.11, 36.37 ± 12.27, 37.48 ± 11.99	Healthy controls	273	37.19 ± 10.60, 38.89 ± 13.11, 36.37 ± 12.27, 37.48 ± 11.99	Classification	NR
26	Yin et al, 2023	No	China	Observational, case-control	Yes	EEG	EFC-GCN	first-episode schizophrenia	103	30.55 ± 8.002	Healthy controls	92	30.55 ± 7.287	Classification	SVM, CNN-2, CNN-5
27	Yu et al, 2023	No	China	Observational, case-control	Yes	fMRI	SMFC-Net	DSM-IV	57	36.68 ± 13.500	Healthy controls	68	35.04 ± 11.205	Classification	SVM, PC-CNN, WSR-CNN, LSTM, MLP, DiffPool, HTFC-Net, SSFC-Net (2), SSFC-Net (4), SSFC-Net (6), SSFC-Net (8), SSFC-Net (10)
28	Hassan et al, 2023	No	Pakistan, Arabia Saudita, UK	Observational, case-control	Yes	EEG	CNN	paranoid sz	14	NR	Healthy controls	14	NR	Classification	Logistic Regression, SVM, Random Forest, Gradient Boosting Classifier
29	Divya et al, 2022	Yes	India	Observational, case-control	Yes	EEG	DCNN-Mayfly	Clinical	14	27.0 + 3.3 M / 28.3 + 4.1 F	Healthy controls	14	27.0 + 3.3 M / 28.3 + 4.1 F	Classification	SVN, SVN-RNF, LS-SVN, KNN, Standard DCNN, MDC-CNN
30	Lin et al, 2022	No	China, USA	Observational, case-control	Yes	fMRI	SSPNet	Clinical	42	41.05 ± 14.16	Healthy controls	40	36.25 ± 11.40	Classification	MAG, SSM, 3D-CNNs
31	Khare et al, 2021	No	India	Observational, retrospective, case-control	Yes	EEG	CNN-SPWVD	Clinical	49	39	Healthy controls	32	39	Classification	AlexNet, VGG16 y ResNet50
32	Shariman et al, 2019	No	Malaysia	observational, case control	Yes	EEG	CNN	NR	45	NR	Healthy controls	39	NR	Classification	ANN

33	Hu et al, 2020	No	Singapore	Observational, retrospective, case-control	Yes	sMRI	CNN	Clinical	289	35.1	Healthy controls	210	31.3	Classification	Linear SVM
34	Li et al, 2019	Yes	China, USA	Observational, retrospective, case-control	Yes	fMRI	DCCSAE	Clinical	92	34	Healthy controls	116	32	Classification	CCA, SCCA, KCCA, DCCA
35	Qiu et al, 2019	Yes	China, Finland, USA	Observational, retrospective, case-control	Yes	fMRI	2D-CNN	Clinical	42	NR	Healthy controls	40	NR	Classification	SB-CNN, SB-CNN

Tabla 2. Métricas de los estudios incluidos.

REF ID	Apellido	True positive	False positive	False negative	True negative	Sensitivity	Specificity	Sample Size	QUADAS Risk	Confidence interval specificity	Confidence interval sensitivity
7	Barros, et al.	53	14	12	49	0.82	0.78	128	Unclear	0.678-0.882	0.727-0.913
11	Haiman, et al.	121	15	19	190	0.862	0.925	345	Unclear	0.889-0.961	0.805-0.919
22	Oh et al.	147	32	24	129	0.86	0.801	332	Unclear	0.739-0.863	0.808-0.912
25	Hu et al.	250	62	39	148	0.864	0.704	499	Unclear	0.642-0.766	0.824-0.904
36	Oh. et al.	90	8	13	33	0.878	0.805	144	Unclear	0.684-0.926	0.815-0.941
38	Qureshi	70	1	2	71	0.975	0.986	144	Unclear	0.959-1.000	0.939-1.000
92	Sattiraju, et al.	12	3	2	11	0.841	0.783	28	High	0.567-0.999	0.649-1.000
94	Bi et al.	697	133	142	670	0.831	0.834	1642	Unclear		0.806-0.856
95	Ghosh, et al.	21	9	6	18	0.782	0.681	54	High	0.505-0.857	0.626-0.938
98	Ellis, et al.	114	38	37	122	0.756	0.762	311	Unclear	0.696-0.828	0.687-0.825
102	Ellis, et al.	107	33	44	127	0.706	0.793	311	Unclear	0.730-0.856	0.633-0.779
112	Xu et al.	71	4	7	43	0.91	0.915	125	Unclear		0.846-0.974
162	Shen, et al.	45	1	0	38	0.993	0.972	84	Unclear	0.920-1.000	0.969-1.000

182	Zhang, et al.	427	24	23	413	0.949	0.946	887	Unclear	0.925-0.967	0.929-0.969
243	Siuly, et al.	45	1	4	31	0.922	0.964	81	Unclear	0.899-1.000	0.847-0.997
267	Bagherzadeh et al	14	0	0	14	0.995	1	28	Unclear	1.000-1.000	0.958-1.000
286	Shoeibi, et al.	14	0	0	14	1	1	28	High		0.934-1.000
288	Zheng et al	86	14	12	88	0.875	0.863	200	Unclear		0.810-0.940
348	Yan, et al.	484	86	98	438	0.831	0.835	1106	Unclear	0.803-0.867	0.801-0.861
419	Zhang, et al	427	24	23	413	0.949	0.946	887	High	0.925-0.967	0.929-0.969
482	Ko, et al.	46	3	3	29	0.939	0.921	81	High	0.828-1.000	0.872-1.000
514	Oh et al.	14	0	0	14	0.973	0.982	28	Unclear	0.912-1.000	0.888-1.000
540	Masoudi, et al.	64	2	0	79	0.998	0.971	145	Unclear	0.934-1.000	0.987-1.000
546	Li, et al.	14	0	0	14	1	1	28	Unclear		0.954-1.000
1001	Kanyal et al.	174	49	45	194	0.794	0.798	492	High		0.740-0.848
1035	Yin, et al.	97	11	6	81	0.945	0.882	195	High	0.816-0.948	0.901-0.989
1037	Yu, et al.	43	13	14	55	0.75	0.809	125	Unclear	0.716-0.902	0.638-0.862
1109	Hassan, et al.	12	0	2	14	0.83	0.99	28	Unclear	0.938-1.000	0.633-1.000

1270	Divya, et al.	13	1	1	13	0.934	0.929	28	High		0.804-1.000
1416	Lin, et al.	39	5	3	35	0.932	0.883	82	Unclear	0.783-0.983	0.856-1.000
1736	Khare, et al.	46	3	3	29	0.943	0.92	81	Unclear	0.826-1.000	0.878-1.000
1827	Shariman et al.	36	3	9	36	0.796	0.911	84	Unclear	0.822-1.000	0.678-0.914
1917	Hu, et al.	217	77	72	133	0.75	0.632	499	Unclear	0.567-0.697	0.700-0.800
1952	Li, et al.	73	6	19	110	0.798	0.947	208	High	0.906-0.988	0.716-0.880
2099	Qiu et al	36	1	6	39	0.85	0.975	82	High	0.927-1.000	0.742-0.958

Tabla 3. Resultados por modalidad.

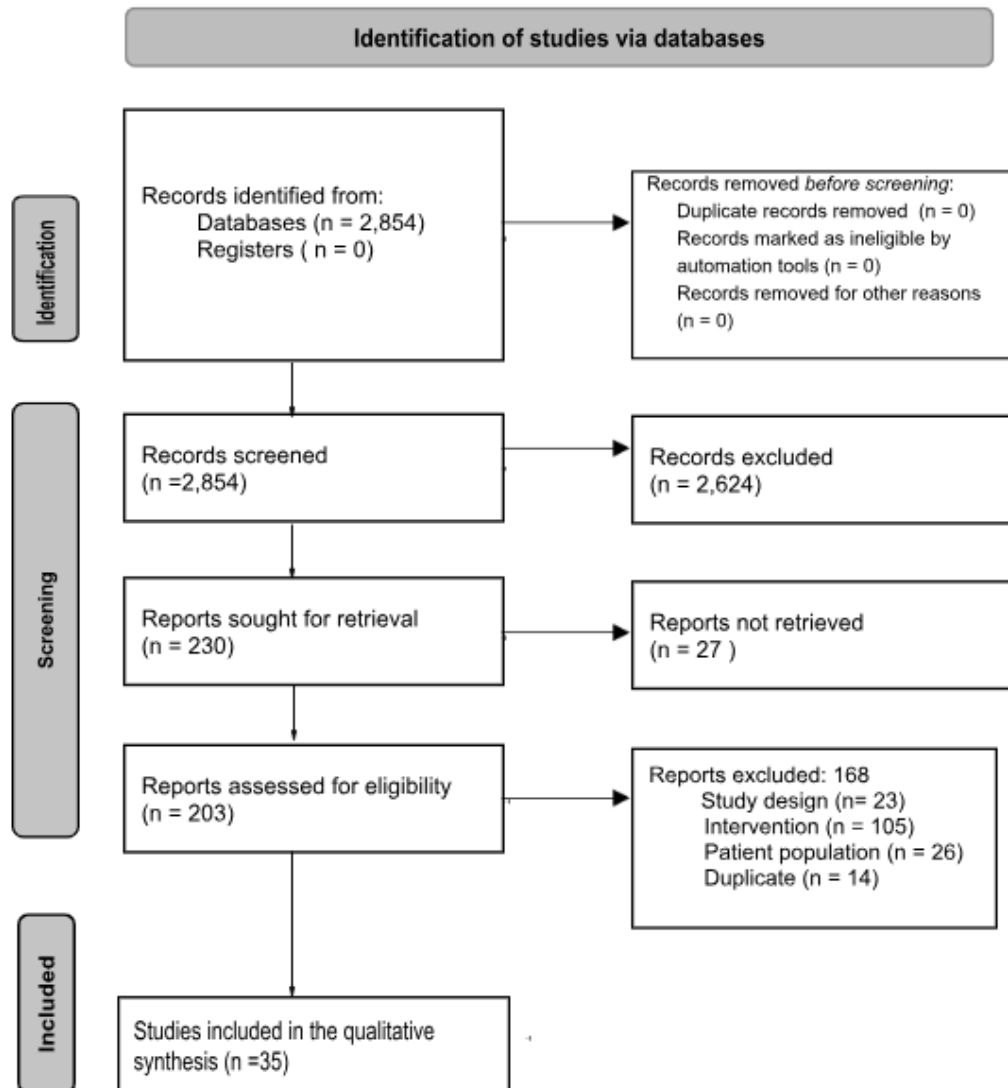
Modalidad	N de estudios	%	Sensibilidad (IC 95%)	Especificidad (IC 95%)	AUC
EEG	14	40	0.91 (0.87–0.94)	0.90 (0.86–0.93)	0.94
fMRI	14	40	0.82 (0.79–0.85)	0.84 (0.80–0.88)	0.90
sMRI	7	20	0.89 (0.82–0.94)	0.88 (0.76–0.95)	0.93
Global			0.87 (0.70-1.00)	0.91 (0.63-1.00)	0.92

Tabla 4. QUADAS: Risk of bias evaluation for all included studies.

Study	Risk of bias								Applicability Concerns		Other	
	D1				D3		D4		D1	D3		
	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Q11	Q12
1	Barros et al, 2022	U	U	U	U	U	U	Y	U	U	Y	U
2	Haiman et al, 2023	U	N	U	U	Y	U	Y	L	L	Y	Y
3	Oh et al, 2022	U	N	Y	U	Y	U	Y	L	L	Y	Y
4	Hu et al, 2021	U	N	Y	L	Y	L	Y	L	L	Y	Y
5	Oh et al, 2019	U	N	U	L	Y	U	Y	U	L	U	Y
6	Qureshi et al, 2019	U	N	Y	L	Y	U	Y	L	L	N	Y
7	Sattiraju et al, 2023	U	N	U	H	U	U	Y	U	U	Y	Y
8	Bi et al, 2023	U	N	U	U	Y	U	Y	L	L	Y	U
9	Ghosh et al, 2023	N	N	U	H	Y	U	Y	L	U	N	Y
10	Ellis et al, 2022	U	N	U	U	U	U	Y	U	L	Y	U
11	Ellis et al, 2022	U	N	U	U	Y	U	Y	L	L	Y	U
12	Xu et al, 2024	U	N	U	U	Y	L	Y	U	L	Y	Y
13	Shen et al, 2024	U	N	U	L	U	U	U	U	L	N	Y
14	Zhang et al, 2023	Y	N	U	U	Y	U	Y	L	L	Y	U
15	Siuly et al, 2022	U	N	U	U	Y	U	Y	L	L	Y	Y
16	Bagherzadeh et al, 2022	U	N	U	L	Y	L	Y	L	L	U	Y
17	Shoeibi et al, 2021	U	N	U	H	Y	U	Y	U	L	U	Y
18	Zheng et al, 2021	U	N	U	U	Y	L	Y	U	L	Y	Y
19	Yan et al, 2019	U	N	U	U	Y	U	Y	U	L	Y	U
20	Zhang et al, 2023	U	N	U	U	Y	U	Y	H	L	Y	Y
21	Ko et al, 2022	U	N	U	H	Y	U	Y	L	L	U	Y
22	Oh et al, 2019	U	N	Y	U	Y	U	Y	L	L	Y	Y
23	Masoudi et al, 2022	U	N	U	U	Y	L	Y	L	L	N	Y
24	Li et al, 2023	U	N	U	U	Y	U	Y	U	L	Y	U
25	Kanyal et al, 2024	U	N	U	H	Y	L	Y	L	L	Y	Y
26	Yin et al, 2023	U	N	U	U	U	H	Y	L	L	Y	Y
27	Yu et al, 2023	U	N	U	U	Y	U	Y	U	L	Y	Y
28	Hassan et al, 2023	U	N	U	U	Y	L	Y	L	L	Y	Y
29	Divya et al, 2022	U	N	U	H	Y	L	Y	L	L	N	Y
30	Lin et al, 2022	U	N	U	U	U	U	U	U	L	Y	Y
31	Khare et al, 2021	U	N	Y	U	Y	L	Y	L	L	N	Y
32	Shariman et al, 2019	U	N	U	L	Y	L	Y	L	L	N	Y
33	Hu et al, 2020	U	N	U	U	Y	U	Y	U	L	Y	Y
34	Li et al, 2019	U	N	Y	H	Y	L	Y	L	L	Y	Y
35	Qiu et al, 2019	U	N	Y	H	Y	L	Y	L	L	Y	Y

Study evaluations were annotated with Y (Yes), N (No), U (Unclear), L (Low Risk), and H (High Risk), and NA (Not Applicable). Columns are annotated as Risk of Bias (ROB), Applicability Concerns (AC), Other (O), Domain 1: Patient Selection (D1), Domain 2: Index Test (D2), Domain 3: Reference Standard (D3) and Domain 4: Flow and Timing (D4). Questions considered were the following. Q1: Was a consecutive or random sample of patients enrolled? Q2: Was a case-control design avoided? Q3: Did the study avoid inappropriate exclusions? Q4: Could the selection of patients have introduced bias? Q5: Is the reference standard likely to correctly classify the target condition? Q6: Could the reference standard, its conduct, or its interpretation have introduced bias? Q7: Did all the patients receive a reference standard? Q8: Could the patient flow have introduced bias? Q9: Is there concern that the included patients do not match the review question? Q10: Is there concern that the target condition as defined by the reference standard does not match the review question? Q11: Is the test dataset separate to the training and validation datasets? Q12: Was the method described in sufficient detail to reproduce the presented results?

Figura 1. PRISMA



12. RERENCIAS

1. World Health Organization. *Schizophrenia*. Geneva: WHO; 2025. Disponible en: <https://www.who.int/news-room/fact-sheets/detail/schizophrenia>
2. Solmi M, Radua J, Olivola M, Croce E, Soardo L, Salazar de Pablo G, et al. Age at onset of mental disorders worldwide: large-scale meta-analysis of 192 epidemiological studies. *Mol Psychiatry*. 2023;28:1–13. doi:10.1038/s41380-021-01161-7
3. Samele C, Frey S, Magliano L, Thornicroft G, Gureje O, et al. Schizophrenia burden and quality of care: an index based on Global Burden of Disease 2019 data. *Schizophr Bull*. 2024;50(5):1083–93. doi:10.1093/schbul/sbad120
4. van Os J, Linscott RJ, Myin-Germeys I, Delespaul P, Krabbendam L. A systematic review and meta-analysis of the psychosis continuum. *Psychol Med*. 2009;39(2):179–95. doi:10.1017/S0033291708003814
5. Karlsgodt KH, Sun D, Cannon TD. Structural and functional brain abnormalities in schizophrenia. *Curr Dir Psychol Sci*. 2010;19(4):226–31. doi:10.1177/0963721410377601
6. Honea R, Crow TJ, Passingham D, Mackay CE. Regional deficits in brain volume in schizophrenia: a meta-analysis. *Am J Psychiatry*. 2005;162(12):2233–45. doi:10.1176/appi.ajp.162.12.2233
7. Zhao C, Zhu J, Liu X, Pu C, Lai Y, Chen L, et al. Structural and functional brain abnormalities in schizophrenia. *Prog Neuropsychopharmacol Biol Psychiatry*. 2018;83:27–32. doi:10.1016/j.pnpbp.2017.12.017
8. Shin KS, Kim JS, Kim SN, Hong KS, O'Donnell BF, Chung CK, et al. Gamma oscillation in schizophrenia. *Psychiatry Investig*. 2011;8(4):288–96. doi:10.4306/pi.2011.8.4.288
9. Tanaka-Koshiyama K, Miyakoshi M, Joshi YB, Molina JL, Tan Z, Sprock J, et al. Abnormal spontaneous gamma power and verbal learning in schizophrenia. *Front Psychiatry*. 2020;11:832. doi:10.3389/fpsyt.2020.00832
10. Shen D, Wu G, Suk HI. Deep learning in medical image analysis. *Annu Rev Biomed Eng*. 2017;19:221–48. doi:10.1146/annurev-bioeng-071516-044442

11. 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. doi:10.1016/j.media.2017.07.005
12. Ranjan R, Sahana BC, Bhandari AK. Deep learning models for diagnosis of schizophrenia using EEG signals. *Arch Comput Methods Eng.* 2024;31:2345–84. doi:10.1007/s11831-023-10047-6
13. Saha A, Park S, Geem ZW, Singh PK. Schizophrenia detection and classification: a systematic review. *Diagnostics.* 2024;14:2698. doi:10.3390/diagnostics14232698
14. Kanyal A, Mazumder B, Calhoun VD, Preda A, Turner J, Ford J, et al. Multi-modal deep learning from imaging genomic data for schizophrenia classification. *Front Psychiatry.* 2024;15:1384842. doi:10.3389/fpsyt.2024.1384842
15. Barros C, Roach B, Ford JM, Pinheiro AP, Silva CA. From sound perception to automatic detection of schizophrenia: An EEG-based deep learning approach. *Front Psychiatry.* 2021;12:813460. doi:10.3389/fpsyt.2021.813460
16. Guo H, Jian S, Zhou Y, Chen X, Chen J, Zhou J, et al. Discriminative analysis of schizophrenia using an integrated 3D+2D CNN model. *Brain Res Bull.* 2024;206:110846. doi:10.1016/j.brainresbull.2023.110846
17. Oh KH, Oh IS, Tsogt U, Shen J, Kim WS, Liu C, et al. Diagnosis of schizophrenia with functional connectome data using GCN. *BMC Neurosci.* 2022;23:6. doi:10.1186/s12868-021-00682-9
18. Hu M, Qian X, Liu S, Koh AJ, Sim K, Jiang X, et al. Structural and diffusion MRI schizophrenia classification. *Schizophr Res.* 2022;243:330–41. doi:10.1016/j.schres.2021.06.011
19. Oh K, Kim W, Shen G, Piao Y, Kang NI, Oh IS, Chung YC. Classification of schizophrenia using 3D CNN. *Schizophr Res.* 2019;212:186–95. doi:10.1016/j.schres.2019.07.034
20. Qureshi MNI, Oh J, Lee B. 3D-CNN based discrimination of schizophrenia using rs-fMRI. *Artif Intell Med.* 2019;98:10–17. doi:10.1016/j.artmed.2019.06.003
21. Sattiraju A, Ellis CA, Miller RL, Calhoun VD. Automated EEG-based schizophrenia diagnosis. *bioRxiv.* 2023. doi:10.1101/2023.05.27.542592

22. Bi Y, Abrol A, Fu Z, Calhoun VD. Multimodal Vision Transformer for schizophrenia. *bioRxiv*. 2023. doi:10.1101/2023.07.14.549002
23. Ghosh S, Bhargava E, Lin CT, Nagarajan SS. Graph convolutional learning of multimodal brain connectome data. *bioRxiv*. 2023. doi:10.1101/2023.01.05.522960
24. Ellis CA, Miller RL, Calhoun VD. Explanation uncertainty in fMRI classification. *bioRxiv*. 2022. doi:10.1101/2022.05.23.493148
25. Ellis CA, Miller RL, Calhoun VD. Towards greater neuroimaging classification transparency. *bioRxiv*. 2022. doi:10.1101/2022.10.06.511164
26. Xu X, Zhu G, Li B, Lin P, Li X, Wang Z. Automated diagnosis using spatial-temporal residual GCN. *Biomed Eng Online*. 2024;23:55. doi:10.1186/s12938-024-01250-y
27. Shen M, Wen P, Song B, Li Y. 3D CNN for EEG-based functional brain networks. *Biomed Signal Process Control*. 2024;89:105815. doi:10.1016/j.bspc.2023.105815
28. Zhang J, Rao VM, Tian Y, Yang Y, Acosta N, Wan Z, et al. Detecting schizophrenia with 3D sMRI deep learning. *Sci Rep*. 2023;13:14433. doi:10.1038/s41598-023-41359-z
29. Siuly S, Li Y, Wen P, Alcin OF. SchizoGoogLeNet deep feature extraction. *Comput Intell Neurosci*. 2022;2022:1992596. doi:10.1155/2022/1992596
30. Bagherzadeh S, Shahabi MS, Shalbaf A. Detection of schizophrenia using EEG and connectivity image. *Comput Biol Med*. 2022;146:105570. doi:10.1016/j.compbiomed.2022.105570
31. Shoeibi A, Sadeghi D, Moridian P, Ghassemi N, Heras J, Alizadehsani R, et al. Automatic diagnosis of schizophrenia using CNN-LSTM. *Front Neuroinform*. 2021;15:777977. doi:10.3389/fninf.2021.777977
32. Zheng J, Wei X, Wang J, Lin H, Pan H, Shi Y. Deep learning using fMRI. *Comput Math Methods Med*. 2021;2021:8437260. doi:10.1155/2021/8437260
33. Cai X, Pan H, Liu X, Lai Y. Automatic schizophrenia identification. *Int J Psychophysiol*. 2021;168:S129–30. doi:10.1016/j.ijpsycho.2021.07.374

34. Phang CR, Noman F, Hussain H, Ting CM, Ombao H. Multi-domain connectome CNN. *IEEE J Biomed Health Inform.* 2020;24:1333–43. doi:10.1109/JBHI.2019.2941222
35. Yan W, Calhoun V, Song M, Cui Y, Yan H, Liu S, et al. RNN applied to multi-site fMRI. *EBioMedicine.* 2019;47:543–52. doi:10.1016/j.ebiom.2019.08.023
36. Ko DW, Yang JJ. EEG-based schizophrenia diagnosis through time series image conversion. *Electronics.* 2022;11:2265. doi:10.3390/electronics11142265
37. Oh SL, Vicnesh J, Ciaccio EJ, Yuvaraj R, Acharya UR. Deep CNN for EEG schizophrenia. *Appl Sci.* 2019;9:2870. doi:10.3390/app9142870
38. Hussain M, Alsalooli NA, Almaghrabi N, Qazi EU. Ensemble lightweight CNN EEG. *Appl Sci.* 2024;14:5048. doi:10.3390/app14125048
39. Masoudi B, Danishvar S. Deep multimodal schizophrenia diagnosis via GRU-CNN. *Neural Netw World.* 2022;32:147–61. doi:10.14311/NNW.2022.32.009
40. Li BL, Wang J, Guo ZF, Li Y. Spatial–temporal feature mapping and LeViT for EEG schizophrenia. *Expert Syst Appl.* 2023;224:119969. doi:10.1016/j.eswa.2023.119969
41. Yin G, Chang Y, Zhao Y, Liu C, Yin M, et al. GCN for brain-network-based schizophrenia detection. *Asian J Psychiatry.* 2023;87:103687. doi:10.1016/j.ajp.2023.103687
42. Yu R, Pan C, Bian L, Fei X, Chen M, Shen D. Multiple functional connectivity patterns with CNN. *Hum Brain Mapp.* 2023;44:4523–34. doi:10.1002/hbm.26396
43. Hassan F, Hussain SF, Qaisar SM. Fusion of multivariate EEG for schizophrenia detection. *Inf Fusion.* 2023;92:466–78. doi:10.1016/j.inffus.2022.12.019
44. Divya V, Kumar SS, Krishnan VG, Kumar M. Optimized deep learning system for schizophrenia. *Comput Syst Sci Eng.* 2023;45:1869–86. doi:10.32604/csse.2023.029762
45. Lin QH, Niu YW, Sui J, Zhao WD, Zhuo C, Calhoun VD. SSPNet: interpretable 3D-CNN. *Med Image Anal.* 2022;79:102430. doi:10.1016/j.media.2022.102430
46. Khare SK, Bajaj V, Acharya UR. SPWVD-CNN for automated EEG schizophrenia detection. *IEEE Trans Instrum Meas.* 2021;70:1–9. doi:10.1109/TIM.2021.3070608

47. Shahriman WNS, Phang CR, Numan F, Ting CM. Classification of brain connectivity using CNN. *IOP Conf Ser Mater Sci Eng*. 2020;884:012003. doi:10.1088/1757-899X/884/1/012003
48. Hu M, Sim K, Zhou JH, Jiang X, Guan C. MRI-based 3D CNN classification. *IEEE EMBC*. 2020:1742–45. doi:10.1109/EMBC44109.2020.9176610
49. Li G, Han D, Wang C, Hu W, Calhoun VD, Wang YP. Deep CCA autoencoder for schizophrenia. *Comput Methods Programs Biomed*. 2020;183:105073. doi:10.1016/j.cmpb.2019.105073
50. Niu YW, Lin QH, Qiu Y, Kuang LD, Calhoun VD. ICA of fMRI + CNN. *ICICIP*. 2019:297–302. doi:10.1109/ICICIP47338.2019.9012169
51. Qiu Y, Lin QH, Kuang LD, Zhao WD, Gong XF, Cong F, et al. ICA of complex-valued fMRI + CNN. *Lect Notes Comput Sci*. 2019;11555:540–7. doi:10.1007/978-3-030-22808-8_53
52. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. PRISMA 2020 statement. *BMJ*. 2021;372:n71. doi:10.1136/bmj.n71
53. Whiting PF, Rutjes AWS, Westwood ME, Mallett S, Deeks JJ, Reitsma JB, et al. QUADAS-2. *Ann Intern Med*. 2011;155:529–36. doi:10.7326/0003-4819-155-8-201110180-00009
54. R Core Team. *R: A language and environment for statistical computing*. Vienna: R Foundation for Statistical Computing; 2025. Disponible en: <https://www.r-project.org/>
55. Viechtbauer W. metafor: meta-analysis in R. *J Stat Softw*. 2010;36:1–48. doi:10.18637/jss.v036.i03
56. Doebler P, Holling H. mada: meta-analysis of diagnostic accuracy. CRAN; 2025. Disponible en: <https://cran.r-project.org/package=mada>
57. Wickham H. *ggplot2: Elegant graphics for data analysis*. Springer; 2016. doi:10.1007/978-3-319-24277-4