



UNIVERSIDAD PERUANA
CAYETANO HEREDIA

Facultad de
MEDICINA

IMPACTO DE LA INTELIGENCIA ARTIFICIAL EN LA MEJORA DE LA
ADQUISICIÓN, EL PROCESAMIENTO Y EL DIAGNÓSTICO POR
IMÁGENES MEDIANTE RESONANCIA MAGNÉTICA Y TOMOGRAFÍA DE
EMISIÓN DE POSITRONES DE LA ENFERMEDAD DE ALZHEIMER: UNA
REVISIÓN DE ALCANCE

IMPACT OF ARTIFICIAL INTELLIGENCE ON IMPROVING THE
ACQUISITION, PROCESSING AND DIAGNOSIS OF ALZHEIMER'S
DISEASE BY MAGNETIC RESONANCE AND POSITRON EMISSION
TOMOGRAPHY: A SCOPE REVIEW

TESIS PARA OPTAR POR EL TÍTULO PROFESIONAL DE LICENCIADO
EN TECNOLOGÍA MÉDICA EN LA ESPECIALIDAD DE RADIOLOGÍA

AUTORES

EMPERATRIZ MYLIN OLULO SANCHEZ
KATTERLI GIULIANNA SALAZAR MONROY
ZAHIRA YAMIRA RAMOS LLANOS

ASESOR

GUILLERMO BRAVO PUENTE

LIMA-PERÚ

2025

JURADO

Presidente: MG. CECILIA LUIS MIRANDA

Vocal: MG. JOHN MELVI LOZANO CASTRO

Secretario: MG. DAVID AGUILAR TORRES

Fecha de Sustentación: 7 de octubre del 2025

Calificación: Aprobado

ASESOR DE TESIS

ASESOR

DR. GUILLERMO BRAVO PUENTE

Departamento Académico de Tecnología Médica

ORCID: 0009-0004-3846-6751

DEDICATORIA

Dedico este logro a mi madre, por darme las herramientas necesarias para ser profesional, por enseñarme a ser una gran mujer, sin ella nada de esto hubiese sido posible. A mi padre por creer en mí, por siempre estar cuando lo necesite, por ser guía y motivación en los días de duda e incertidumbre. A mi querida abuela Isabel por siempre mirarme con esos ojos de esperanza y orgullo que me ayudaron a no rendirme, y a mi hermano por hacerme sentir siempre acompañada. Este logro es de todos ustedes, gracias por haber sido parte de todo este proceso.

Emperatriz Mylin Olulo Snchez

Dedicado a mis padres, quienes han sido el pilar más importante de mi vida y formación. Gracias por su apoyo incondicional, por la confianza depositada en mí, por los sacrificios realizados y por el aliento constante que me brindaron en cada etapa de este camino. Este logro es también fruto de su esfuerzo, amor y ejemplo.

A mi familia y amigos, por su amor incondicional, comprensión y apoyo constante, incluso en los momentos más difíciles. Su confianza y aliento fueron un pilar fundamental para no rendirme y seguir adelante.

Katterli Giulianna Salazar Monroy

A mis padres por su apoyo incondicional, comprensión y confianza constante. Su esfuerzo, orientación y valores inculcados a lo largo de mi vida han sido fundamentales durante mi formación académica, brindándome la fortaleza y motivación necesarias para afrontar los retos presentados en este proceso y seguir adelante en mi desarrollo personal y profesional.

Zahira Yamira Ramos Llanos

AGRADECIMIENTOS

Expresamos nuestro agradecimiento en primer lugar a Dios por brindarnos
fortaleza y claridad en toda nuestra etapa universitaria.

Agradecemos al Dr. Guillermo Bravo, por su tiempo, dedicación y por haber sido
nuestro guía en todo este proceso.

También agradecemos a nuestros padres por creer en nosotras, por darnos esa
motivación cuando más hacía falta y su apoyo incondicional.

FUENTES DE FINANCIAMIENTO

Autofinanciado

DECLARACIÓN DE CONFLICTO DE INTERÉS

Los autores declaran no tener conflicto de interés

DECLARACIÓN DE ORIGINALIDAD



UNIVERSIDAD PERUANA
CAYETANO HEREDIA

DECLARACIÓN DE ORIGINALIDAD

Los egresados:

N°	APELLIDOS Y NOMBRES
1.	OLULO SANCHEZ EMPERATRIZ MYLIN
2.	SALAZAR MONROY KATTERLI GIULIANNA
3.	RAMOS LLANOS ZAHIRA YAMIRA

Pertencientes al programa de la **CARRERA DE TECNOLOGÍA MÉDICA EN LA ESPECIALIDAD DE RADIOLOGÍA** autores del trabajo titulado: **IMPACTO DE LA INTELIGENCIA ARTIFICIAL EN LA MEJORA DE LA ADQUISICIÓN, EL PROCESAMIENTO Y EL DIAGNÓSTICO POR IMÁGENES MEDIANTE RESONANCIA MAGNÉTICA Y TOMOGRAFÍA DE EMISIÓN DE POSITRONES DE LA ENFERMEDAD DE ALZHEIMER: UNA REVISIÓN DE ALCANCE** el cual ha sido elaborado, sustentado y aprobado, según corresponda, para optar por el **TÍTULO PROFESIONAL DE LICENCIADO EN TECNOLOGÍA MÉDICA EN LA ESPECIALIDAD DE RADIOLOGÍA** bajo la modalidad de **TESIS**.

En calidad de docente asesor de la Universidad Peruana Cayetano Heredia:

N°	APELLIDOS Y NOMBRES DEL DOCENTE	FACULTAD	NIVEL DE ASESORÍA
1.	BRAVO PUENTE GUILLERMO	MEDICINA	ASESOR

Declaramos que el contenido del presente documento es original y que las citas y referencias a otros autores cumplen con las normas académicas establecidas. En ese sentido, hacemos constar que:

- El documento presenta un porcentaje de similitud de **18 %**, según el reporte emitido por el software **Turnitin®** (identificador de entrega: **trn:oid:::1:3498502171**; fecha de entrega: **05-03-2026**).
- Tras una revisión detallada del reporte y del contenido del trabajo en cuestión, no se han identificado indicios de plagio.
- Se certifica que el documento respeta los principios de integridad académica y cumple con los requisitos institucionales de originalidad.

Lugar y fecha: **Lima, 05 de marzo del 2026.**

Firma del asesor
N° DNI: 09218831
ORCID: 0009-0004-3884-6751.



TABLA DE CONTENIDOS

RESUMEN:	
ABSTRACT.....	
I. INTRODUCCIÓN.....	1
II. JUSTIFICACIÓN.....	4
III. OBJETIVOS	6
IV.MATERIAL Y MÉTODO	7
V. DISCUSIÓN	18
VI. LIMITACIONES	22
VII. CONCLUSIONES.....	23
VIII. REFERENCIAS BIBLIOGRAFICAS	25
IX. TABLAS.....	32
<u>X</u> ANEXOS.....	

RESUMEN:

Antecedentes: La enfermedad de Alzheimer (EA) es una alteración neuronal progresivo neurodegenerativo caracterizada por la acumulación anormal del β -amiloide y la proteína tau en el cerebro. Según la OMS, afecta a unos 60 millones de sujetos en el mundo, presentándose con mayor incidencia en personas de la tercera edad y en el sexo femenino. **Objetivo:** La presente revisión busca explorar la evidencia disponible sobre el impacto de la inteligencia artificial (IA) en el mejoramiento de la adquisición, el procesamiento y la interpretación de imágenes adquiridas por Resonancia Magnética (RM) y tomografía por Emisión de Positrones (PET) en el diagnóstico de la EA. **Metodología:** Se realizó una revisión de alcance siguiendo con una extensión de PRISMA, la búsqueda se realizó en base de datos MEDLINE, EMBASE, Cochrane Library, y otras plataformas como SciELO, Web of Science, Scopus y Google Scholar. Además, se consultó literatura gris en el base de datos ALICIA, incluimos estudios con acceso completo, del 2015 al 2025. **Resultados:** Se seleccionaron 14 publicaciones para el estudio, que se clasificó según los objetivos específicos. Los diseños de estudio incluyeron mayoritariamente estudios experimentales y de cohorte. En cuanto al tipo de inteligencia artificial utilizada, predominó el uso de técnicas de *Deep Learning* (como CNN y GNN), seguido por *Machine Learning*. **Conclusión:** la IA se posiciona como una herramienta crucial y emergente en el diagnóstico por imágenes de la enfermedad de Alzheimer, al intervenir eficazmente en todo el flujo de trabajo radiológico, desde la adquisición, pasando por el procesamiento, hasta la interpretación diagnóstica.

Palabras clave: Inteligencia artificial (IA), Enfermedad de Alzheimer (EA), Resonancia magnética (IRM), Tomografía por emisión de positrones (PET).

ABSTRACT

Background: Alzheimer's disease (AD) is a progressive neurodegenerative disorder characterized by the abnormal accumulation of β -amyloid and tau proteins in the brain. According to the World Health Organization (WHO), it affects approximately 60 million people worldwide, with a higher prevalence in women and older adults.

Objective: This review aims to explore the available evidence on the impact of artificial intelligence (AI) in improving the acquisition, processing, and diagnostic interpretation of magnetic resonance imaging (MRI) and positron emission tomography (PET) in Alzheimer's disease.

Methodology: A scoping review was conducted following an extension of the PRISMA guidelines. The search was carried out in databases such as MEDLINE, EMBASE, Cochrane Library, and other relevant platforms including SciELO, Web of Science, Scopus, and Google Scholar. Grey literature was also consulted through the ALICIA repository. We included full-text studies published between 2015 and 2025.

Results: Fourteen publications were selected for this study and categorized according to specific objectives. The study designs mainly included experimental and cohort studies. Regarding the type of artificial intelligence used, deep learning techniques (such as CNN and GNN) predominated, followed by machine learning approaches.

Conclusion: AI is emerging as a crucial tool in Alzheimer's disease imaging diagnosis, playing an effective role throughout the entire radiological workflow—from acquisition and processing to diagnostic interpretation.

Keywords: Artificial intelligence (AI), Alzheimer's disease (AD), Magnetic resonance imaging (MRI), Positron emission tomography (PET)

I. INTRODUCCIÓN

La enfermedad de Alzheimer es un trastorno neurodegenerativo de progresión gradual que se distingue por la acumulación anómala de las proteínas β -amiloide, como de la proteína "tau" en el cerebro, TDP-43, la alfa sinucleína (1). Esta enfermedad afecta principalmente la memoria episódica y se manifiesta con síntomas como dificultades en la expresión verbal (afasia), problemas en la coordinación motora (apraxia), incapacidad para reconocer personas u objetos (agnosia), alteraciones en la capacidad de juicio, planificación y toma de decisiones, desorientación y cambios en la conducta que comprometen la independencia en la vida diaria (2).

De acuerdo con la Organización Mundial de la Salud (OMS), cerca de 60 millones de 5 personas a nivel mundial padecen de EA. En la población mayor de 65 años, la 11 prevalencia es del 8,1 % en mujeres y del 5,4 % en hombres (3). Un estudio desarrollado en el Cercado de Lima, con una muestra de 1.532 personas reportó una prevalencia de demencia del 6,85 %, siendo la EA el diagnóstico más frecuente, representando el 56,2 % de los casos. La edad se identifica como el principal factor de riesgo para desarrollar demencia y Alzheimer; en este sentido, la prevalencia de un 2,40 % en el grupo de 65 a 69 años, aumentando un 20,20 % en personas de 85 a 89 años, y alcanza un 33,07 % en quienes tienen entre 90 y 94 años (4).

Además de contribuir al aumento de la mortalidad en adultos mayores, la enfermedad de Alzheimer también está relacionado con distintos síndromes geriátricos, tales como caídas recurrentes, episodios de delirio, incontinencia urinaria, polifarmacia (uso excesivo de medicamentos) y pérdida de fuerza y resistencia física (fragilidad) (2). El diagnóstico de la enfermedad de Alzheimer,

aunque esencialmente clínico, requiere el apoyo de pruebas complementarias para mejorar su precisión. Es necesario recurrir a estudios de laboratorio y especialmente a técnicas de neuroimagen, como la resonancia magnética (RM) y la tomografía por emisión de positrones (PET), tanto para confirmar el diagnóstico clínico como para detectar estadios preclínicos de la enfermedad y establecer un diagnóstico diferencial con otros tipos de demencia. Esta integridad diagnóstica es clave en el enfoque actual de la EA, y representa el entorno preciso para la incorporación de herramientas basadas en inteligencia artificial (IA) (5).

La IA se ha posicionado como una herramienta útil en apoyo al diagnóstico para enfrentar estos desafíos. Todos los algoritmos de aprendizaje profundo, particularmente las redes neuronales convolucionales (CNN), facilitan el diagnóstico temprano y preciso de los patrones degenerativos cerebrales asociados a la enfermedad. Estas innovaciones no solo mejoran los procesos diagnósticos, sino que también posibilitan el desarrollo de modelos predictivos, favoreciendo a los pacientes, ofreciéndoles una mejor calidad de vida en las etapas de envejecimiento (6).

El uso de la neuroimagen ha potenciado el diagnóstico de la EA, destacando la RM y PET como herramientas fundamentales. Al identificar la acumulación de proteínas amiloides relacionada a fases preclínicas y en el deterioro cognitivo leve, se puede diagnosticarse mediante PET con el uso de radio trazadores como el ¹¹C-PIB. De manera similar, la PET-FDG se emplea para analizar tanto el metabolismo cerebral como la actividad neuronal (7).

A diferencia de métodos convencionales el uso de algoritmos de aprendizaje automático y aprendizaje profundo requieren poco o ningún preprocesamiento de imágenes, ya que fácilmente identifican patrones relevantes de la enfermedad sin necesidad de una revisión manual de características. Esta metodología permite una detección más objetiva y libre de sesgos, convirtiendo esta integración en una alternativa eficiente para identificar alteraciones anatómicas sutiles y dispersas en el cerebro (8).

II. JUSTIFICACIÓN

El impacto del Alzheimer no se limita únicamente al ámbito médico, sino que también influye el entorno personal, social y económico, especialmente en el sector salud. Aunque existen tratamientos que pueden aliviar algunos síntomas y retrasar el progreso de la enfermedad, hasta el momento no se ha encontrado la solución que detenga por completo su avance. Esta falta de tratamientos efectivos está directamente relacionada con las limitaciones de los métodos diagnósticos actuales (9). Por esto las técnicas de neuroimagen han demostrado ser herramientas clave para la detección temprana de la EA con un alto nivel de precisión. Por ejemplo la RM emplea métodos estadísticos para diagnosticar la EA en fases iniciales (10).

La literatura sobre RM relacionada particularmente para el análisis de la neuroimagen en la EA, ha desarrollado la innovación de herramientas basadas en IA, como algoritmos en aprendizaje automático y aprendizaje profundo (11).

El uso de CNN ha optimizado la calidad de las imágenes, identificando la acumulación de placas de amiloide y otros biomarcadores asociados a la enfermedad. Además, esta técnica disminuye la necesidad de aplicar dosis doble de radiación, lo hace al procedimiento más seguro (12). Esta integración de herramientas no solo permite diagnósticos más rápidos y precisos, sino que también incrementa la eficiencia del proceso clínico (13).

La IA influye en la automatización del análisis de imágenes médicas, mejorando la exactitud en la identificación de biomarcadores. Estas tecnologías avanzadas optimizan el diagnóstico y perfeccionan el uso de recursos clínicos al facilitar el

análisis automatizado de grandes volúmenes de datos, superando así las limitaciones del análisis manual. (14).

En este estudio se llevará a cabo un análisis de la información existente sobre el efecto de la inteligencia artificial en las diferentes fases del flujo de trabajo en neuroimágenes, a través de resonancia magnética y tomografía por emisión de positrones, que abarcan la obtención, procesamiento e interpretación diagnóstica de las imágenes. Este efecto se reflejará en la identificación temprana de la enfermedad de Alzheimer.

III. OBJETIVOS

3.1 Objetivo General

- Explorar la evidencia disponible sobre el impacto de la inteligencia artificial en la mejora de la adquisición, el procesamiento y la interpretación diagnóstica de imágenes por resonancia magnética y tomografía de emisión de positrones en la enfermedad de Alzheimer

3.2 Objetivos específicos

- Identificar la evidencia disponible sobre el impacto de la inteligencia artificial en la mejora de la adquisición de imágenes por RM y PET para el diagnóstico de la enfermedad de Alzheimer.
- Caracterizar los enfoques de inteligencia artificial utilizados para la mejora del procesamiento de imágenes por RM y PET en el contexto del diagnóstico de la enfermedad de Alzheimer.
- Describir cómo se ha empleado la inteligencia artificial para mejorar la interpretación diagnóstica de imágenes por RM y PET en pacientes con enfermedad de Alzheimer.

IV. MATERIAL Y MÉTODO

4.1 Diseño de estudio

Este estudio se estructurará según la versión 01.00/06-05-2024 de la reglamentación de la Universidad Peruana Cayetano Heredia denominada "Normas y procedimientos para la elaboración, desarrollo, exposición, evaluación y publicación de trabajos de investigación y tesis". El estudio se basará en una revisión alcance (scoping review), utilizando publicaciones científicas como fuente de datos. Esta es una forma de condensación del saber que sigue un procedimiento sistemático para reconocer la evidencia en un tema específico. Para escoger los artículos en los ámbitos en RM y PET, se emplea la extensión PRISMA (Artículos Recomendados para Revisiones Sistemáticas y metaanálisis) para realizar revisiones de gran alcance.

Dentro de los criterios de inclusión se consideraron:

- Publicaciones nacionales e internacionales con acceso completo, de estudios primarios (experimentales y observacionales y secundarios como metaanálisis, revisiones sistemáticas y revisiones de alcance.
- Desde el 2015 hasta 2025.
- Con rango de edad mayor a los 18 años.
- Investigaciones centradas en el uso de resonancia magnética y/o tomografía por emisión de positrones para el diagnóstico de la enfermedad de Alzheimer.

Resultados esperados: Estudios sobre la aplicación de la inteligencia artificial en las modalidades de neuroimagen por resonancia magnética y tomografía de emisión de positrones en el diagnóstico de la enfermedad de Alzheimer.

Se excluyeron:

- Estudios con información incompleta, resúmenes de congresos, cartas dirigidas al editor, artículos editoriales y estudios que no hayan sido sometidos a revisión por pares.
- Estudios que en ninguna de las tres etapas (adquisición, procesamiento o interpretación diagnóstica) aborden el uso de la IA de imágenes RM o PET para el diagnóstico del Alzheimer.
- Publicaciones centradas exclusivamente en otras enfermedades o en modalidades de imagen distintas a RM y PET.
- Estudios publicados en idiomas distintos al inglés o español, en tanto se carezca de recursos para su adecuada traducción.

La búsqueda de información se realizó en bases de datos como MEDLINE (a través de PubMed), EMBASE (por medio de OVID), Cochrane Library, y otras plataformas relevantes como SciELO, Web of Science, Scopus y Google Scholar. Además, se consultará literatura gris en el repositorio ALICIA. Se emplearon términos clave y libres fundamentados en los descriptores MeSH, ajustados a los criterios de búsqueda de cada base de datos. La selección de evidencia se realizó en dos etapas: primero, se revisaron títulos y resúmenes, y luego se evaluaron de forma completa los estudios seleccionados, documentando el proceso con un diagrama PRISMA.

Los datos fueron extraídos y presentados en una plantilla estandarizada que incluía: autor, país, año, objetivo, metodología del estudio, N° imágenes/pacientes, tipo de IA, impacto de la IA y principales hallazgos. Estos componentes se agruparon narrativamente con el fin de analizar el impacto de la IA en el diagnóstico de la EA.

Los resultados fueron presentados de forma descriptiva. Se organizaron por tablas para resumir las características de los estudios seleccionados, evidencia existente sobre el impacto de la IA en la mejora de los procesos de adquisición de imágenes para el diagnóstico de la EA, mejora del procesamiento de imágenes para el diagnóstico de la EA y evidencia sobre el impacto de la IA en el diagnóstico de la EA.

4.2 RESULTADOS

Se seleccionaron catorce publicaciones para el presente estudio, cuyas principales características se detallan en la tabla 1. Respecto al país de origen, cinco provienen de China, tres de Corea del sur, dos de EE. UU y uno de Suecia, Francia, Japón, y Ecuador respectivamente. Referente a los años de publicación tenemos que uno pertenece al 2025, cinco corresponden al 2024 y 2023, dos del 2021 y uno del 2020. En el diseño de estudio se encontraron seis estudios experimentales, cuatro estudios de Cohorte, dos observacionales analíticos, un metaanálisis y un observacional descriptivo. Por otro lado, respecto al tipo de inteligencia artificial empleado se menciona Deep Learning en 9 ocasiones (QUADAS-2, CNN, GNN) y Machine Learning 5 en ocasiones (CNN VGG16,), dentro de ellos no se mencionan los nombres de los modelos específicos de IA desarrollados (Tabla 1).

El impacto de la IA en el proceso de adquisición de imágenes para el diagnóstico de la EA se resume en la tabla 2.

En el estudio Bottani S. et al. (22) que uso resonancia magnética ponderada en T1, siguiendo un protocolo estandarizado cuyo objetivo fue implementar una línea de base filtrando las imágenes de baja calidad de los resultados clínicos, garantizando la calidad y la homogeneización de los datos, donde la IA mejora la extracción de características cerebrales relevantes. Aplica un modelo lineal de secuenciación de objetos (SVM) que utiliza mapas de materia gris y tres modelos de Red neuronal convolucional CNN (Conv5_FC3, ResNet e InceptionNet) para evaluar la sensibilidad y especificidad de cada uno al diferenciar el diagnóstico de demencia con lesiones–frente a demencia sin lesiones. También propuso un enfoque de traducción de imágenes basado en aprendizaje profundo para eliminar el efecto

visual del gadolinio aplicando un modelo de traducción de imágenes *Att-U-Net*. Se obtuvo un alto rendimiento de clasificación alrededor del 87% de precisión equilibrada. Esta técnica permite establecerse en modelos de grandes volúmenes de datos no etiquetados, lo que mejora significativamente el rendimiento en tareas de clasificación de EA temprana garantizando la calidad y la homogeneización de los datos.

En el estudio de Ejaz U. et al. (28), se propuso un modelo combinado CNN-LSTM (Redes convolucionales y Red de memoria a corto-largo plazo) de arquitectura ligera que permite el diagnóstico multimodal de la enfermedad de Alzheimer utilizando imágenes de resonancia magnética; el nuevo modelo alcanzó una precisión notable del 92,3 %. El modelo, debido a su diseño compacto, consigue obtener características pertinentes de diversas modalidades de RM con una carga computacional reducida, lo que simplifica su incorporación en contextos clínicos con recursos escasos. Esta eficiencia estructural puede disminuir la necesidad de adquirir imágenes adicionales, contribuyendo indirectamente a reducir los tiempos de adquisición. También la combinación de la capacidad de extracción espacial de CNN y la secuencial de LSTM mejora la representación de la progresión de la EA, aumentando la precisión diagnóstica.

La evidencia existente sobre el impacto de la IA en la mejora del *procesamiento de imágenes* para el diagnóstico en la EA se detalla en la tabla 3.

Bao Y. et al. (24) desarrollaron un modelo basado en *random forest* utilizando características cuantitativas de PET con amiloide- β y características estructurales de IRM. Esta integración permitió mejorar significativamente la clasificación del Alzheimer, al combinar múltiples modalidades de imagen que capturan tanto los

depósitos amiloides como los cambios estructurales cerebrales. Al combinar características cuantitativas de dos tipos de imágenes pude clasificarlas en pacientes con EA, personas con deterioro cognitivo leve (DCL) y sujetos sanos mayores (OHC). El rendimiento del modelo RF mejora y refleja una mayor precisión de 0,81/sensibilidad de 0,86 y AUC de 0,80 al introducir las características de sMRI, y una precisión de 0,86/sensibilidad de 0,90 y AUC de 0,85 basada en las características de A β PET. Logró una mayor precisión diagnóstica gracias a la sinergia entre imágenes PET y MRI, destacando el potencial de los modelos de aprendizaje automático en contextos clínicos multicéntricos.

Por su parte, Lee M. et al. (25) propusieron un modelo de aprendizaje automático que combina información clínica, imágenes y pruebas cognitivas para predecir la conversión de DCL a enfermedad de Alzheimer. La IA integra distintas fuentes de datos, mejorando la sensibilidad de predicción en el diagnóstico. Esta estrategia facilitó una interpretación diagnóstica en etapas preclínicas, disminuyendo la progresión de la enfermedad.

Kim S. et al. (26) utilizó la adquisición de imágenes mediante PET y PET-IRM para comparar los métodos automatizados para cuantificar la retención de amiloide cerebral. La IA empleada para la segmentación de imágenes y la cuantificación automática aumentó la objetividad y la uniformidad del procesamiento, calculando la relación estandarizada de captación regional (SUVR) mediante ambos enfoques. Se usaron modelos de regresión logística junto con validación cruzada de 10 pliegues y métricas del área bajo la curva de características operativas del receptor (AUROC) para medir la diferencia entre grupos positivos y negativos según la cantidad de acumulación amiloide. Esto disminuyó la variabilidad entre evaluadores y

facilitó el seguimiento a largo plazo en investigaciones y estudios clínicos. Finalmente, Zhang Y. et al. (27) fabricó e instaló una red neuronal de grafos (GNN) multimodal que integró estudios MRI y PET para el diagnóstico de Alzheimer. La precisión promedio alcanzó el 98,00 % y 96,29 %, con una desviación estándar de 0,78 en ambos casos. El AUC se registró en 98,06 y 96,58, con desviaciones estándar de 0,90 y 0,72, respectivamente. Estos hallazgos muestran que el modelo GNN multimodal propuesto muestra un rendimiento estable y fiable. Este método basado en grafos facilitó la identificación de conexiones espaciales y funcionales entre distintas áreas cerebrales, facilitando su método diagnóstico. La aplicación de IA permitió una mayor exactitud al detectar patrones iniciales de la enfermedad (Tabla 3).

La información disponible sobre el efecto de la IA en la mejora de la interpretación diagnóstica para la EA se presenta en la tabla 4.

Mediante un análisis exhaustivo de las imágenes cerebrales y utilizando algoritmos de aprendizaje profundo, Zhou X. et al. (21) exploró el uso de CNN para evaluar datos de resonancia magnética funcional (fMRI) para predecir la enfermedad de Alzheimer. Este método no solo alcanzó una precisión destacable en la categorización de pacientes, sino que también facilitó la identificación de regiones cerebrales clave utilizando técnicas de interpretación de modelo, como los mapas de activación. Estos resultados indican que los modelos de aprendizaje profundo no solo automatizan el proceso diagnóstico, sino también optimizan la interpretación clínica evidenciando las regiones más significativas en el deterioro cognitivo. Entre los hallazgos principales, se destaca que la CNN logró niveles de precisión del 92,8

% y un ROC de 0,95, siendo superior a los convencionales, lo que la convierte en una opción más eficaz y accesible. Bottani S. et al. (22) evalúa la implementación de algoritmos de aprendizaje automático sobre datos IRM almacenados en un *data warehouse* clínico, simulando condiciones reales de un habiente hospitalario. Los modelos lograron diferenciar entre varios tipos de demencia con grados de precisión más altos que las técnicas tradicionales. Esta investigación destaca cómo la IA, al analizar grandes cantidades de datos variados, puede proporcionar al médico una segunda opinión informada que refuerza la interpretación de los hallazgos radiológicos, especialmente en casos con síntomas atípicos o superpuestos. En las categorías de demencia y Lesiones no demencia (NDL), la mayoría de las imágenes son de calidad buena/media (58% y 52%, respectivamente), mientras que en la categoría No Demencia No Lesiones (NDNL) solo el 36% de las imágenes son de calidad buena/media. No obstante, el rendimiento diagnóstico asistido por computadora está sesgado hacia arriba y pasa porque la IA aprende de imágenes de bases de investigación y no de imágenes de bases hospitalarias, lo cual es un reto para el desarrollo futuro de la IA.

Wang L. et al. (22) realizaron un metaanálisis centrado en estudios que aplicaban *deep learning* a imágenes estructurales de RM para la detección temprana de Alzheimer y DCL. Sin embargo, no incluye las otras publicaciones que forman parte de este trabajo. Aporta los datos de sensibilidad y especificidad cuando se usa la IA para diferenciar EA y DCL. La revisión integró resultados de múltiples investigaciones, demostrando que los modelos alcanzan consistentemente altas tasas de sensibilidad y especificidad, incluso en etapas preclínicas. Estos descubrimientos respaldan la utilidad de la IA en la interpretación diagnóstica al

detectar sutiles cambios anatómicos que podrían pasar desapercibidas en evaluaciones humanas. La curva AUROC fue 0,92 lo que sugiere que el aprendizaje profundo basado en RM obtuvo una alta precisión para distinguir el diagnóstico de EA y DCL en parámetros de sensibilidad y especificidad.

En un enfoque diferente, Won S. et al. (29) utilizó PET con 18F-flortaucipir para detectar agregados de tau, usando métodos de aprendizaje automático, para clasificar con precisión las etapas del Alzheimer. El sistema diferenció entre estados de cognitivos leves, moderados y avanzados, contribuyendo a una caracterización más exacta de la evolución de la enfermedad. Esta capacidad de estratificación ayuda a mejorar la interpretación de la fase clínica, lo cual es esencial para la toma de decisiones terapéuticas. Mostró que la combinación de variables clínicas y SUVR de tau mejoró significativamente la precisión de la clasificación, con un AUC superior a 0.96 en la mayoría de los modelos para diferenciar entre pacientes con deterioro cognitivo (CU) y EA.

Kimura N. et al. (30) desarrollaron un modelo interpretable que, a diferencia de los enfoques tradicionales basados en neuroimagen, utilizó datos de sensores portátiles y factores de estilo de vida para predecir la positividad amiloide en PET cerebral. Este enfoque innovador mostró que la IA puede integrar información contextual y conductual para anticipar cambios neuropatológicos, lo cual enriquece la interpretación clínica al ampliar el espectro de datos considerados en el proceso diagnóstico. El área ROC del modelo que utilizó únicamente factores de estilo de vida medidos objetivamente fue de 0,70, mientras que la de los modelos que utilizaron sensores portátiles en combinación con características demográficas y cuestionarios de salud y entorno vital fue de 0,79.

Por su parte, Ucañay W. et al. (31) se presenta un sistema de diagnóstico automatizado basado en imágenes de resonancia magnética y el modelo VGG16. Este enfoque emplea técnicas de aprendizaje profundo para clasificar imágenes cerebrales en categorías de pacientes sanos, con deterioro cognitivo leve y Alzheimer. Utiliza el sistema SHA (Shapley Additive explanations) para calificar y comparar el marco computacional de dos capas. Estas capas identifican patrones visuales simples y más complejos en capas más profundas (formas anatómicas, regiones atróficas). Cada filtro genera un mapa de activación que destaca dónde se genera una característica en la imagen. El modelo VGG16 mostró una precisión del 98.6%, una sensibilidad del 98.2% y una especificidad del 98.8%, al clasificar correctamente entre controles sanos, pacientes con DCL y con enfermedad de Alzheimer. Estas métricas son muy superiores a las obtenidas con métodos convencionales. El modelo permitió procesar imágenes de manera eficiente, reduciendo tiempos de análisis y aumentando la objetividad diagnóstica. Esto representa un aporte significativo adquisición de resultados

Etminani K. et al. (33) propusieron un modelo tridimensional de aprendizaje profundo para clasificar casos de Alzheimer, deterioro cognitivo leve y demencia con cuerpos de Lewy a partir de tomografías PET con 18F-FDG. El uso de un enfoque 3D permitió capturar relaciones espaciales más complejas dentro del cerebro, mejorando así la diferenciación entre condiciones clínicas que suelen compartir manifestaciones neuropsicológicas. Esta capacidad de discernimiento preciso refuerza la utilidad de la IA en contextos donde la interpretación clínica puede ser ambigua. El modelo alcanzó un rendimiento perfecto en los casos de DLB

con una sensibilidad del 86%, una especificidad del 100% y una precisión del 100% y una puntuación F1 del 92%.

Yanag Z. et al. (33) desarrollaron un modelo predictivo de Alzheimer basado en PET con 18F-FDG y aprendizaje profundo, el cual logró identificar patrones de hipometabolismo cerebral asociados a etapas tempranas de la enfermedad. La interpretación de estos patrones mediante mapas de calor y análisis multivariado permite al clínico visualizar directamente las áreas de afectación, lo que favorece un enfoque diagnóstico más personalizado y basado en evidencia cuantitativa. La clasificación de conv3 logró resultados preferibles en la predicción de DCL, con una sensibilidad y especificidad de 91,02% y 77,63%. La capa conv5, la precisión fue del 72,19 %, y la sensibilidad y la especificidad de 73 %, lo que indica que el modelo de clasificación fue útil para la clasificación de Deterioro Cognitivo Leve Temprano (DCLT) y Deterioro Cognitivo Leve Tardío (DCLD).

Finalmente, Sappagh et al. (34) revisaron las aplicaciones diagnósticas y pronósticas de la IA en Alzheimer, señalando que los modelos analizados no solo son capaces de detectar la enfermedad con alta precisión, sino también de predecir su progresión a lo largo del tiempo. Este potencial pronóstico mejora la interpretación clínica al ofrecer una visión más completa del curso esperado de la enfermedad, lo que facilita la planificación de intervenciones preventivas o terapéuticas a medida. La combinación de dos modalidades Fluido cerebroespinal (CS) + batería neuropsicológica (NB) mejoró la precisión de CS en aproximadamente un 1 %, es decir, $MCA = 93,00 \pm 2,61 \%$.

V.DISCUSIÓN

Los estudios por imagen se constituyen en un componente valioso para el diagnóstico de la enfermedad de Alzheimer, principalmente en las modalidades de resonancia magnética y la tomografía de emisión de positrones. Su importancia se acentúa en los estadios preclínicos de la enfermedad y en el diagnóstico diferencial. La inteligencia artificial potencia estas modalidades de estudio y está presente en todas las etapas de trabajo con la neuroimagen, esto es en la adquisición, procesamiento e interpretación diagnóstica de las imágenes.

Respecto al impacto de la IA en la mejora de la adquisición de imágenes se demostró Bottani et al. (22) al emplear resonancia magnética ponderada en T1 combinada con algoritmos como SVM y CNN (Conv5_FC3, ResNet e InceptionNet), logra una precisión equilibrada del 87% mediante la eliminación de ruido y el control de calidad en imágenes clínicas. De manera similar, Ejaz Ul H. et al. (28) desarrollaron un modelo CNN-LSTM de arquitectura ligera que alcanzó una precisión diagnóstica del 92.3%, facilitando la adquisición más rápida de imágenes sin comprometer la exactitud. Estos resultados evidencian que la IA no solo optimiza la eficiencia del proceso técnico de obtención de imágenes, sino que también garantiza el estándar completo, aspecto el cual es esencial para construir modelos predictivos confiables y para realizar estudios longitudinales de seguimiento en Alzheimer.

En relación a la influencia de la IA en la mejor al procesamiento de imágenes los estudios propusieron modelos de redes convolucionales para afrontar la clasificación de signos y así detectar de manera temprana la EA. Tales como Zhou

et al. (21), que logró una precisión del 92,8% y un ROC de 0,95 en la predicción de EA mediante fMRI. Además de su alta capacidad clasificatoria, este modelo incorporó mapas de activación para identificar regiones cerebrales clave también como el estudio de Li Xue W. et al. (22), que mediante un metaanálisis de modelos deep learning sobre imágenes estructurales de IRM confirma esta tendencia al mostrar una AUROC promedio de 0,92, incluso en etapas preclínicas. Esto respalda la capacidad de la IA para detectar alteraciones anatómicas poco evidentes, lo cual resulta crítico para la detección temprana del DCL o la EA incipiente. Mientras tanto Zhiguang Y. et al. (32) también implementó una red CNN profunda con distintas capas convolucionales para identificar patrones de hipometabolismo cerebral en PET 18F-FDG. El modelo fue especialmente eficaz en la clasificación de EMCI y LMCI, con una sensibilidad del 91,02%.

Respecto al impacto de la IA en la mejora de la interpretación diagnóstica se encontró que el modelo automático facilita la precisión diagnóstica como Won et al. (29): usaron un modelo ensemble VGG16 con imágenes estructurales, lo cual lo hizo más fácil de obtener y menos invasivo que el PET o la fMRI. Esto lo hace más viable en contextos clínicos con recursos limitados, y como Ucañay Barreto et al. (31) que también aplicaron VGG16 preentrenado en ImageNet, lo que permite desarrollar sistemas de diagnóstico automatizados con alta precisión y relativamente baja complejidad computacional. para reducir el tiempo de procesamiento y mejorar la precisión diagnóstica usando un conjunto de datos médicos especializado.

En el caso de las imágenes PET la IA toma como herramienta los cambios asociados a biomarcadores como la retención de amiloide y alteraciones metabólicas

cerebrales, siendo crucial para detección temprana, incluso antes de que se presenten síntomas clínicos graves. Como Kim et al. (26) y Etmnani et al. (33). Ambos destacan el valor diferencial de PET en la detección de EA y otras demencias como la de cuerpos de Lewy, así como la comparación entre métodos automáticos con y sin integración de MRI. En contraposición, Kimura et al. (30) demuestra que es posible predecir la positividad de amiloide sin imágenes médicas, utilizando datos de sensores portátiles y factores de estilo de vida a través de modelos de aprendizaje automático interpretables.

La integración de la IA como herramienta diagnóstica ha permitido no solo una mejora en la precisión, sino también una mayor capacidad de integración de múltiples fuentes de información biomédica. En este contexto, los estudios que integran imágenes funcionales (PET), estructurales (IRM) y datos clínicos *y de laboratorio* representan el enfoque más completo y prometedor para abordar la complejidad clínica y biológica del Alzheimer. En la investigación de Lee et al. (25) se muestra un ejemplo destacado de integración multimodal. La idea planteada une información de PET e IRM con factores clínicos para anticipar el desarrollo de demencia en individuos que presentan un leve deterioro cognitivo. Al igual que El-Sappagh et al. (34) proponen un modelo multimodal explicable que integra PET, IRM y una amplia gama de datos clínicos, incluyendo biomarcadores sanguíneos y pruebas cognitivas. Esta integración de información de diferentes fuentes manejada por la inteligencia artificial es también conocida como radiómica. Este enfoque representa un avance crucial hacia la transparencia algorítmica. Por su parte Bao Y. et al. (24) también destacan al aplicar un enfoque multimodal basado en deep learning, con énfasis en la interpretabilidad del modelo. A través de la integración

de PET e IRM, su sistema logra una mejor caracterización de los patrones neurodegenerativos, lo que permite anteponer con mayor precisión entre distintas fases de la EA.

Los resultados mostraron el papel primordial de los algoritmos de aprendizaje profundo, especialmente las redes neuronales convolucionales, en la extracción de patrones complicados y en la predicción precisa de diagnósticos.

Adicionalmente, se evidenció que la integración de datos multimodales, como la IRM y PET, progresó la eficacia diagnóstica en comparación con métodos tradicionales. De los 14 estudios seleccionados, muestran que el uso de IA mejora significativamente la detección temprana y la clasificación de las etapas del Alzheimer, disminuyendo los tiempos de procesamiento y el margen de error humano. Solo el estudio de Bottani S. (21) al encontrar errores en el diagnóstico asistido por computadora, enfatiza que los desafíos aún presentes de la IA cuando aprende de imágenes que provienen de bases de estudios de investigación y se traslada a bases clínicas asistenciales.

El estudio reveló que la inteligencia artificial (IA) ha demostrado ser una herramienta prometedora en la mejora de la adquisición, el procesamiento y el diagnóstico de imágenes para la enfermedad de Alzheimer.

VI. LIMITACIONES

Una de las limitaciones más relevantes de este estudio es la posible omisión de investigaciones cruciales debido de restricciones en los idiomas de los artículos elegidos, ya que se priorizan los redactados en idioma inglés y español. Esto podría haber disminuido la variedad de perspectivas incluidas en la revisión.

Del mismo modo, a pesar del método PRISMA garantiza un enfoque riguroso, la dependencia de bases de datos específicas como PubMed, Embase y LILACS puede haber restringido la identificación de artículos significativos publicados en otras bases de datos. Por otro lado, los estudios incluidos muestran variabilidad en sus diseños, lo que podría influir en la comparabilidad de los resultados obtenidos.

Finalmente, el carácter retrospectivo de la revisión indica que los resultados dependen de la calidad y consistencia de los datos presentados en las investigaciones seleccionadas, lo que podría introducir sesgos no controlados en la evaluación.

VII. CONCLUSIONES

- La IA ha mostrado un efecto transformador en la adquisición de imágenes a través de RM y PET para el diagnóstico de la EA, optimizando la calidad, uniformidad y eficiencia de la información recopilada, permitiendo conseguir imágenes de manera más veloz sin comprometer la precisión.
- En lo que respecta al tratamiento de imágenes la IA ha facilitado una integración avanzada de datos de RM estructural y funcional, incluyendo cambios de atrofia en ciertas áreas cerebrales, especialmente en el lóbulo temporal medial y PET, como la identificación y medición de beta amiloide, contribuyendo a mejorar la identificación entre sujetos con deterioro cognitivo leve, EA y controles sanos. Los hallazgos reflejaron la capacidad de la IA para procesar grandes cantidades de datos de información heterogénea, detectando patrones ocultos que difícilmente serían identificables mediante métodos convencionales, y proporcionando herramientas sólidas para la estratificación del riesgo clínico y la predicción de progresión.
- La interpretación diagnóstica ha mejorado con la incorporación de IA, al permitir una mayor precisión y clasificación de los estados patológicos. Los modelos de IA cuando integran la información de neuroimágenes, datos de laboratorio y datos clínicos distinguen correctamente entre sanos, deterioro cognitivo leve y enfermedad de Alzheimer elevando la precisión diagnóstica en más del 95%.
- La IA tiene un impacto positivo en la mejora al diagnóstico por imágenes de la Enfermedad de Alzheimer mediante Resonancia Magnética y Tomografía de Emisión de Positrones, interviniendo eficazmente en todas las etapas del flujo de

trabajo con la imagen esto es en la adquisición, procesamiento e interpretación diagnóstica.

VIII. REFERENCIAS BIBLIOGRAFICAS

1. Carvajal CC. Biología molecular de la enfermedad de Alzheimer. Med Leg Costa Rica [Internet]. 2016 [citado 2024 Nov 6] Disponible en: https://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S1409-00152016000200104
2. Rodríguez JJ, Gutiérrez R, Guerra MA. Enfermedad de Alzheimer: actualización en su prevención, diagnóstico y tratamiento. Rev haban cienc méd [Internet]. 2022 [citado 2024 Nov 16]; Disponible en: <http://www.revhabanera.sld.cu/index.php/rhab/article/view/4702>
3. Organización mundial de la salud. Demencia. 2023 [citado 2024 Nov 16] Disponible en: https://www.who.int/es/news-room/fact-sheets/detail/dementia?gad_source=1&gclid=Cj0KCQiA_9u5BhCUARIsABbMSPvdbUkgbVALIE_NzAL48BPWxj692jTu1PIXK_HkABJwLrtUYJvWDx8aAsYSEALw_wcB
4. Custodio N. Living with dementia in Peru: Is the health system facing overload? 2016. [citado 2024 Nov 16] Disponible en: <https://revistas.upch.edu.pe/index.php/RNP/article/view/2762/2615>
5. Rojas G, Bartoloni L, Dillon C, Serrano CM, Allegri RF. Evaluación del paciente con demencia. *Neurol Argent*. 2011. [Internet]. Argentina [citado 13 de Diciembre de 2024] Disponible en: <https://www.elsevier.es/es-revista-neurologia-argentina-301-pdf-S185300281170026X>
6. Yang K, Mohammed EA. A review of artificial intelligence technologies for early prediction of Alzheimer's disease. [Internet]. arXiv e-prints; 2020.

[citado 13 de Diciembre de 2024] Disponible en:
<https://doi.org/10.48550/arXiv.2101.01781>

7. Zaharchuk G, Chen K, Hsu Y. La IA mejora las imágenes del Alzheimer. [Internet] *Stanford HAI*. 2023 [citado 23 de noviembre de 2024]. Disponible en: [https://hai.stanford.edu/news/ai-improves-alzheimer%E2%80%99s-imaging::contentReference\[oaicite:2\]{index=2}](https://hai.stanford.edu/news/ai-improves-alzheimer%E2%80%99s-imaging::contentReference[oaicite:2]{index=2}).
8. Loddo A, Buttau S, Di Ruberto C, Deep learning based pipelines for Alzheimer's disease diagnosis: A comparative study and a novel deep-ensemble method, *Computers in Biology and Medicine* [Internet] 2022 [Citado 2024 Nov 22] Disponible en: <https://doi.org/10.1016/j.combiomed.2021.105032>.
9. Warren SL, Moustafa AA. Functional magnetic resonance imaging, deep learning, and Alzheimer's disease: A systematic review. *J Neuroimaging*. 2023;33(1):5–18. [citado 2024 Nov 16] Disponible en: <http://dx.doi.org/10.1111/jon.13063>
10. Warren SL, Moustafa AA, Alashwal H. Harnessing forgetfulness: can episodic-memory tests predict early Alzheimer's disease? [Internet] *Exp Brain Res* 2021 [Citado 2024 Nov 20] Disponible en: <http://dx.doi.org/10.1007/s00221-021-06182-w>
11. Tory O, Frizzell, MG, Careesa CL, An Z, Dan P, Sujoy GH, et al. Artificial intelligence in brain MRI analysis of Alzheimer's disease over the past 12 years: A systematic review. [Internet] 2022 [Citado 2024 Nov 22] Disponible en:

<https://www.sciencedirect.com/science/article/abs/pii/S1568163722000563?via%3Dihub>

12. Arbizu J, García G, Carrió I, Garrastachu P, Martínez-Lage P, Molinuevo JL. Recomendaciones para la utilización de biomarcadores de imagen PET en el proceso de diagnóstico de las enfermedades neurodegenerativas que cursan con demencia: documento de consenso SEMNIM y SEN. [Internet] Rev Esp Med Nucl Imagen Mol. [Citado 2024 Nov 20] Disponible en: <https://www.elsevier.es/es-revista-revista-espanola-medicina-nuclear-e-imagen-molecular-200-pdf-S0212656715001679>
13. Ras G, et al. Combinación de aprendizaje profundo e imágenes moleculares para el diagnóstico temprano de la enfermedad de Alzheimer. [Internet] Front Aging Neurosci. 2023. [Citado 2024 Nov 16] Disponible en: <https://www.frontiersin.org/journals/aging-neuroscience/articles/10.3389/fnagi.2023.1094233/full>
14. Jie C, Treyer V, Schibli R, Mu L. Should artificial intelligence be used in conjunction with Neuroimaging in the diagnosis of Alzheimer's disease? [Internet] Pharmaceuticals (Basel). 2021 [Citado 2024 Nov 22] Disponible en: <https://doi.org/10.3390/ph14020110>
15. Breijyeh, Z., Karaman, R. Comprehensive Review on Alzheimer's Disease: Causes and Treatment. [Internet] In *Molecules*. 2020 MDPI. [Citado 2024 Nov 22] Disponible en: <https://doi.org/10.3390/MOLECULES25245789>
16. Jean, A. A brief history of artificial intelligence. [Internet] 2020. Editions EDK. [citado 11 de Diciembre de 2024] Disponible en: <https://doi.org/10.1051/medsci/2020189>

17. Currie, G., Hawk, KE., Rohren, E., Vial A., Klein, R. Machine Learning and Deep Learning in Medical Imaging: Intelligent Imaging. [Internet] In Journal of Medical Imaging and Radiation Sciences 2019 [Citado 2024 Nov 22] Disponible en: <https://doi.org/10.1016/j.jmir.2019.09.005>

18. Sprawls, Perry. *Magnetic resonance imaging : principles, methods, and techniques*. [Internet] Medical Physics Pub. 2000 [Citado 2024 Nov 22] Disponible en: <http://www.sprawls.org/resources/books/Sprawls%20Magnetic%20Resonance%20Imaging%20PMT%20%20.pdf>

19. Zatcepin, A., & Ziegler, S. I. Detectors in positron emission tomography. [Internet] In Zeitschrift fur Medizinische Physik 2023 . Elsevier GmbH. [Citado 2024 Nov 22] Disponible en: <https://doi.org/10.1016/j.zemedi.2022.08.004>

20. Hardy M, Harvey H. Artificial intelligence in diagnostic imaging: impact on the radiography profession.[Internet] Br J Radiol 2020 [Citado 2024 Nov 22] Disponible en: <https://doi.org/10.1259/bjr.20190840>

21. Zhou X, Kedia S, Meng R, Gerstein M (2024) Deep learning analysis of fMRI data for predicting Alzheimer’s Disease: A focus on convolutional neural networks and model interpretability. PLOS ONE. EE.UU [Internet]. 2024 [citado 2025 May 20] Disponible en: <https://doi.org/10.1371/journal.pone.0312848>

22. Simona B, et al. Federated learning with self-supervised pretraining for early diagnosis of Alzheimer’s disease. Med Image. Francia [Internet]. 2023 [citado 2025 May 20] Disponible en:

<https://www.sciencedirect.com/science/article/abs/pii/S136184152300163>

9

23. Wang LX, Wang YZ, Han CG, et al. Revolutionizing early Alzheimer's disease and mild cognitive impairment diagnosis: a deep learning MRI meta-analysis. *Arq Neuropsiquiatr. China* [Internet]. 2024 [citado 2025 May 20] Disponible en: <https://doi.org/10.1055/s-0044-1788657>
24. Yi Wen B, et al. Multimodal deep learning with interpretability for Alzheimer's disease diagnosis using PET and MRI. *Neuroimage Clin. China* [Internet]. 2024 [citado 2025 May 20]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1076633224004264>
25. Lee, MW., Kim, H.W., Choe, Y.S. et al. A multimodal machine learning model for predicting dementia conversion in Alzheimer's disease. *Corea del Sur* [Internet]. 2024 [citado 2025 May 20]. Disponible en: <https://doi.org/10.1038/s41598-024-60134-2>
26. Kim S, Wang SM, Kang DW, Um YH, Han EJ, et al. A Comparative Analysis of Two Automated Quantification Methods for Regional Cerebral Amyloid Retention: PET-Only and PET-and-MRI-Based Methods. *Revista Internacional de Ciencias Moleculares* [Internet]. 2024 [citado 2025 May 20]. Disponible en: <https://doi.org/10.3390/ijms25147649>
27. Zhang, Y. Hao Chan Y. Qizhi T. Jagath C. et al. Multi-modal graph neural network for early diagnosis of Alzheimer's disease from sMRI and PET scans. *Computers in biology and medicine China* [Internet]. 2023 [citado 2025 May 20]. Disponible en: 10.1016/j.combiomed.2023.107328

28. Ejaz Ul H, Qin Y, Zhou Y, Huarong X, et al. Multimodal fusion diagnosis of the Alzheimer's disease via lightweight CNN-LSTM model using magnetic resonance imaging (MRI). China [Internet]. 2023 [citado 2025 May 20] Disponible en: <https://doi.org/10.1016/j.bspc.2025.107545>
29. Won S, et al. Ensemble deep learning model for Alzheimer's disease diagnosis based on structural MRI. Biomed Eng Online [Internet]. 2023 [citado 2025 May 20]. Disponible en: 10.1186/s12938-023-01107-w
30. Kimura N, Aota T, Aso Y, et al. Predicting positron emission tomography brain amyloid positivity using interpretable machine learning models with wearable sensor data and lifestyle factors. Alzheimers Res Ther. 2023 [Internet] Japón [citado 2025 May 20]. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/38087316/>
31. Ucañay Barreto WS, Coral Ygnacio MA. Sistema de diagnóstico del Alzheimer basado en imágenes de resonancia magnética mediante el algoritmo VGG16. Latin Am J Comput. 2024 [Internet] Ecuador [citado 2025 May 20] Disponible en: <https://biblat.unam.mx/es/revista/latin-american-journal-of-computing-lajc/articulo/sistema-de-diagnostico-del-alzheimer-basado-en-imagenes-de-resonancia-magnetica-mediante-el-algoritmo-vgg16>
32. Etmnani K, Soliman A, Davidsson A, et al. A 3D deep learning model to predict the diagnosis of dementia with Lewy bodies, Alzheimer's disease, and mild cognitive impairment using brain 18F-FDG PET. 2021 [Internet] Suecia [citado 2025 May 20] Disponible en: <https://pubmed.ncbi.nlm.nih.gov/34328531/>

33. Yang Z, Zhang T, Hu Y, et al. Automated diagnosis of Alzheimer's disease using deep convolutional neural networks. 2020 [Internet] China [citado 2025 May 20]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1319562X19302906>
34. El-Sappagh S, Alonso JM, Islam SMR, et al. An explainable multimodal AI model for detection and prediction of Alzheimer's disease. 2021 [Internet] EE. UU [citado 2025 May 20] Disponible en: <https://doi.org/10.1038/s41598-021-82098-3>

IX. TABLAS

Tabla 1. Características de los artículos seleccionados

N°	Autor	País	Año	Objetivo	Diseño de estudio	Modalidad de imagen	Tipo de IA	N° Imágenes o pacientes
1	Zhou X. et al. (21)	Estados Unidos	2024	Distinguir entre sujetos con deterioro cognitivo leve y con EA, fue mejorar los mecanismos de detección temprana de la EA mediante el uso de datos de neuroimagen.	Estudio de Cohorte	fMRI	Algoritmo basado en aprendizaje profundo. (CNN)	81 participantes de fMRI
2	Bottani S. et al. (22)	Francia	2023	Estudiar experimentalmente el rendimiento de los métodos de aprendizaje automático para detectar pacientes con demencia en una CDW utilizando una resonancia magnética cerebral.	Estudio Experimental	MRI estructural - PET amiloide	Aprendizaje automático y aprendizaje profundo CNNs y Grad-CAM	2268 pacientes
3	Wang L. et al. (23)	China	2024	Analizar la precisión diagnóstica del aprendizaje profundo de imágenes de resonancia magnética en modelos de EA y MCI.	Estudio de Metaanálisis	RM y PET	Aprendizaje profundo	18 estudios retrospectivos
4	Bao Y. et al. (24)	China	2024	Explorar la capacidad discriminatoria de las características de la	Estudio de cohortes	RM estructural y PET con	Algoritmo de aprendizaje automático	261 pacientes: 94 pacientes con EA, 82

				PET A β y si la combinación de las características de la PET A β y la IRM estructural puede mejorar el rendimiento de clasificación del modelo de aprendizaje automático en OHC y DCL de EA		18F-flutemetamol y/o 11C-PiB		pacientes con DCL y 85 personas con discapacidad auditiva.
5	Lee M. et al. (25)	Corea del Sur	2024	Investigar y validar un modelo de aprendizaje automático de aplicación universal para predecir la conversión de EA en pacientes dentro de un período de tiempo de 4 años	Estudio experimental	RM T1 y T2-FLAIR, y PET amiloide (α PET)	Algoritmo de aprendizaje automático	196 imágenes
6	Kim S. et al. (26)	Corea del Sur	2024	Comparar el método de solo PET y el método basado en PET y IRM con un modelo de segmentación de aprendizaje profundo entrenado previamente para medir el rendimiento y eficacia.	Estudio Observacional analítico	PET β -amiloide - IRM estructural	Sistema tecnologías de neuroimagen avanzadas y aprendizaje profundo	1180 participantes en la base de datos
7	Zhang Y. et al. (27)	China	2023	Desarrollar un marco de GNN multimodal poblacional que integre datos de imágenes cerebrales (sMRI y PET) y datos fenotípicos para:	Estudio experimental	sMRI y PET (con 18F-FDG)	IA basada en aprendizaje profundo (GNN)	200 imágenes de pacientes con demencia

				Diagnosticar de forma temprana la EA. Predecir la progresión de DCL a Alzheimer. Superar limitaciones técnicas previas en la construcción de redes cerebrales a partir de modalidades tridimensionales.				
8	Ejaz UI H. et al. (28)	China	2025	Transformar características tridimensionales (3D) de MRI a bidimensionales (2D), las cuales son procesadas por el modelo CNN-LSTM. Busca capturar tanto las características espaciales como las secuencias temporales relevantes para la detección de la EA.	Estudio experimental	IRM	Aprendizaje profundo CNN	416 estudios
9	Won P. et al. (29)	Corea del Sur	2023	Implementar un marco de aprendizaje automático para la clasificación de la etapa de EA utilizando el índice de SUVR extraído de imágenes PET con 18 F-flortaucipir	Estudio Cohorte	PET con 18 F-flortaucipir	Sistema basado en la precisión diagnóstica por aprendizaje profundo	199 imágenes
10	Kimura N. et al. (30)	Japon	2023	Desarrollar y validar modelos predictivos	Estudio de Cohorte	IRM y PET usando	Emplea técnicas de aprendizaje	122 imágenes de pacientes

				utilizando tres técnicas de aprendizaje automático mediante la integración de variables de estilo de vida fácilmente disponibles y no invasivas para detectar individuos con deposición elevada de amiloide cerebral.		compuesto Pittsburgh B-PiB	automático tradicionales	
11	Ucañay B. (31)	Ecuador	2024	Detectar signos tempranos de la enfermedad. Su aplicación sirve para la identificación temprana y el seguimiento del Alzheimer, siendo de especial relevancia para el tratamiento y cuidado del paciente.	Estudio Experimental	Resonancia magnética estructural y funcional.	Aprendizaje automático, algoritmo de redes neuronales convolucionales denominado VGG16	416 imágenes pacientes (datos del repositorio OASIS)
12	Etminani K. et al. (32)	Suecia	2021	Desarrollar y validar un modelo de aprendizaje profundo 3D que prediga el diagnóstico clínico final de la EA, demencia con cuerpos de Lewy, deterioro cognitivo leve debido a la enfermedad de Alzheimer (DCL-EA) y cognitivamente normal (CN) utilizando PET con flúor 18	Estudio observacional analítico	PET 18F-FDG	Aprendizaje profundo 3D con puntuación F1 y curva ROC	556 imágenes de la base de datos

13	Yang Z. et al. (33)	China	2020	Identificar la EA en una etapa más temprana y proporcionar evidencia para el diagnóstico y tratamiento tempranos de la EA.	Estudio Observacional descriptivo	PET 18F-FDG	Aprendizaje profundo mediante un modelo de Red Neuronal Convolutacional	350 pacientes De la base de datos
14	Sappagh S. et al. (34)	EE.UU	2021	Optimizar el proceso de desarrollo y validación de un marco computacional de dos capas para diagnosticar pacientes con EA y predecir el deterioro cognitivo leve.	Estudio experimental	IRM	Sistema de aprendizaje automático	1048 imágenes de la base de datos

Glosario tabla 1: CNN: Redes convolucionales. EA: Enfermedad de Alzheimer. fIRM: Imágenes de resonancia funcional. sIRM: Imágenes de resonancia estructural. PET: Tomografía por emisión de positrones. OHC: personas sanas mayores. DCL: deterioro cognitivo leve. CN: cognitivamente normal. CNN-LSTM: Red Neuronal Convolutacional combinada con Memoria a Largo y Corto Plazo. SUVR: Razón Estándar de Captación Unificada. ROC: Curva Característica Operativa del Receptor. CDW: Almacén de Datos Clínicos. FDG: Fluorodesoxiglucosa-18F.

TABLA 2. Evidencia existente sobre el impacto de la IA en la mejora *de adquisición* de imágenes para el diagnóstico de la EA

SVM: Máquina de Vectores de Soporte; CL: Deterior cognitivo leve; SUVR: Relación de Valor Estandarizad; LSTM: memoria a largo plazo

Autor	Modalidad de imagen	Tipo de IA	Impacto de la IA	Principales hallazgos
Simona Bottani.et al. (22)	Resonancia magnética (T1 _w)	Algoritmo de aprendizaje profundo (CNN) y automático (SVM)	Uso de resonancia magnética ponderada en T1 con un filtro de sesgo, siguiendo un protocolo estandarizado SVM cuyo objetivo es garantizar la calidad y la homogeneización de los datos, filtrando las imágenes de baja calidad.	<ul style="list-style-type: none"> ● Las imágenes registradas se clasificaron aún más en función de los valores de intensidad mínimos y máximos. Este preprocesamiento se utilizó para evaluar la calidad de las imágenes con un enfoque automático. ● En comparación con el SVM, la CNN arrojó una mayor precisión equilibrada.
Ejaz Ul H. et al. (28)	IRM	Aprendizaje profundo CNN -LSTM	Hace posible extraer información diagnóstica relevante incluso de conjuntos de datos más reducidos o más rápidos de adquirir, puede permitir escaneos más rápidos o menos invasivos en el futuro.	<ul style="list-style-type: none"> ● El modelo propuesto CNN-LSTM multimodal ligero logró una alta precisión de clasificación entre los grupos CN, DCL y EA. ● Se reportó una precisión superior al 93%, superando a varios modelos tradicionales y más complejos.

CNN: Redes neuronales convolucionales HOC: Controles sanos mayores

Tabla 3. Evidencia existente sobre el impacto de la IA en el *procesamiento de imágenes* para el diagnóstico de la EA

AUTOR	MODALIDAD DE IMAGEN	TIPO DE IA	IMPACTO DE LA IA	PRINCIPALES HALLAZGOS
Bao Y. et al. (24)	RM estructural y PET con 18F-flutemetamol y/o 11C-PiB	Algoritmo de aprendizaje automático (Random Forest)	La incorporación de información multimodal (PET amiloide- β y RM estructural) en un modelo de aprendizaje automático incrementa la exactitud en la categorización de la EA.	<ul style="list-style-type: none"> ● La combinación de características de PET de amiloide-β y RM estructural mejora significativamente el rendimiento del modelo en la clasificación de la EA frente a HOC y DCL.
Lee M. et al. (25)	IRM PET amiloide	Modelos de Aprendizaje automático (DT, RF, SVM, XGB)	Mejora del procesamiento de imagen, mejorando la predicción de EA con la modalidad GBM, utilizando una combinación de características de IRM estructurales y funcionales.	Se descubrió que la probabilidad de que un paciente con DCL se convierta a enfermedad de Alzheimer EA en un plazo de 2 a 4 años podía predecirse mediante aprendizaje automático con base en las características demográficas del individuo, los volúmenes regionales, el HOC y los SUVR regionales.
Kim S. et al. (26)	PET β -amiloide - RMI estructural	Sistema tecnologías de neuroimagen avanzadas y aprendizaje profundo	Permite una mejor alineación y segmentación de las regiones cerebrales, lo que mejora la precisión en la cuantificación de la retención de amiloide.	<ul style="list-style-type: none"> ● Utilizar tanto PET como MRI y segmentar en el espacio nativo en lugar del espacio estándar podría reducir errores potenciales, lo que permitiría una extracción más precisa de los valores SUVR <p>El modelo LR, será usara para predecir la lectura visual usando SUVR regionales como entradas, los valores extraídos a través del método PET-MRI mejoraron significativamente el rendimiento del modelo.</p>
Zhang Y. et al. (27)	sMRI y PET (con 18F-FDG)	IA basada en aprendizaje profundo (MM-GNN)	La red neuronal de grafos puede almacenar información sobre la similitud entre nodos. Las GCN pueden filtrar señales y agregar información de nodos vecinos para obtener representaciones de características	<ul style="list-style-type: none"> ● Al combinar características de sMRI y PET, el modelo MM-GNN logra una representación más completa del cerebro, mejorando la precisión en la clasificación de sujetos con EA, DCL y OHC.

mejoradas, que a su vez pueden utilizarse para la predicción de enfermedades y el análisis de grafos.

GBM: Máquina de Potenciación por Gradiente. GCN: Red Neuronal Gráfica Convolutiva. GNN: Red Neuronal de Grafo. MM: Multimodal. LR: Regresión Logística.

Tabla 4. Evidencia existente sobre el impacto de la IA en la *mejora de interpretación diagnóstica por imágenes* de la EA

Autor	Modalidad de imagen	Tipo de IA	Impacto de la IA	Principales hallazgos
Zhou X. et al. (21)	fMRI	Aprendizaje profundo CNN	<ul style="list-style-type: none"> ● Mejora de la interpretabilidad usando mapas de características y visualizaciones SHAP para identificar qué regiones cerebrales influyen más en la predicción. ● Demuestra que estructuras de red más simples pueden ser tan efectivas como modelos complejos si se configuran adecuadamente. ● Mejora la interpretabilidad gracias a la reducción del número de capas y la complejidad. 	<ul style="list-style-type: none"> ● CNN demuestra niveles de precisión que alcanzan el 92,8 % y un ROC de 0,95 superando a modelos previos, lo que lo hace más eficiente y accesible. ● El modelo mostró un rendimiento competitivo, alcanzando una precisión y un AUC de 0,8333 ($\pm 0,0589$) y 0,8930 ($\pm 0,0588$), respectivamente, demostró una precisión, recuperación, MCC superiores
Bottani S. et al. (22)	MRI estructural - PET de amiloide	Aprendizaje profundo CNN	<p>Mejoras técnicas de atención y visualización que permiten identificar qué regiones cerebrales influyen más en las decisiones del modelo, facilitando la comprensión de los resultados</p> <p>No obstante, el rendimiento diagnóstico asistido por computadora está sesgado hacia arriba y pasa porque la IA aprende de imágenes de bases de investigación y no de imágenes de bases hospitalarias</p>	<ul style="list-style-type: none"> ● Se observó una disminución significativa de la precisión equilibrada en comparación con la obtenida en el conjunto de datos de investigación: 68,8 % para D vs. NDNL y 73,1 % para D vs. NDNL, en comparación con el 86,4 % para EA vs. CN en ADNI. ● En las categorías de demencia y NDNL, la mayoría de las imágenes son de calidad buena/media (58% y 52%, respectivamente), mientras que en la categoría NDNL solo el 36% de las imágenes son de calidad buena/media.

Wang L. et al. (23)	MRI	Aprendizaje profundo - ResNet18	Implementa técnicas de visualización como los mapas de activación, el modelo destaca las regiones cerebrales que influyen en la clasificación	<ul style="list-style-type: none"> • La sensibilidad combinada de la RM ponderada en T1 fue de 0,84, similar a la de la RM no ponderada en T1. • La curva AUROC fue 0,92 lo que indica que el aprendizaje profundo basado en RM tuvo una alta precisión para diferenciar el diagnóstico de EA y DCL en términos de sensibilidad y especificidad. • El punto Q de la curva HSROC fue de 3,463
Won P. et al. (29)	PET con 18 F-flortaucipir	Aprendizaje automatico, (Logistic Regression) (XGBoost)(MLP)(SVM)	Mejora la clasificación correctamente a los pacientes en diferentes etapas de la enfermedad. Gracias al uso de la técnica SHAP mejora la comprensión de los patrones subyacentes a la progresión de la enfermedad.	<ul style="list-style-type: none"> • Mostro que la combinación de variables clínicas y SUVR de tau mejoró significativamente la precisión de la clasificación, con un AUC superior a 0.96 en la mayoría de los modelos para la clasificación entre CU y EA.
Kimura N. et al. (30)	IRM y PET usando compuesto Pittsburgh B-PiB	Aprendizaje automatico Elastic Net, Gradient Boosting	Los modelos de aprendizaje automático fueron capaces de predecir con buena precisión la positividad de amiloide cerebral, utilizando únicamente datos derivados de sensores portátiles y factores de estilo de vida, sin requerir directamente imágenes PET.	<ul style="list-style-type: none"> • El ROC del modelo que utilizó únicamente factores de estilo de vida medidos objetivamente fue de 0,70, mientras que la de los modelos que utilizaron sensores portátiles en combinación con características demográficas y cuestionarios de salud y entorno vital fue de 0,79.
Ucañay W. et al. (31)	Magnetic Resonance Imaging	Aprendizaje automatico (VGG16 Algorithm)	Mejora la precisión y la eficacia de la interpretación de imágenes, mitigando así algunos de los problemas asociados a la interpretación humana, reduciendo tiempos de análisis.	<ul style="list-style-type: none"> • Aplicación de capas convolucionales que recorren toda la imagen y generan mapas de características. Estos filtros permiten detectar patrones locales en las imágenes. • El modelo VGG16 mostró una precisión del 98.6%, una sensibilidad del 98.2% y una especificidad del 98.8%, al clasificar correctamente entre controles sanos, pacientes con DCL y con EA
Etminani K. e. et al. (32)	PET FDG 18F	Aprendizaje profundo 3D CNN y curva ROC	Logra una precisión del 95.6% en la clasificación de pacientes con diferentes tipos de demencia, incluyendo EA.	<ul style="list-style-type: none"> • El modelo alcanzó un rendimiento perfecto en los casos de DLB con una sensibilidad del 86%, una especificidad del 100% y una

				<p>precisión del 100% y una puntuación F1 del 92%.</p> <ul style="list-style-type: none"> • A diferencia de los métodos existentes, el modelo presentado puede distinguir casos de EA, CN, DCL-EA y DLB con un AUC del 96,4 %, 94,7 %, 71,4 % y 96,2 %, respectivamente.
Yang Z. et al. (33)	PET 18F-FDG	Aprendizaje profundo CNN	<p>La predicción del riesgo de EA basada en el modelo de aprendizaje profundo de la PET cerebral con 18F-FDG, coincidió con los resultados esperados, logrando resultados predictivos preferibles en el problema de la transformación del DCL. Proporcionó un modelo de referencia relativamente preciso para la predicción de EA</p>	<ul style="list-style-type: none"> • La clasificación de conv3 logró resultados preferibles en la predicción de DCL, con una sensibilidad y especificidad de 91,02% y 77,63%. • La capa conv5, la precisión fue del 72,19 %, y la sensibilidad y la especificidad de 73 %, lo que indica que el modelo de clasificación fue útil para la clasificación de DCLT y DCLD.

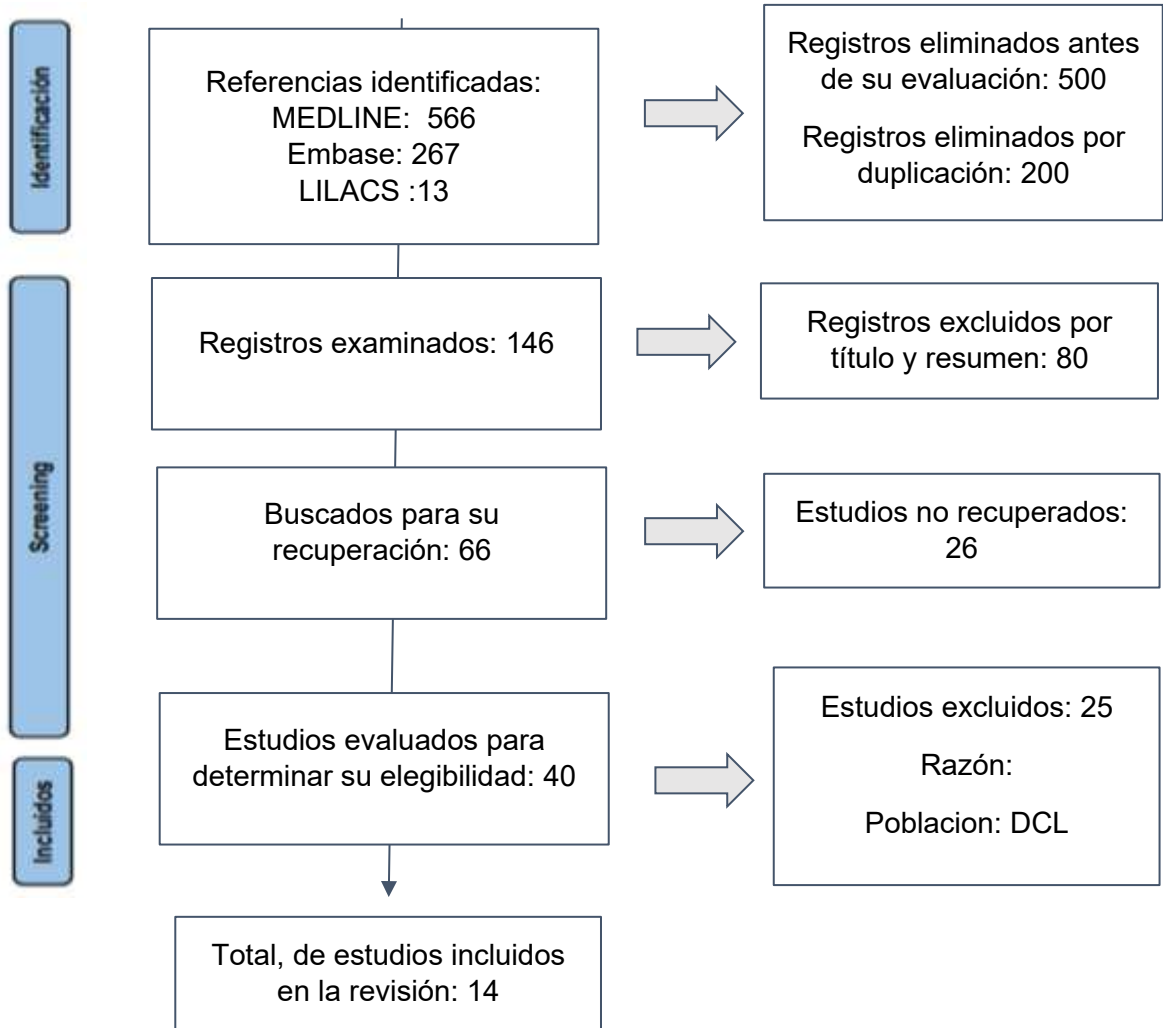
Shaker S. et al. (34)	IRM y PET FDG	Aprendizaje automatico Random Forest - SHAP (SHapley Additive exPlanations)	El sistema propuesto puede contribuir a mejorar la comprensión clínica del diagnóstico y los procesos de progresión de la EA, proporcionando información detallada sobre el efecto de las diferentes modalidades en el riesgo de padecer la enfermedad.	<ul style="list-style-type: none"> • La combinación de dos modalidades CS + NB mejoró la precisión de CS en aproximadamente un 1 %, es decir, MCA = $93,00 \pm 2,61$ %. • Los datos genéticos mejoraron la precisión del sistema a $93,95 \pm 2,30$ %. RF muestra más confianza basada en el conjunto de datos CS + NB + Genética que el conjunto de datos CS + NB. • Observamos que las clases de EA y DCL se relacionan con valores negativos de ADNI_MEM, mientras que CN se relaciona con valores positivos.
--------------------------	------------------	---	---	---

ROC: Curva de Característica Operativa del Receptor. NDL: No Demencia Lesiones. NDNL: No Demencia No Lesiones. D: Demencia

AUC: Área Bajo la Curva. MCC: Coeficiente de Correlación de Matthews. DLB: Demencia con Cuerpos de Lewy. DCLT: Deterioro Cognitivo Leve Temprano. DCLD: Deterioro Cognitivo Leve Tardío. CS: Líquido Cefalorraquídeo. CN: Controles Cognitivamente Normales. MCA: Análisis de Correspondencia Múltiple. RF: Bosque Aleatorio. ADNI_MEM: Puntuación de Memoria de la Iniciativa de Neuroimagen del Alzheimer.

X. ANEXOS

ANEXO I. PRISMA-S



ANEXO II. PCC: POBLACION-CONCEPTO-CONTEXTO

¿Cuál es la evidencia actual sobre el impacto de la inteligencia artificial en la mejora de la adquisición, el procesamiento y la interpretación diagnóstica de imágenes por resonancia magnética y tomografía de emisión de positrones en la enfermedad de Alzheimer?

Población:	Mayores de 18 años
Concepto:	La inteligencia artificial (IA) en el diagnóstico por imágenes de la enfermedad de Alzheimer mediante resonancia magnética y tomografía de emisión de positrones.
Contexto:	Atención ambulatoria en establecimientos de salud de alto nivel resolutivo

ANEXO III. Estrategias de búsqueda

Fuente de búsqueda	Términos
PubMed	("Artificial Intelligence"[Mesh] OR "Machine Learning"[Mesh] OR "Deep Learning"[Mesh]) AND ("Alzheimer Disease"[Mesh]) AND ("Diagnostic Imaging"[Mesh] OR "Positron-Emission Tomography"[Mesh] OR "Magnetic Resonance Imaging"[Mesh])
Web of Science	TS= ("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning") AND TS= ("Alzheimer Disease") AND TS= ("Diagnostic Imaging" OR " Positron-Emission Tomography " OR "MRI"
Scopus	TITLE-ABS-KEY (("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning") AND ("Alzheimer Disease") AND ("Diagnostic Imaging" OR " Positron-Emission Tomography" OR "MRI"))
EMBASE	('artificial intelligence'/exp OR 'machine learning'/exp OR 'deep learning'/exp) AND (' alzheimer disease '/exp) AND ('diagnostic imaging'/exp OR 'positron-emission tomography'/exp OR 'magnetic resonance imaging'/exp)
Google académico	"Artificial Intelligence" OR "Machine Learning" OR "Deep Learning" AND " Alzheimer Disease " AND "Diagnostic Imaging" OR "Positron-Emission Tomography" OR "MRI"
Literatura Gris	Inteligencia artificial enfermedad de alzheimer

ANEXO IV. Operacionalización de variables

Variable	Definición conceptual	Definición operacional	Tipo de variable	Dimensiones	Escala de medición	Indicadores
Enfermedad de Alzheimer	Patología neurodegenerativa crónica y progresiva lo que provoca un deterioro gradual de la memoria, el razonamiento y las capacidades cognitivas (15).	Perdidas de la memoria. Deterioro cognitivo funcional (15).	Principal	Enfermedad de Alzheimer temprana	Cualitativa nominal	Diagnóstico clínico
				Enfermedad de Alzheimer tardía		
Inteligencia Artificial	Es un campo de la informática y una disciplina de investigación, que se centra en crear sistemas que puedan analizar, comprender y predecir un fenómeno (16).	Desarrollo y aplicación de sistemas informáticos que utilizan algoritmos y técnicas avanzadas para procesar y analizar grandes cantidades de datos (17).	Principal	Aprendizaje profundo (Deep learning)	Cualitativa nominal	Tipo de IA utilizado
				Aprendizaje automático (machine learning)		
Resonancia magnética	El estudio de resonancia magnética incluye los procesos de	Procedimiento médico y diagnóstico no invasivo que utiliza	Principal	Resonancia magnética convencional (RM)	Cualitativa nominal	Tipo de Resonancia magnetical

	adquisición de imágenes Procesamiento de imágenes, diagnóstico de imágenes (18).	campos magnéticos y ondas de radiofrecuencia para generar imágenes detalladas del interior del cuerpo (18).		Resonancia magnética funcional (RMf)		
				Resonancia magnética espectroscópica		
Tomografía de Emisión de Positrones (PET)	Técnica de diagnóstico por imágenes moléculas no invasivas. basada en fotones de aniquilación y desintegración de positrones (19).	Procedimiento de neuroimagen que utiliza marcadores marcados con radioisótopos para moléculas de interés (19).	Principal	Tomografía de Emisión de Positrones (PET) con marcador molecular para beta amiloide	Cualitativa nominal	Tipo de PET según marcador
				Tomografía de Emisión de Positrones (PET) con otro marcador de molécula anormal		
				Tomografía de Emisión de Positrones		

				(PET) con marcador radiometabóli co como la 18F-FDG		
				Tomografía de Emisión de Positrones (PET) con marcador molecular para proteína tau		
Flujo de trabajo con la imagen radiológica	La secuencia de trabajo con imágenes médicas incluye tres etapas principales: la adquisición de imágenes mediante técnicas como RM o PET, su procesamiento para optimizar su calidad y funcionalidad, y su posterior lectura diagnóstica basada en las imágenes procesadas (20).	Etapas en el flujo de trabajo con la imagen radiológica (20).	Principal	Adquisición de las imágenes	Cualitativa nominal	Etapas de flujo del trabajo con la imagen
				Procesamiento de las imágenes		
				Interpretación diagnóstica de las imágenes		