



UNIVERSIDAD TÉCNICA DE MACHALA  
FACULTAD DE INGENIERÍA CIVIL

MAESTRÍA EN SOFTWARE

DESARROLLO DE UNA APLICACIÓN MÓVIL PARA CLASIFICACIÓN DE IMÁGENES DE  
ALZHEIMER MEDIANTE APRENDIZAJE AUTOMÁTICO

OSCAR PATRICIO CUENCA MORENO

Propuesta Metodológica y Tecnológica Avanzada

TUTOR: ING. WILMER RIVAS  
COTUTOR: ING. EDUARDO TUSA

MACHALA  
2024

## **RESPONSABILIDAD DE AUTORÍA**

Yo, Oscar Patricio Cuenca Moreno con C.I. 0705209526, declaro que el trabajo de “Desarrollo de una aplicación móvil para clasificación de imágenes de Alzheimer mediante aprendizaje automático”, en opción al título de Magister en Software, es original y auténtico; cuyo contenido: conceptos, definiciones, datos empíricos, criterios, comentarios y resultados son de mi exclusiva responsabilidad.

OSCAR PATRICIO CUENCA MORENO

C.I. 0705209526

Machala, 2024/05/08

## **CERTIFICACIÓN DEL TUTOR**

Yo, Wilmer Braulio Rivas Asanza con C.I 0702580192; tutor del trabajo de “Desarrollo de una aplicación móvil para clasificación de imágenes de Alzheimer mediante aprendizaje automático”, en opción al título de Magister en Software, ha sido revisado, enmarcado en los procedimientos científicos, técnicos, metodológicos y administrativos establecidos por el Centro de Posgrado de la Universidad Técnica de Machala (UTMACH), razón por la cual doy fe de los méritos suficientes para que sea presentado a evaluación.

WILMER BRAULIO RIVAS ASANZA  
C.I 0702580192

Machala, 2024/05/08

INFORME DE ORIGINALIDAD

---

4%

INDICE DE SIMILITUD

3%

FUENTES DE INTERNET

0%

PUBLICACIONES

3%

TRABAJOS DEL  
ESTUDIANTE

---

ENCONTRAR COINCIDENCIAS CON TODAS LAS FUENTES (SOLO SE IMPRIMIRÁ LA FUENTE SELECCIONADA)

---

< 1%

★ libros.catedu.es

Fuente de Internet

---

---

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo

**Resumen:** Este trabajo detalla el desarrollo de una aplicación móvil diseñada para la detección de fases de la enfermedad de Alzheimer (EA), mediante técnicas de inteligencia artificial y análisis de imágenes de resonancia magnética cerebral (IRM). La creciente prevalencia del Alzheimer y la necesidad de diagnósticos precoces hacen indispensable la implementación de herramientas que mejoren la precisión y accesibilidad en la identificación de esta enfermedad neurodegenerativa. Se utilizó un modelo basado en redes neuronales convolucionales (CNN) para clasificar IRM en diferentes fases de la enfermedad de Alzheimer, entrenado con un extenso conjunto de datos obtenido de Kaggle. La metodología empleada incluyó el preprocesamiento de imágenes, la implementación de arquitecturas optimizadas de CNN y la integración del modelo en una aplicación móvil funcional. Los resultados de la evaluación del modelo mostraron una precisión general del 98%, con un rendimiento particularmente alto en la identificación de "Demencia Moderada" y "Sin Demencia". La aplicación móvil no solo facilita el análisis de IRM, sino que también ofrece una interfaz de usuario amigable y eficiente, adecuada para profesionales de la salud y pacientes. Este avance representa un progreso significativo en el campo de la detección de fases de la enfermedad de Alzheimer, una herramienta confiable que puede aumentar la calidad del diagnóstico y permitir una intervención temprana. Se recomienda realizar estudios adicionales con datos más diversos y ajustar la arquitectura del modelo para optimizar aún más su rendimiento en entornos clínicos variados.

**Palabras clave:** Alzheimer, inteligencia artificial, redes neuronales convolucionales, aplicación móvil, detección de fases de la enfermedad de Alzheimer, imágenes de resonancia magnética cerebral.

**Abstract:**

This work details the development of a mobile application designed for the detection of phases of Alzheimer's disease (EA), utilizing artificial intelligence techniques and analysis of cerebral magnetic resonance imaging (MRI). The increasing prevalence of Alzheimer's disease and the need for early diagnoses make the implementation of tools that improve precision and accessibility in the identification of this neurodegenerative disease indispensable. A convolutional neural network (CNN)-based model was used to classify MRI scans into different phases of Alzheimer's disease, trained with an extensive dataset obtained from Kaggle. The methodology employed included image preprocessing, the implementation of optimized CNN architectures, and the integration of the model into a functional mobile application. The model evaluation results showed an overall accuracy of 98%, with particularly high performance in identifying 'Moderate Dementia' and 'No Dementia'. The mobile application not only facilitates the analysis of MRI but also offers a user-friendly and efficient interface, suitable for healthcare professionals and patients. This advancement represents significant progress in the field of detecting phases of Alzheimer's disease, a reliable tool that can enhance diagnostic quality and enable early intervention. Additional studies with more diverse data are recommended, as well as adjusting the model architecture to further optimize its performance in various clinical settings.

**Keywords:** Alzheimer, artificial intelligence, convolutional neural networks, mobile application, detection of phases of Alzheimer's disease, cerebral magnetic resonance imaging.

## CONTENIDO

INTRODUCCIÓN .....	12
i.    Formulación del problema .....	17
ii.   Objetivos .....	17
Objetivo general.....	17
Objetivos específicos .....	17
iii.  Diseño Metodológico.....	18
iv.   Delimitación del objeto y campo de estudio .....	18
CAPÍTULO 1 .....	20
1.  MARCO TEÓRICO .....	20
1.1.  ANTECEDENTES HISTÓRICOS.....	20
1.1.1.  Trabajos previos .....	22
1.2.  ANTECEDENTES CONCEPTUALES Y REFERENCIALES .....	23
1.2.1.  Variables del Estudio .....	23
1.2.2.  Hipótesis de la Investigación.....	23
1.2.3.  Fundamentación Teórica de la Variable Dependiente.....	23
1.2.4.  Enfoques Tecnológicos.....	23
1.2.5.  Clasificación de las fases de la EA .....	23
1.2.6.  Personalización de Tratamientos .....	23
1.2.7.  Biomarcadores y Predicción .....	23
1.2.8.  Aumento en la Predicción y Respuesta a Terapias.....	23
1.3.  FUNDAMENTACIONES TEÓRICAS .....	23
1.3.1.  Enfermedad de Alzheimer.....	23
1.3.1.1.  Anatomía Patológica .....	23
1.3.2.  Causas o factores que originan la EA .....	25
1.3.3.  Síntomas de la EA .....	26
1.3.4.  Diagnóstico.....	27
1.3.5.  Spin Echo (SE) .....	32
1.3.6.  Gradiente de Echo (GE) .....	32
1.3.7.  Visión Artificial .....	33
1.3.8.  Aprendizaje Automático .....	33
1.3.9.  Aprendizaje Supervisado .....	33
1.3.10.  PCA (Análisis de Componentes Principales) .....	34
1.3.11.  SVM (Máquinas de Vectores de Soporte) .....	34
1.3.11.1.  SVM con Kernel Lineal .....	34

1.3.11.2.	SVM con Kernel Polinomial.....	35
1.3.11.3.	SVM con Kernel RBF (Función de Base Radial).....	35
1.3.12.	Aprendizaje No Supervisado.....	35
1.3.13.	Aprendizaje por Refuerzo.....	36
1.3.14.	Redes Neuronales Convolucionales (CNN):.....	36
1.3.15.	Convolución.....	37
1.3.16.	Estructura de CNN.....	40
1.3.17.	Componentes de la Estructura de la CNN.....	41
1.3.18.	Hiperparámetros.....	44
1.3.19.	Convoluciones (1:1).....	46
1.4.	Antecedentes contextuales.....	47
CAPÍTULO II.....		51
2.	MATERIALES Y MÉTODOS.....	51
2.1.	Tipo de estudio o investigación.....	51
2.2.	Estudio correlacional.....	52
2.3.	Diseño de la investigación.....	52
2.3.1.	Enfoque cuantitativo.....	53
2.4.	Población y muestra.....	53
2.5.	Técnicas estadísticas.....	54
2.6.	Métodos teóricos.....	54
2.7.	Metodología CRISP-DM.....	55
2.7.1.	Fase de comprensión del negocio.....	55
2.7.2.	Fase de comprensión de los datos.....	56
2.7.3.	Fase de preparación de los datos.....	56
2.7.4.	Fase de modelado.....	57
2.7.5.	PCA.....	57
2.7.6.	Modelo SVM con Kernel Lineal.....	58
2.7.7.	Modelo SVM con Kernel Polinomial.....	58
2.7.8.	Modelo SVM Kernel rbf.....	59
2.8.	Fase de evaluación:.....	59
2.9.	Fase de despliegue:.....	60
CAPÍTULO III.....		61
3.	DESARROLLO DE LA APLICACIÓN MÓVIL.....	61
3.1.	Aplicación de CRISP-DM en la selección de modelos de ML para la clasificación de fases de la EA.....	61
3.1.1.	Fase de comprensión del negocio.....	61

3.1.2.	Fase de comprensión de los datos .....	62
3.1.3.	Fase de preparación de los datos .....	62
3.1.4.	Fase de modelado .....	62
3.1.4.1.	PCA .....	62
3.1.4.2.	Modelo SVM con Kernel Lineal .....	62
3.1.4.3.	Modelo SVM con Kernel Polinomial .....	63
3.1.4.4.	Modelo SVM con Kernel RBF .....	63
3.1.5.	Fase de evaluación.....	63
3.1.6.	Fase de despliegue.....	63
3.2.	Desarrollo de una aplicación móvil que integra el modelo de ML seleccionado para la clasificación de las fases de la EA utilizando la metodología SCRUM .....	65
CAPÍTULO IV .....		69
4.	EVALUACIÓN DE LA PROPUESTA Y DISCUSIÓN DE RESULTADOS .....	69
4.1.	Matriz de confusión.....	69
4.2.	Matriz de observación.....	70
4.3.	Resultados de la prueba de eficiencia.....	71
4.4.	Descripción visual de la aplicación móvil en funcionamiento.....	75
4.5.	Discusión de resultados .....	77
CONCLUSIONES .....		79
RECOMENDACIONES .....		80
BIBLIOGRAFÍA.....		81
ANEXOS.....		91

## ÍNDICE DE FIGURAS

Figura 1. Análisis de cronológico de estudios previos de la aplicación de IA en Alzheimer..	22
Figura 2. Atrofia cerebral en la EA.....	24
Figura 3. Placas amiloides. ....	25
Figura 4. Detección y diagnóstico de EA [10].....	28
Figura 5. Representación de la secuencia spin echo con realce en T2. Se observan áreas con alta señal correspondientes a estructuras con abundante contenido de agua, como el líquido cefalorraquídeo; los tejidos con presencia considerable de grasa se visualizan. ....	30
Figura 6. Ilustración de la secuencia de eco de espín, que comprende un pulso inicial de 90 grados seguido por un pulso de 180 grados. ....	32
Figura 7. Ejemplo de convolución con un kernel para la extracción de características en imágenes. ....	40
Figura 8. Estructura de una CNN.....	40
Figura 9. Arquitectura de una red neuronal convolucional.....	41
Figura 10. Max-pooling. ....	42
Figura 11. Esquema de desarrollo de la aplicación móvil. ....	55
Figura 12. Modificación de la escala de colores obtenida dentro de la aplicación móvil. ....	64
Figura 13. Metodología SCRUM aplicada para la aplicación de modelado de la aplicación. ....	65
Figura 14. Prototipo Mockups de la parte visual de la aplicación móvil.....	68
Figura 15. Matriz de confusión del entrenamiento. ....	69
Figura 16. Métricas de precisión, recall y F1-score para las categorías de clasificación de los modelos.....	70
Figura 17. Descripción visual de la probabilidad de clasificación para cada una de las fases de la EA .....	71
Figura 18. Arquitectura del modelo CNN utilizada en la evaluación del algoritmo .....	72
Figura 19. Perdida y precisión de la clasificación de las imágenes en el entrenamiento. ....	73
Figura 20. Descripción grafica de la precisión de los tipos en la clasificación. ....	74
Figura 21. Descripción visual de la interfaz de la aplicación móvil.....	76

## ÍNDICE DE TABLAS

Tabla 1 Hiperparámetros para convoluciones.....	45
Tabla 2 Descripción de la interfaz visual de la aplicación móvil .....	67

## INTRODUCCIÓN

La demencia, particularmente la enfermedad de Alzheimer (EA), es una preocupación global, y la clasificación de las fases de la EA es crucial para la intervención efectiva. Desafortunadamente, los métodos actuales son costosos y requieren expertos. La integración de inteligencia artificial (IA) mediante el empleo de neuroimágenes puede facilitar su comprensión, pues a partir de esta tecnología se puede generar un algoritmo capaz de clasificar las fases de la EA [1]. En Ecuador, la EA tiene un impacto significativo, debido a las afectaciones que produce a las personas y en los sistemas de salud público y privado. Aunque no hay cura, las IRM cerebrales y el aprendizaje automático (AA) han revolucionado el diagnóstico [2], además, el AA permite un análisis sistemático de datos de alta dimensión [3].

La EA se caracteriza por ser un trastorno cerebral progresivo e irreversible que gradualmente afecta la memoria y las capacidades cognitivas [4]. Con una alta prevalencia en individuos mayores de 65 años a nivel global, la EA constituye una de las principales causas de demencia, asociada tanto a factores genéticos como ambientales. Es un trastorno exclusivo del sistema nervioso central en el que se produce una lenta destrucción y atrofia de la corteza cerebral [1]. Para lograr una identificación precisa y temprana, así como la clasificación en las fases iniciales de la enfermedad, se han propuesto diversos enfoques de diagnóstico asistido por computadora (CAD) basados en IA, a partir de datos obtenidos de IRM [5].

La IA fue descrita por primera vez en 1950; sin embargo, las limitaciones de los primeros modelos utilizados en la clasificación de la EA restringieron su aceptación en la medicina. Con avances como el aprendizaje automático (AA) en la década de 2000, se superaron esas limitaciones, permitiendo que la IA se aplique a la práctica clínica, mejorando diagnósticos y eficiencia [6]. Para comprender mejor, la IA es un fenómeno tecnológico de rápido crecimiento que diversas industrias desean explotar para beneficiarse de ganancias en eficiencia y reducciones de costos. Otra corriente de pensamiento sugiere que, en lugar de reemplazar la mente humana, la IA puede proporcionar recursos adicionales para mejorar el tratamiento y la clasificación temprana de enfermedades [7].

n este contexto, la IA es crucial para analizar conjuntos de datos extensos y complejos. Por tal motivo, la revisión se centra en la aplicación de herramientas de CAD y el uso de la IA para respaldar prácticas clínicas, como la predicción del riesgo individual de conversión a EA y la estratificación de pacientes para el desarrollo de terapias efectivas y personalizadas [8]. En la

práctica clínica, existen limitaciones en la estandarización, comparabilidad y conexión entre los objetivos del estudio y las aplicaciones clínicas. Se destaca la necesidad de cerrar estas brechas para facilitar la traducción de la investigación futura a la práctica clínica [9].

Revisiones bibliográficas y análisis de ejemplos del mundo real revelan que los hospitales emplean sistemas que permiten fortalecer al personal médico en el diagnóstico y tratamiento de diversas enfermedades [4]. Estos sistemas también aumentan la eficiencia en actividades de enfermería y gestión hospitalaria. Aunque la adopción de la IA en la atención médica es positiva, el estudio destaca tanto las perspectivas utópicas (nuevas oportunidades) como las distópicas (desafíos a superar) [10,11].

Adicionalmente, es necesario considerar los retos éticos asociados con la aplicación de IA en la clasificación de las fases de la EA en individuos asintomáticos. Aunque la clasificación temprana es beneficiosa para el derecho a saber y la planificación futura, también se han señalado preocupaciones éticas, como la falta de tratamientos, la precisión de las clasificaciones realizadas por IA y las amenazas a los derechos sociales [10].

Estudios actuales basados en la fusión de extremo a extremo y la transferencia de aprendizaje para la clasificación de las fases de la EA han aprovechado las ventajas de la tecnología de CNN. La convergencia de estas tecnologías podría dar lugar a una aplicación móvil basada en CNN para la clasificación de las fases de la EA en la práctica clínica [10]. Identificar a pacientes con deterioro cognitivo leve (DCL) que evolucionarán a EA es un desafío. La IA, especialmente el aprendizaje automático (AA), ha demostrado ser una herramienta poderosa para extraer predictores confiables y clasificar automáticamente las fases de la EA [12].

A su vez, es necesario llevar a cabo una planificación estratégica y efectiva para maximizar los beneficios de las aplicaciones de IA en el sector de la salud [4]. Los rápidos avances en la IA aumentan la eficiencia operativa y generarán nuevo valor para los pacientes. Su implementación efectiva requerirá una transformación integral en los servicios y operaciones de atención médica, lo que permitirá una mejor clasificación de las fases de la EA y otros beneficios.

A pesar de décadas de esfuerzos, el rompecabezas de la EA sigue incompleto. Comprender su patogénesis continúa siendo un desafío persistente. No obstante, las iniciativas recientes de intercambio de datos abiertos ofrecen una oportunidad sin precedentes para obtener

información sobre la enfermedad. La integración de conjuntos de datos provenientes de estudios multi-ómicos permite explorar de manera exhaustiva los mecanismos patofisiológicos de la EA [8].

Se identifican desafíos como la falta de equipos, costos y dificultades para obtener el consentimiento del paciente [13]. La EA es una enfermedad neurodegenerativa progresiva que provoca atrofia cerebral y la muerte de células cerebrales. Afecta principalmente a personas mayores de 65 años y es una de las principales causas de demencia. Dado que no existe un tratamiento efectivo hasta la fecha, la identificación temprana es crucial [14]. En este sentido, el estudio se centra en clasificar las fases de la EA mediante el método de propagación de relevancia en capas en la IA explicativa. Actualmente, se emplean arquitecturas de redes neuronales, como VGG-16 y otras, para incrementar la precisión del análisis. La aplicación de la IA proporciona resultados con explicaciones detalladas, lo que aumenta la confiabilidad de los resultados en el análisis de la EA [14].

Estudios previos demuestran que el modelo alcanza una alta precisión y puntaje F1 (una métrica que combina precisión y sensibilidad) en la validación cruzada, lo que lo hace tanto preciso como confiable. Las explicaciones proporcionadas son coherentes entre sí y con la literatura médica sobre la EA, lo que hace que el sistema sea aplicable y útil en el ámbito clínico para la comprensión de los procesos de diagnóstico y progresión de la EA [15]. El estudio previamente mencionado destaca el aumento significativo en las capacidades de simulación, gracias al rápido avance en la potencia informática y el uso de unidades de procesamiento gráfico (GPU). Este estudio se enfoca en la aplicación de técnicas como la inteligencia artificial, el aprendizaje automático y las redes neuronales para analizar los extensos datos generados en simulaciones de la cinética de la agregación de proteínas en la EA [16]. En otros casos, los resultados del metaanálisis indican que el AA aplicado a medidas neuropsicológicas puede lograr una clasificación automática exitosa, tanto como herramienta de clasificación como de pronóstico. Se pueden extraer categorías relevantes de pruebas neuropsicológicas usando AA para maximizar la precisión de la clasificación [3].

A su vez, los modelos de aprendizaje automático para clasificar entre sujetos sanos, individuos con deterioro cognitivo y sujetos con demencia utilizan diferentes índices cognitivos. Un análisis longitudinal de los valores SHapley Additive exPlanations (SHAP) puede ofrecer información efectiva sobre la progresión de la EA [17]. Además, se utiliza un marco computacional basado en AA para extraer representaciones de baja dimensión de datos de

interacción (PIN). La aplicación de este marco para identificar posibles objetivos terapéuticos en la EA ha resultado en la identificación exitosa de genes clave, como DLG4, EGFR, RAC1, SYK, PTK2B y SOCS1. También se pueden inferir compuestos candidatos para el reposicionamiento en el tratamiento de la EA, como tamoxifeno, bosutinib y dasatinib, basándose en estos posibles objetivos [11].

Además de las imágenes que pueden ser analizadas, también se puede realizar la identificación de genes de riesgo para la EA y posibles objetivos terapéuticos utilizando un marco de IA basado en redes [18]. Por ejemplo, en un estudio donde se integraron datos de estudios de asociación del genoma (GWAS), datos multi-ómicos, redes de interacción proteína-proteína humana y validación a gran escala en bases de datos de pacientes, se identificaron 103 genes de riesgo para la EA [1,3,19]. Además, el enfoque predijo y validó, a nivel poblacional, tres medicamentos (pioglitazona, febuxostat y atenolol) que están significativamente asociados con un menor riesgo de EA. Se demostró que la pioglitazona, un agonista del receptor activado por proliferadores de peroxisomas (PPAR), está asociada con una disminución del riesgo de EA en estudios de validación retrospectiva y comparativa [20]. Experimentos in vitro respaldaron un posible mecanismo de acción, mostrando que la pioglitazona regulaba a la baja GSK3 $\beta$  y CDK5 en células de microglía humana. Este enfoque integrado demuestra una metodología eficaz para traducir rápidamente los hallazgos de GWAS y los datos multi-ómicos en el descubrimiento de terapias genotipo-informadas para la EA [21].

La revisión bibliográfica de Frizzell et al., (2022) destaca la necesidad de enfoques de IA avanzados para capturar los sutiles cambios cerebrales en la EA y el envejecimiento. Este estudio resalta el papel crucial de la IA en la clasificación de las fases de la EA y en la identificación temprana de deterioro cognitivo leve [4]. Un marco de aprendizaje automático (AA) logra una precisión del 98.88% y analiza simultáneamente cuatro fases de la EA en resonancias magnéticas estructurales. Los modelos también alcanzan un 99.7% de precisión mediante transferencia de aprendizaje. Esta metodología ofrece resultados rápidos y fiables, libres de los errores asociados con la fatiga y los sesgos cognitivos en el diagnóstico humano [22].

El objetivo de este estudio es desarrollar una aplicación móvil para clasificar las fases de la EA utilizando redes convolucionales aplicadas a imágenes de resonancia magnética cerebral, con el fin de aumentar la precisión y eficacia en la identificación de esta enfermedad neurodegenerativa. Los objetivos específicos son: 1) Investigar el estado del arte en el uso de

CNN para la clasificación de las fases de la EA, analizando técnicas y enfoques relevantes de otros investigadores; 2) Implementar una arquitectura óptima de CNN para la clasificación precisa de patrones asociados a la EA en imágenes cerebrales; 3) Evaluar la efectividad del modelo propuesto utilizando conjuntos de datos clínicos, analizando la precisión, sensibilidad y especificidad para la clasificación de las fases de la EA; 4) Desarrollar una aplicación móvil para la clasificación de las fases de la EA.

En el capítulo 1 de esta tesis, se describe un breve paradigma sobre la EA, destacando su impacto como un trastorno cerebral progresivo que afecta la memoria y las funciones cognitivas, especialmente en personas mayores de 65 años. Se proporciona una visión general de la relevancia global de la EA y se presenta el enfoque del estudio: la aplicación de CAD basada en IA, que utiliza datos de imágenes cerebrales para clasificar las fases de la EA.

En el capítulo 2, el marco teórico explora las bases conceptuales y teóricas que sustentan este estudio, adentrándose en la comprensión profunda de la EA, los enfoques tradicionales de diagnóstico, así como en la evolución y aplicación de la IA en el campo médico. Este capítulo sirve como un cimiento sólido para comprender la innovadora perspectiva que representa la implementación de CAD basada en IA en la clasificación de las fases de la EA.

En el capítulo 3, se presenta la metodología del estudio, que emplea un enfoque que combina diversas técnicas para explorar y analizar la relación entre variables en el contexto de una aplicación móvil para la clasificación de las fases de la EA. Inicialmente, se realiza un estudio exploratorio para familiarizarse con el tema, seguido de un estudio correlacional que busca determinar asociaciones entre variables sin establecer causalidad directa. El diseño de investigación se basa en un enfoque cuantitativo que utiliza técnicas estadísticas avanzadas para medir la eficiencia de los algoritmos de clasificación de imágenes. Esto incluye el uso de PCA, SVM con diferentes kernels y técnicas de preprocesamiento de datos.

La metodología emplea el modelo CRISP-DM, que guía el proceso desde la comprensión del negocio hasta la implementación del modelo. Se realiza un análisis exhaustivo de los datos a través de un conjunto de imágenes de IRM disponible en Kaggle, seguido de fases de preparación, modelado y evaluación, para finalmente implementar el modelo en una aplicación móvil. Las técnicas estadísticas, como la matriz de confusión, junto con métodos teóricos de evaluación y la metodología CRISP-DM, aseguran una evaluación rigurosa y una integración efectiva de los resultados en el sistema propuesto para la clasificación de las fases de la EA.

En el cuarto capítulo, titulado 'Resultados y Discusiones', se analizan los hallazgos obtenidos y se abre un diálogo reflexivo sobre la importancia y limitaciones de estos resultados. La discusión se extiende a interpretaciones críticas, comparaciones con la literatura existente y consideraciones para futuras investigaciones, lo que brinda una perspectiva completa y robusta de los descubrimientos alcanzados. En conjunto, estos cuatro capítulos proporcionan una narrativa coherente y enriquecedora sobre la contribución de la IA en la clasificación temprana de las fases de la EA.

### **i. Formulación del problema**

El diagnóstico temprano de la EA presenta múltiples desafíos debido a su complejidad, variabilidad en manifestaciones clínicas y la falta de herramientas tecnológicas accesibles. Esta investigación busca abordar estas limitaciones mediante el desarrollo de una aplicación móvil que permita clasificar las fases de la EA, optimizando así la intervención terapéutica y la planificación de cuidados personalizados. La pregunta central que guía este estudio es: ¿Cómo puede la tecnología mejorar la clasificación de las fases de la EA a través del análisis de imágenes de IRM?

### **ii. Objetivos**

#### **Objetivo general**

Desarrollar una aplicación móvil que facilite la clasificación de las fases de la EA mediante el uso de redes neuronales convolucionales (CNN) aplicadas a IRM, asegurando una precisión y eficacia significativas en la identificación de esta enfermedad neurodegenerativa.

#### **Objetivos específicos**

- Investigar el estado del arte en el uso de CNN para la clasificación de las fases de la EA, mediante técnicas, métodos y enfoques relevantes utilizados por otros investigadores.
- Implementar una arquitectura de CNN óptima que permita la clasificación precisa de patrones y características asociadas a las fases de la EA en IRM, mediante la comparación de algoritmos de máquinas de soporte de vectores y análisis de componentes principales.

- Evaluar el modelo propuesto basado en conjuntos de datos clínicos de imágenes cerebrales de pacientes con y sin Alzheimer, a través de la precisión, sensibilidad y especificidad del modelo para la clasificación de las fases de la EA.
- Desarrollar una aplicación móvil para la clasificación de las fases de la EA utilizando CNN aplicadas a IRM.

### **iii. Diseño Metodológico**

El diseño metodológico de esta investigación se centra en una población de pacientes diagnosticados con Alzheimer y en individuos sanos, lo que permitirá realizar comparaciones efectivas en la clasificación de las fases. Para lograr esto, se emplearán métodos de análisis de imágenes utilizando redes neuronales convolucionales (CNN) junto con herramientas de aprendizaje automático (AA). El estudio adoptará un enfoque cuantitativo, integrando tanto estudios exploratorios como correlacionales, y se considerará como una investigación aplicada que busca desarrollar soluciones tecnológicas para mejorar la clasificación de las fases de la EA.

### **iv. Delimitación del objeto y campo de estudio**

Esta investigación se centra en la clasificación de las fases de la EA a través del análisis de IRM. El principal desafío es identificar los signos iniciales de la enfermedad, que a menudo son sutiles y difíciles de clasificar con métodos convencionales. Identificar estos patrones tempranos resulta fundamental para implementar tratamientos y cuidados adecuados en una fase temprana, lo que puede marcar una gran diferencia en el manejo de la enfermedad.

El diseño metodológico de esta investigación se centra en una población de pacientes diagnosticados con Alzheimer y en individuos sanos, lo que permitirá realizar comparaciones efectivas en la clasificación de las fases. Para lograr esto, se emplearán métodos de análisis de imágenes utilizando CNN junto con herramientas de AA. El estudio adoptará un enfoque cuantitativo, integrando tanto estudios exploratorios como correlacionales, y se considerará como una investigación aplicada que busca desarrollar soluciones tecnológicas para mejorar la clasificación de las fases de la EA.

El campo de esta investigación abarca el desarrollo y la validación de una tecnología específica para la clasificación de las fases de la EA. Se diseña una aplicación móvil que utiliza CNN para

procesar y analizar IRM. Esta tecnología permite realizar un análisis detallado y automatizado de las imágenes, identificando patrones que podrían ser indicativos de la EA antes de que se vuelvan evidentes con técnicas tradicionales. La aplicación se enfoca en proporcionar una herramienta accesible y eficaz para los profesionales de la salud, limitando su alcance a la clasificación de las fases de la EA y no a otras formas de demencia o enfermedades neurodegenerativas. Esta decisión responde a la necesidad de una solución específica para una de las enfermedades neurodegenerativas más comunes y problemáticas, como es la EA.

Se plantea que el modelo basado en CNN clasifica las fases de la EA con una precisión superior al 90%. Esta hipótesis se fundamenta en la capacidad de las CNN para analizar grandes volúmenes de datos y detectar patrones complejos en las imágenes, lo cual es esencial para clasificar las fases de la EA. La alta precisión se respalda en el uso de un modelo avanzado entrenado con un conjunto extenso y representativo de IRM, tanto de pacientes con EA como de aquellos sin la enfermedad. Si el modelo alcanza esta precisión en la clasificación de las fases de la EA, permitirá a los profesionales de la salud intervenir de manera más efectiva y en una fase más temprana.

El diseño metodológico de esta investigación se centra en una población de pacientes diagnosticados con Alzheimer y en individuos sanos, lo que permitirá realizar comparaciones efectivas en la clasificación de las fases. Se emplearán métodos de análisis de imágenes utilizando CNN junto con herramientas de AA. El estudio adoptará un enfoque cuantitativo, integrando tanto estudios exploratorios como correlacionales, y se considerará como una investigación aplicada que busca desarrollar soluciones tecnológicas para mejorar la clasificación de las fases de la EA.

## CAPÍTULO 1

### 1. MARCO TEÓRICO

#### 1.1. ANTECEDENTES HISTÓRICOS

La historia de la enfermedad de Alzheimer (EA) se remonta a principios del siglo XX, cuando el médico alemán Alois Alzheimer describió por primera vez los síntomas que luego se asociarían con esta condición. En 1906, Alzheimer presentó un caso clínico notable de una mujer llamada Auguste Deter, cuyos síntomas incluían pérdida de memoria, desorientación, cambios de personalidad y dificultades para comunicarse. Tras su fallecimiento, realizó una autopsia en la que examinó el cerebro de Deter y descubrió anomalías como placas y ovillos neurofibrilares, marcando así el inicio del conocimiento de la enfermedad [1,18].

A lo largo del tiempo, la comprensión de la EA ha evolucionado significativamente, impulsada por investigaciones que han explorado sus bases genéticas y moleculares. En la década de 1970, se identificó la presencia de placas de beta-amiloide en los cerebros de pacientes diagnosticados con Alzheimer, lo que llevó a un mayor interés en el estudio de estas características patológicas. Posteriormente, en la década de 1980, se descubrieron mutaciones genéticas asociadas con la enfermedad, lo que sentó las bases para futuras investigaciones centradas en la genética y la neurobiología de la EA. [23,24].

En la última década, la atención se ha centrado en el uso de tecnologías avanzadas, como la IRM y la IA, para la clasificación de las fases de la EA y la mejor comprensión de la enfermedad. Los avances en la investigación genética, la identificación de biomarcadores y el desarrollo de técnicas de imagen han abierto nuevas posibilidades para la intervención temprana y el tratamiento personalizado. [25,26].

La EA es una patología neurodegenerativa caracterizada por la acumulación de placas de beta-amiloide y ovillos neurofibrilares en el cerebro. Estos cambios estructurales van acompañados de la pérdida de neuronas y conexiones sinápticas, lo que contribuye a la progresiva disfunción cognitiva observada en los pacientes con EA. La hipótesis amiloide, que postula que la acumulación de placas de beta-amiloide es el desencadenante primario de la enfermedad, ha sido central en la investigación, sugiriendo que abordar esta acumulación podría ser clave para desarrollar tratamientos efectivos. [27].

La aplicación de IA en la detección de enfermedades neurodegenerativas, incluida la EA, ha ganado relevancia en las últimas décadas. Los algoritmos de aprendizaje profundo, en particular las CNN, han demostrado ser eficaces en el análisis de imágenes médicas, como las obtenidas mediante IRM, mejorando así la precisión en el diagnóstico y permitiendo intervenciones más tempranas y efectivas. [28,29].

Investigaciones recientes han explorado la capacidad de la IA para identificar patrones y anomalías en las imágenes cerebrales, facilitando así la clasificación de las fases de la EA. La combinación de grandes conjuntos de datos de imágenes médicas y algoritmos de aprendizaje profundo ha permitido avances significativos en la precisión y eficiencia del diagnóstico. [30].

El uso de aplicaciones móviles en el ámbito de la salud ha experimentado un crecimiento exponencial. Estas aplicaciones ofrecen una variedad de servicios, desde el monitoreo de la actividad física hasta el seguimiento de condiciones médicas. En el contexto de la clasificación de las fases de la EA, las aplicaciones móviles pueden desempeñar un papel crucial al proporcionar herramientas accesibles y de fácil uso para el público en general.

Aplicaciones específicas para la detección de enfermedades neurodegenerativas, como la EA, han comenzado a emerger. La combinación de algoritmos de IA y la portabilidad de los dispositivos móviles ofrece la posibilidad de realizar evaluaciones rápidas y no invasivas, permitiendo una intervención temprana y una planificación de cuidados más efectiva.

## 2018

- Abajian et al. Análisis de datos clínicos y moleculares, modelos de regresión logística (LR) y bosque aleatorio (RF), validación cruzada.

## 2020

- Falcón. Revisión bibliográfica del uso de resonancia magnética y aprendizaje profundo para la detección temprana de AD.
- de la Fuente Garcia et al. Procesamiento de lenguaje natural y análisis de voz mediante pruebas TAVEC para la clasificación automática de pacientes.
- Battista et al. Metaanálisis de la aplicación de ML para la clasificación y medida neuropsicológicas.

## 2021

- El-Sappagh et al. Multicapa y multimodalidad en la detección mediante modelo de dos capas con bosque aleatorio (RF) como algoritmo clasificador.
- Fabrizio et al. Herramientas de diagnóstico asistido por computadora mediante el análisis de IA de grandes conjuntos de Big Data.
- Rojas et al. Análisis de imágenes de Tomografía por Emisión de Positrones (PET) y biomarcadores séricos mediante modelos de predicción ML.

## 2022

- Frizzell et al. Estudio de IA que utilizan imágenes de resonancia magnética para investigar el deterioro cognitivo y la demencia de AD mediante criterios PROBAST.
- Sudar et al. Aplicación de IA mediante método de propagación con técnicas de LRP, algoritmos VGG-16 y CNN.
- Silva-Spinola et al. Uso de IA para análisis de grandes cantidades de datos para comprender la dinámica paciente-enfermedad.

## 2023

- Winchester et al. Aplicación de IA en el descubrimiento de biomarcadores mediante aprendizaje ML.

**Figura 1. Análisis de cronológico de estudios previos de la aplicación de IA en Alzheimer.**

### 1.1.1. Trabajos previos

En el conjunto de investigaciones recopiladas, se evidencia una rica variedad de enfoques y técnicas utilizadas para abordar el desafío de la EA, fusionando la medicina con la IA. Cada estudio ha contribuido a la comprensión y tratamiento de la enfermedad desde distintas perspectivas, ofreciendo tanto técnicas convencionales como novedosas. Una descripción más

detallada de los estudios previos, autores y técnicas utilizadas se presenta en los anexos sobre el resumen de las investigaciones, técnicas y resultados existentes (Anexo 1).

Al analizar en conjunto los estudios seleccionados, se destaca la diversidad de enfoques y técnicas empleadas para abordar la EA desde distintas perspectivas. Los autores han explorado diversas facetas de la enfermedad, desde la clasificación de las fases de la EA hasta la predicción de su progresión y la personalización de tratamientos. Este amplio espectro de investigaciones subraya la complejidad de la EA y la necesidad de estrategias multifacéticas para comprender y combatir eficazmente esta enfermedad neurodegenerativa.

## **1.2. ANTECEDENTES CONCEPTUALES Y REFERENCIALES**

### **1.2.1. Variables del Estudio**

### **1.2.2. Hipótesis de la Investigación**

### **1.2.3. Fundamentación Teórica de la Variable Dependiente**

### **1.2.4. Enfoques Tecnológicos**

### **1.2.5. Clasificación de las fases de la EA**

### **1.2.6. Personalización de Tratamientos**

### **1.2.7. Biomarcadores y Predicción**

### **1.2.8. Aumento en la Predicción y Respuesta a Terapias**

El trabajo de Abajian et al [35] muestra cómo la IA puede mejorar la predicción de la respuesta a terapias. Este enfoque es crucial para adaptar tratamientos de manera más efectiva, maximizando así los beneficios para cada paciente.

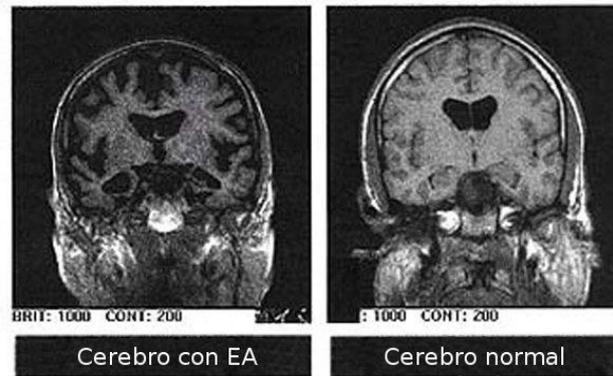
## **1.3. FUNDAMENTACIONES TEÓRICAS**

### **1.3.1. Enfermedad de Alzheimer**

#### **1.3.1.1. Anatomía Patológica**

La EA se presenta como una afectación multisistémica del sistema nervioso central, resultando en una atrofia cerebral generalizada [36]. Este trastorno provoca un deterioro progresivo y extenso del cerebro, que inicialmente afecta las áreas temporales internas y luego se extiende

al neocórtex, especialmente en regiones como las temporales, parietales y frontales [37]. Se observa atrofia en áreas como el cerebro basal y el mesencéfalo, donde se produce una notable pérdida de neuronas colinérgicas, particularmente en el núcleo de Meynert y el locus coeruleus. Esto conduce a una reducción en el sistema noradrenérgico y en los núcleos del rafe, resultando en una disminución de los niveles de serotonina. [36] [30].

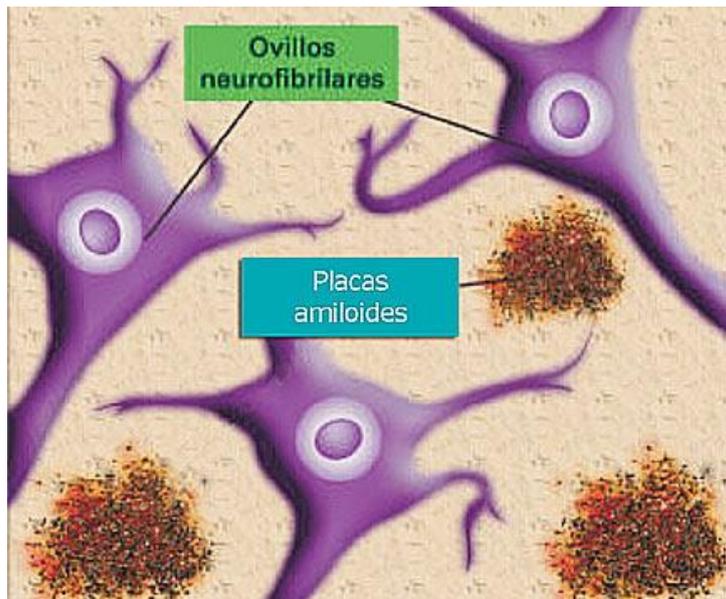


**Figura 2. Atrofia cerebral en la EA.**  
**Fuente: de la Fuente García et al [9].**

Como se ilustra en la Figura 2, los individuos con EA presentan una disminución en el grosor de las circunvoluciones y un aumento en la amplitud de los surcos cerebrales. Este fenómeno está asociado con una pérdida neuronal y sináptica, así como con la presencia de depósitos anómalos tanto intracelulares (ovillos neurofibrilares) como extracelulares (placas amiloides o seniles) en la corteza cerebral. [36] [38].

Las placas amiloides están formadas por residuos de dendritas y axones degenerados que se entrelazan con proteínas fibrilares o péptidos, siendo la proteína  $\beta$ -amiloide su componente principal [39]. Estas placas forman conglomerados densos, acompañados de neuritas distróficas que son positivas para  $\beta$ -APP (proteína precursora de  $\beta$ -amiloide). Por otro lado, los ovillos neurofibrilares consisten en agregados anormales de proteína Tau, una fosfoproteína insoluble en esta condición patológica, que interrumpe el transporte axonal y conduce a la muerte neuronal. [36].

La Figura 3 muestra las placas amiloides. Aunque algunas de estas alteraciones también se observan en el envejecimiento normal, su presencia e intensidad en la EA son considerablemente mayores. Esto permite identificar diferentes fases de la EA [36] [40].



**Figura 3. Placas amiloides.**

### **1.3.2. Causas o factores que originan la EA**

Aunque se ha especulado sobre una predisposición genética, no se ha demostrado completamente. Existen casos en los que varios miembros de una familia sufren de EA, aunque esto no implica necesariamente una herencia genética [41]. Alrededor del 15-35% de los afectados por EA tienen antecedentes familiares [36] [30]. Se han reportado casos de EA, especialmente aquellos que comienzan antes de los 65 años, que pueden atribuirse a un patrón hereditario dominante [42]. Estos casos están vinculados a mutaciones en genes específicos como A $\beta$ PP y PSEN1 [41,42]. El genotipo ApoE se ha asociado como un factor de riesgo para la EA: aquellos con el alelo ApoE4 tienen un riesgo del 10% en heterocigosis y del 33% en homocigosis, mientras que los portadores del alelo ApoE2 presentan un riesgo menor. Otros genes también se han relacionado con un aumento del riesgo, aunque de manera menos significativa.

La EA es el resultado de múltiples factores, que incluyen la predisposición genética, características individuales como la edad y factores ambientales [43]. En cuanto a la etiología de la EA, existen tres hipótesis principales:

**Hipótesis amiloide:** Se sugiere que el exceso y acumulación de la proteína  $\beta$ -amiloide, derivado de un aumento en su producción o una disfunción en su eliminación, puede desencadenar la EA. Esta acumulación está relacionada con la formación de ovillos neurofibrilares (ONF)

compuestos por proteína Tau [43].

Hipótesis de la proteína Tau: Se plantea que la EA comienza por la fosforilación de la proteína Tau, lo que afecta su capacidad de unirse a la tubulina y provoca la formación de ovillos neurofibrilares (ONF), generando efectos neurotóxicos que contribuyen a la progresión de la enfermedad.

Hipótesis colinérgica: Se sugiere que la reducción o falta del neurotransmisor acetilcolina interrumpe las conexiones neuronales, desencadenando así los síntomas asociados con la EA [43] [44]. Aunque las dos primeras hipótesis son ampliamente aceptadas, los resultados han sido contradictorios y aún no se ha determinado de manera definitiva la patogénesis de la EA. Esto se debe a los múltiples factores que influyen en la predisposición a la enfermedad, incluidos la predisposición genética, las características individuales como la edad y factores ambientales [45].

Las dos primeras hipótesis son ampliamente aceptadas; sin embargo, los resultados han mostrado contradicciones y aún no se ha determinado de manera definitiva la patogénesis de la EA. Es posible que la aparición de placas amiloides y ovillos neurofibrilares sea más una consecuencia del progreso de la enfermedad que un evento inicial que la desencadena [45,46].

Junto con los factores genéticos, se han identificado otros elementos de riesgo que contribuyen a la aparición y progresión acelerada de la EA [45,46]. Estos factores incluyen género, edad, tóxicos ambientales, aspectos nutricionales, sanitarios, socioeconómicos, culturales, cognitivos y epifenómenos. Por el contrario, valores opuestos de estos factores podrían ejercer un efecto protector.

### **1.3.3. Síntomas de la EA**

Los síntomas de la EA se caracterizan por la disminución de las funciones cognitivas y la manifestación de síntomas psicológicos no cognitivos, como depresión y psicosis [36]. Las disfunciones cognitivas típicas abarcan:

- Notables deficiencias en la memoria episódica, que afectan tanto la memoria reciente como la remota, atribuibles a una afectación temprana de las estructuras temporales mediales [36].
- Problemas en el lenguaje, que incluyen dificultades en la denominación y comprensión,

mientras que la repetición se mantiene hasta fases avanzadas.

- Diversos cambios motores, que van desde dispraxias hasta abulia.
- Deterioro en funciones ejecutivas, atención y memoria de trabajo.
- Disminución general en el funcionamiento personal y social.

La EA comienza de manera gradual y progresiva, desarrollándose en un período que abarca de siete a diez años [43]. Se divide comúnmente en fases de la EA: leve, moderada y grave. Además, se reconoce una fase preclínica silenciosa, donde hay evidencia de afectación cerebral marcada por placas amiloides y ovillos neurofibrilares, sin síntomas clínicos. La velocidad de progresión está influenciada por diversos factores de riesgo y protección [47].

**Fase leve:** Esta fase suele extenderse entre tres y cuatro años, durante los cuales comienzan a manifestarse los primeros síntomas de deterioro cognitivo, como la pérdida de memoria, dificultad para recordar nombres, problemas en la ejecución de movimientos (dispraxia) y en las funciones ejecutivas.

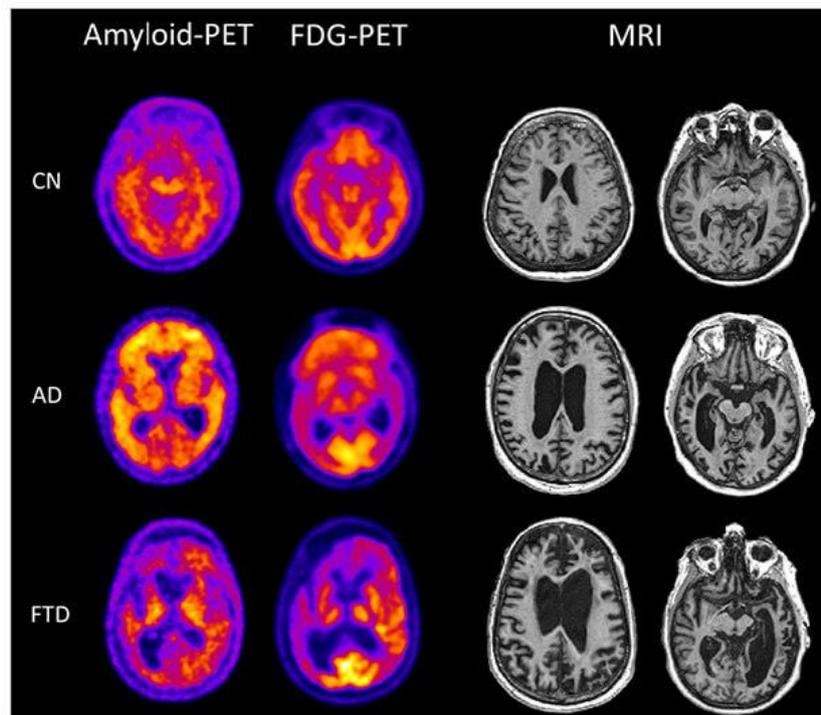
**Fase moderada:** Esta fase dura de dos a tres años, durante los cuales se presentan síntomas más evidentes, que pueden incluir manifestaciones psicóticas.

**Fase grave:** Esta fase generalmente abarca un lapso de dos a tres años y culmina con el fallecimiento del paciente, caracterizándose por una actividad cognitiva muy reducida, alteraciones conductuales y problemas físicos, como deshidratación y neumonía.

#### 1.3.4. Diagnóstico

Tradicionalmente, el proceso de diagnóstico de la EA inicia en la atención primaria cuando el individuo presenta signos de pérdida de memoria o cuando la familia identifica algún tipo de deterioro cognitivo. En nuestro país, el diagnóstico de la EA tiende a realizarse en etapas más avanzadas de la enfermedad, con una edad media de detección de 65 años. El diagnóstico inicial de la EA se fundamenta en criterios clínicos y de exclusión. En la consulta médica, se revisa la historia médica del paciente y se lleva a cabo un examen físico detallado. Se llevan a cabo pruebas adicionales para descartar otras posibles condiciones médicas. En la práctica de enfermería, se utiliza el Mini-Mental State Examination (MMSE) de Folstein como herramienta clave para evaluar el estado cognitivo del paciente [48]. Este examen se utiliza como una evaluación preliminar para detectar el declive cognitivo. El MMSE evalúa aspectos clave como la orientación temporal y espacial, la memoria inmediata y diferida, la atención, el

cálculo y el lenguaje. Sin embargo, según el informe de la Fundación del Cerebro [49], esta prueba podría no ser lo suficientemente sensible en las fases iniciales, lo que dificulta la clasificación de las fases de la EA [50]. Ha surgido como una alternativa al MMSE, ya que es sensible y requiere una duración igualmente breve. Ante la sospecha de demencia, se deriva al paciente a especialistas como neurólogos y neuropsicólogos para una evaluación más detallada. En España, el proceso más típico suele ser el siguiente Figura. 4



*Distinguishing AD and frontotemporal dementia (FTD) from cognitively normal (CN) with amyloid and FDG-PET imaging<sup>9</sup>*

**Figura 4. Detección y diagnóstico de EA [10].**

El proceso de diagnóstico más completo y específico implica realizar pruebas de neuroimagen, análisis de marcadores bioquímicos y evaluaciones neuropsicológicas diferenciales.

**Tratamiento con fármacos:** El tratamiento prescrito para la EA no cura la enfermedad ni tiene un impacto significativo en la supervivencia; más bien, ralentiza la progresión del deterioro y, por lo tanto, aumenta la calidad de vida de los pacientes [43]. Se recomienda un enfoque de tratamiento que incluya:

- **Inhibidores de la colinesterasa (IACE):** Estos fármacos actúan inhibiendo de manera reversible y competitiva la enzima colinesterasa, como el donepezilo y la galantamina.

La rivastigmina también actúa como inhibidor de la butirilcolinesterasa en el ámbito periférico. Su uso está respaldado para tratar la EA en las fases de demencia leves a moderadas, siendo menos efectivos en etapas avanzadas de la demencia o en casos de deterioro cognitivo leve (DCL) que puedan evolucionar hacia demencia [51].

- **Memantina:** Actúa como un antagonista no competitivo de los receptores de N-metil D-Aspartato (NMDA), reduciendo la neurotoxicidad asociada con este receptor mientras permite su activación, lo cual es esencial para funciones fisiológicas normales [41]. Su uso se recomienda en casos de EA moderada a grave, ya sea como tratamiento único o en combinación con un inhibidor de la colinesterasa.

Es importante tener en cuenta que estos medicamentos pueden ocasionar efectos secundarios gastrointestinales, como náuseas, diarrea o pérdida de apetito. La memantina, en particular, puede provocar cefaleas y confusión. Además, para abordar los trastornos psicológicos asociados con la EA, es común recetar antipsicóticos, ansiolíticos, neurolépticos o antidepresivos, adaptándose a las necesidades específicas de cada paciente. [41].

**Tratamiento sin fármacos:** Tratamiento sin fármacos: Las terapias no farmacológicas para pacientes pueden incluir psicoterapia, entrenamiento cognitivo y actividades diarias [42]. La rehabilitación neuropsicológica se considera una estrategia efectiva para mitigar las alteraciones cognitivas y conductuales tras una lesión cerebral. Estas terapias se agrupan bajo el término 'rehabilitación neuropsicológica' [42], buscando provocar cambios funcionales en pacientes con daño cerebral. Este enfoque aborda no solo el aspecto físico, sino también el psicosocial, involucrando al paciente, su familia y cuidadores.

La rehabilitación neuropsicológica abarca diversas intervenciones, como la rehabilitación cognitiva (que incluye estimulación cognitiva y entrenamiento en actividades diarias), modificaciones conductuales (como psicoterapia y técnicas de relajación), así como enfoques para la intervención familiar (modificación del entorno) y adaptación vocacional (terapia ocupacional). Su objetivo en casos de deterioro cognitivo, como la EA, es compensar las deficiencias para potenciar la participación del paciente en la vida diaria y mejorar su capacidad de adaptación [36]. Además, esta rehabilitación busca ralentizar el declive cognitivo [19] y retrasar la institucionalización del paciente en la medida de lo posible [10].

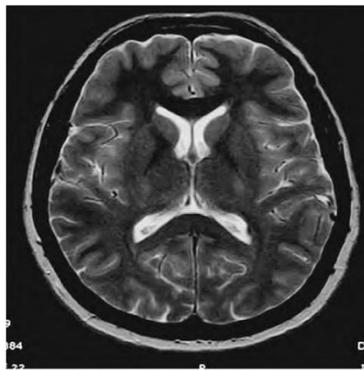
Además de las terapias no farmacológicas, como la rehabilitación neuropsicológica, se han explorado otros enfoques para la EA, incluyendo acupuntura, modificaciones dietéticas y

fisioterapia [43]. Es importante destacar que estas terapias no farmacológicas no deben sustituir el tratamiento con medicamentos; en cambio, se recomienda su uso conjunto para optimizar la atención del paciente [10].

**Fundamentos de la resonancia magnética cerebral:** La neuroimagen se ha convertido en una herramienta invaluable para estudiar la anatomía y función del sistema nervioso central (SNC), ya que permite la identificación de cambios estructurales y funcionales.

Las pruebas de neuroimagen, como la tomografía por emisión de positrones (PET), la tomografía por emisión de fotón único (SPECT), la tomografía computarizada (TC) y la resonancia magnética (RM), junto con las imágenes de resonancia magnética (IRM), proporcionan datos complementarios cruciales para diagnosticar y tratar trastornos del sistema nervioso central (SNC) [27].

La IRM se ha consolidado como una herramienta muy valiosa en el diagnóstico y la investigación médica. Su capacidad para ofrecer una excelente caracterización y distinción de los tejidos blandos en diversas partes del cuerpo la ha convertido en una técnica altamente apreciada en la medicina.



**Figura 5. Representación de la secuencia spin echo con realce en T2. Se observan áreas con alta señal correspondientes a estructuras con abundante contenido de agua, como el líquido cefalorraquídeo; los tejidos con presencia considerable de grasa se visualizan.**

Las alteraciones tanto en la estructura como en la función cerebral suelen ser graduales, especialmente en las fases de la EA, lo que dificulta su detección a través de la observación visual [42]. Los estudios de neuroimagen se han centrado en comparaciones estadísticas a nivel de grupo, proporcionando una perspectiva interesante sobre las áreas cerebrales afectadas por diversas enfermedades [43]. Sin embargo, estos hallazgos a nivel grupal no siempre tienen un

valor diagnóstico directo para pacientes individuales. Recientemente, los métodos basados en el reconocimiento de patrones han marcado un cambio significativo al permitir análisis multivariados y resultados predictivos más precisos, especialmente en el diagnóstico temprano de pacientes individuales [31].

El proceso de IRM se basa en el magnetismo generado por los núcleos atómicos, específicamente del hidrógeno, el cual, al estar sometido a un campo magnético y estimulado por radiofrecuencia, produce cambios en la orientación de sus átomos, generando una señal que puede ser medida para ofrecer información sobre los tejidos [45].

La RM involucra la orientación y movimiento de los protones en respuesta a pulsos de radiofrecuencia. Este proceso, que afecta la magnetización longitudinal y transversal, permite medir los tiempos de relajación (T1 y T2), los cuales influyen en la formación de la imagen y en la diferenciación de los tejidos [30].

A mayor intensidad del campo magnético, se incrementa la frecuencia de precesión ( $\omega$ ), que se puede calcular mediante la ecuación de LARMOR. Esta fórmula utiliza  $B_0$  para denotar la intensidad del campo magnético externo, medida en teslas (T), y  $\gamma$ , una constante de giro magnética específica para cada elemento (para el protón de hidrógeno, su valor es de 42,5 MHz/T) [52].

$$W \frac{Hz}{MHz} = \gamma B_0 [T] \quad \text{Ecuación (1)}$$

Esa afirmación sugiere que la frecuencia de precesión ( $\omega$ ) surge de multiplicar la constante de giro magnético ( $\gamma$ ) por la intensidad del campo magnético ( $B_0$ ). [53].

Por tanto, no todos los pulsos de radiofrecuencia influyen en el vector de magnetización longitudinal. Solo un pulso con una frecuencia de precesión precisa, según la ecuación de Larmor, puede inducir resonancia e interactuar con dicho vector.

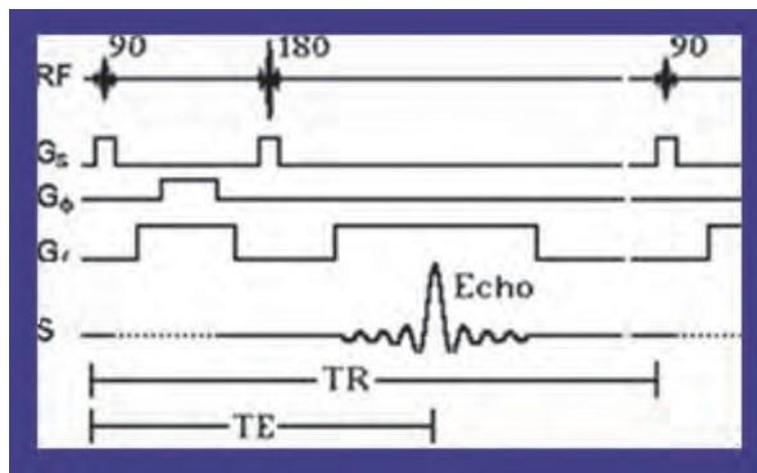
Las secuencias de RM, ajustadas mediante parámetros físicos, se diseñan para acentuar las diferencias entre los tejidos (ponderación) y se transforman en imágenes en computadoras mediante la transformada de Fourier. Estas imágenes se presentan en monitores como voxeles, que representan las dimensiones habituales (alto, ancho y profundidad). [54].

Las secuencias básicas de IRM incluyen Spin Echo (SE) y Gradient Echo (GE), que se utilizan

en estudios estructurales. Estas secuencias ofrecen diferentes resoluciones espaciales y tiempos de adquisición, lo que es necesario para identificar tejidos específicos y generar imágenes precisas [53].

### 1.3.5. Spin Echo (SE)

La secuencia Spin Echo es la más utilizada, también conocida como eco de espín. Involucra un pulso inicial de radiofrecuencia de 90 grados, seguido posteriormente por un pulso de 180 grados. Después de un tiempo equivalente al doble del lapso entre estos dos pulsos, se recibe una señal o eco originado en el tejido estimulado [55]. Se aplican sucesivamente múltiples secuencias de pulsos de 90 y 180 grados, y cada una de ellas genera un eco que contribuye a la señal de radiofrecuencia, proporcionando así detalles moleculares [56].



**Figura 6. Ilustración de la secuencia de eco de espín, que comprende un pulso inicial de 90 grados seguido por un pulso de 180 grados.**

### 1.3.6. Gradiente de Echo (GE)

Esta técnica busca obtener señales o ecos sin emplear pulsos de 180 grados después del pulso inicial de 90 grados. En lugar de ello, se invierte gradualmente la polaridad del campo magnético externo al tejido expuesto, utilizando un método denominado adquisición de ecos por inversión de gradientes. Esta secuencia tiene aplicaciones específicas en la detección de hemorragias y en la evaluación de la transformación hemorrágica de las lesiones [57].

En manos expertas, estas técnicas diagnósticas son herramientas altamente sensibles, no solo para la localización, sino también para determinar, en ocasiones, la causa subyacente de las

enfermedades [56]. Actualmente, demuestran una alta sensibilidad y especificidad para patologías específicas.

### **1.3.7. Visión Artificial**

La visión artificial se enfoca en capturar, procesar y extraer datos de imágenes. Este campo interdisciplinario emplea ideas y técnicas provenientes de diversas áreas científicas [58]. El procesamiento de imágenes utiliza métodos de procesamiento de señales para mejorar la calidad o modificar la imagen original, haciéndola más adecuada para extraer información. La etapa final, que consiste en la extracción de datos, corresponde al ámbito de la minería de datos [58]. Una vez adquirida la información de la imagen, su utilidad abarca diversos campos, que van desde guiar robots hasta permitir la exploración autónoma de áreas mediante sistemas inteligentes, e incluso facilitar la conducción autónoma de vehículos [58].

En términos de procesamiento e información extraída, la técnica más empleada en visión artificial es la convolución en dos dimensiones. Los datos extraídos se almacenan en vectores de características que funcionan como representaciones del objeto identificado. La intersección entre el procesamiento de imágenes, la minería de datos y el AA es crucial en este ámbito. [56].

### **1.3.8. Aprendizaje Automático**

El aprendizaje automático (AA) es una rama de la inteligencia artificial (IA) que permite a los sistemas aprender y mejorar a partir de la experiencia sin ser explícitamente programados. Existen varios tipos de AA que pueden aplicarse en la creación de aplicaciones móviles para el apoyo a pacientes con Alzheimer [59].

### **1.3.9. Aprendizaje Supervisado**

El aprendizaje supervisado utiliza datos etiquetados para entrenar modelos predictivos. Este enfoque, por lo general, implica proporcionar al algoritmo un conjunto de datos de entrenamiento que incluye tanto las entradas como las salidas esperadas. Su objetivo es que el modelo aprenda a mapear entradas a salidas para predecir resultados en datos nuevos y no vistos. [60].

En el contexto del Alzheimer, el aprendizaje supervisado puede emplearse de diversas formas, como en la predicción de la progresión de la enfermedad. Mediante la recopilación de datos

históricos sobre el estado cognitivo y físico de los pacientes, los modelos de aprendizaje supervisado pueden predecir la evolución de la enfermedad [61]. Un modelo puede utilizarse para analizar pruebas cognitivas, historiales médicos y datos de estilo de vida, con el fin de prever el deterioro cognitivo futuro. Esto permitirá a médicos y cuidadores planificar intervenciones adecuadas con antelación.

### **1.3.10. PCA (Análisis de Componentes Principales)**

Aunque no es un algoritmo de aprendizaje supervisado, el Análisis de Componentes Principales (PCA) se utiliza a menudo para la reducción de dimensionalidad. Este método ayuda a transformar un conjunto de datos de alta dimensionalidad en uno de menor dimensionalidad, manteniendo la mayor parte de la variabilidad presente en los datos [62]. Esto es útil para preprocesar los datos antes de aplicar algoritmos de aprendizaje supervisado, ya que reduce el ruido y aumenta la eficiencia computacional.

En el contexto del Alzheimer, PCA puede ayudar a manejar grandes volúmenes de datos de diversas fuentes, como imágenes cerebrales, resultados de pruebas cognitivas y datos genéticos [63]. Al reducir la dimensionalidad, PCA facilita la identificación de patrones importantes que podrían no ser evidentes en los datos originales de alta dimensionalidad.

Adicionalmente, se describen brevemente los modelos de Máquinas de Vectores de Soporte (SVM) utilizados en la comparativa del estudio [59,60,63,64] , destacando su eficacia en la clasificación de las fases de la EA y su rendimiento en comparación con otros algoritmos de aprendizaje automático.

### **1.3.11. SVM (Máquinas de Vectores de Soporte)**

#### **1.3.11.1. SVM con Kernel Lineal**

El SVM con kernel lineal es un tipo de SVM que utiliza un kernel lineal para separar los datos mediante una línea recta o un hiperplano en espacios de mayor dimensión. Este enfoque es especialmente útil para problemas en los que las fases de la EA son linealmente separables, permitiendo una clasificación efectiva de los diferentes grados de la enfermedad.

### **1.3.11.2. SVM con Kernel Polinomial**

El SVM con kernel polinomial utiliza una función de kernel que permite manejar problemas en los que la relación entre las características y las fases de la EA no es lineal. Este tipo de kernel permite al modelo aprender límites de decisión más complejos, facilitando así una clasificación más precisa en situaciones donde las etapas de la EA no se pueden separar de manera sencilla. Al emplear un kernel polinomial, el modelo puede capturar interacciones de alto orden entre las características, mejorando su capacidad para diferenciar entre diferentes fases de la enfermedad.

### **1.3.11.3. SVM con Kernel RBF (Función de Base Radial)**

El kernel RBF es uno de los más populares para abordar problemas no lineales. Este tipo de kernel transforma el espacio de entrada en uno de mayor dimensión, lo que permite que las fases de la EA se separen más fácilmente mediante un hiperplano en este nuevo espacio. Al utilizar la función de base radial, el modelo puede capturar relaciones complejas entre las características, lo que mejora significativamente su capacidad de clasificación en escenarios donde las divisiones no son lineales.

### **1.3.12. Aprendizaje No Supervisado**

El aprendizaje no supervisado se utiliza para descubrir patrones ocultos en datos no etiquetados. En lugar de aprender una función específica de entrada-salida, este tipo de aprendizaje intenta encontrar estructuras subyacentes en los datos. En el contexto del Alzheimer, se aplica en el análisis de grandes cantidades de datos de sensores y dispositivos móviles. Los algoritmos de aprendizaje no supervisado pueden detectar patrones de comportamiento que no son evidentes a simple vista [63,64]. Por ejemplo, identifican cambios sutiles en la movilidad diaria, patrones de sueño o el uso del teléfono móvil, que pueden indicar un deterioro cognitivo temprano. Además, estos algoritmos pueden agrupar a los pacientes en diferentes segmentos basándose en sus datos clínicos y de comportamiento, lo que permite identificar subgrupos de pacientes con necesidades y características similares. Esta información es útil para diseñar intervenciones más específicas y efectivas.

### **1.3.13. Aprendizaje por Refuerzo**

El aprendizaje por refuerzo es un tipo de aprendizaje automático en el que un agente aprende a tomar decisiones mediante la interacción con su entorno y la recepción de recompensas o castigos. Este enfoque se basa en la teoría del aprendizaje por ensayo y error y puede ser particularmente efectivo en entornos dinámicos y complejos. En el contexto del Alzheimer, el aprendizaje por refuerzo puede utilizarse para desarrollar sistemas que optimicen el comportamiento de los pacientes en función de su progreso y necesidades específicas, mejorando así la eficacia de las intervenciones personalizadas [60].

Los asistentes virtuales pueden ser entrenados mediante aprendizaje por refuerzo para interactuar con los pacientes y proporcionar apoyo continuo. Estos asistentes optimizan sus interacciones para mejorar la adherencia a los tratamientos, ofreciendo recordatorios oportunos y apoyo emocional. Además, pueden ajustar la frecuencia y tipo de recordatorios según la respuesta del paciente, aumentando así la efectividad de su ayuda. Los agentes de aprendizaje por refuerzo también pueden personalizar terapias cognitivas interactivas [59].

### **1.3.14. Redes Neuronales Convolucionales (CNN):**

La estructura de las CNN se asemeja a las redes neuronales artificiales de múltiples capas. Estas redes están compuestas por capas convolucionales, de agrupación, ReLu (Rectified Linear Units), completamente conectadas y de pérdida. Cada capa desempeña un papel específico en la extracción y procesamiento de características, contribuyendo a la clasificación final [65].

Los hiperparámetros asociados con la operación de convolución incluyen el tamaño del filtro, el paso, el relleno y otros. Su elección es crucial para el rendimiento de las CNN [66,67]. Además, utilizar convoluciones de  $1 \times 1 \times M$  al final de la red puede ser preferible a las capas completamente conectadas, ya que ofrece eficiencia en la implementación y flexibilidad en las dimensiones [68].

Además de su función original en el reconocimiento de imágenes, las CNN también tienen aplicaciones notables en el procesamiento del lenguaje natural y el aprendizaje automático [69,70].

### 1.3.15. Convolución

En teoría de señales, la convolución se aplica a dos señales continuas unidimensionales,  $f(t)$  y  $g(t)$ . Para entender su significado, es fundamental introducir el concepto de sistema lineal e invariante en el tiempo (LTI). Esta teoría proporciona herramientas para comprender cómo los sistemas físicos responden a estímulos de entrada específicos, lo que es relevante para el procesamiento de imágenes en el contexto de las CNN.

**Enunciado 1:** Un sistema  $S$  se considera lineal e invariante en el tiempo (LTI) si, al recibir un estímulo en la entrada y producir una señal de salida  $y(t)$ , cumple con las siguientes propiedades:

1. Linealidad:

$$S[\alpha x_1(t) + \beta x_2(t)] = \alpha y(x_1(t)) + \beta y(x_2(t)), \alpha, \beta \in \mathbb{R} \quad \text{Ecuación (2)}$$

2. Tiempo de invarianza:

$$S[x(t + t_0)] = y(t + t_0) \quad \text{Ecuación (3)}$$

El comportamiento de un sistema LTI se puede estudiar mediante su respuesta a la función Delta de Dirac  $\delta(t)$ . Esta función es nula en todos los puntos de su dominio, excepto en el punto cero, donde su valor es infinitamente alto, permitiendo así que se considere como un impulso unitario que activa el sistema:

$$\int_{-\infty}^{\infty} \delta(t) \phi(t) dt = \phi(0) \quad \text{Ecuación (4)}$$

De manera intuitiva, al aplicar  $\delta(t)$  a una función  $\phi(t)$ , esto equivale a evaluar el valor de  $\phi(t)$  en  $t = 0$ . Al introducir  $\delta(t)$  como entrada del sistema  $S$ , obtenemos la reacción del sistema ante un impulso unitario centrado en el origen.

**Enunciado 2:** La respuesta impulsiva de un sistema se manifiesta al representar la función Delta de Dirac como entrada del sistema.

$$h(t) = [S[\delta(t)]] \quad \text{Ecuación (5)}$$

La importancia de la respuesta impulsiva radica en su capacidad para calcular la respuesta de

un sistema LTI ante cualquier entrada. Cualquier señal genérica  $x(t)$  puede representarse mediante un desplazamiento de  $\delta(t)$  a cualquier punto dentro del dominio de  $x(t)$ .

$$x(t) = \int_{-\infty}^{\infty} x(t)\delta(t - T)dT = x(t) * \delta(t) \quad \text{Ecuación (6)}$$

La función de convolución entre dos señales (indicada por el símbolo  $*$ ) es donde  $\delta(t)$  asume un papel neutral en esta operación. Al explorar la convolución, podemos entender su relevancia en el análisis de señales. En este contexto,  $x(t)$  representa una señal de entrada genérica, mientras que  $h(t)$  simboliza la respuesta impulsiva del sistema S, la convolución produce el siguiente resultado:

$$y(t) \stackrel{\text{def}}{=} x(t) * \delta * (t) = (x * h)(t) = \int_{-\infty}^{\infty} x(t)\delta(t - T)dT \quad \text{Ecuación (5)}$$

El resultado de esta convolución revela cómo la respuesta impulsiva  $h(t)$  del sistema LTI modela su acción ante la señal de entrada  $x(t)$ . Este desenlace es crítico, ya que demuestra que la respuesta impulsiva describe en su totalidad las características del sistema.

La convolución discreta unidimensional también tiene una definición. Si  $g(n)$  y  $x(n)$  están definidos en el conjunto de números enteros  $Z$ , su convolución se puede calcular de la siguiente manera:

$$(x * g)[n] \stackrel{\text{def}}{=} \sum_{m=-\infty}^{\infty} x[m]g[n - m] \quad \text{Ecuación (7)}$$

La extrapolación hacia el caso bidimensional resulta natural, especialmente en el campo de la visión por computadora, donde la convolución se aplica entre señales discretas en dos dimensiones. Las versiones discretas de la función Delta de Dirac y de la función Delta de Kronecker pueden describirse sin depender de la dimensión espacial que se maneje.

$$\delta_{i,j} \stackrel{\text{def}}{=} \begin{cases} 1 & \text{Si } i = j \\ 0 & \text{Si } i \neq j \end{cases} \quad \text{Ecuación (8)}$$

En el contexto bidimensional, el enfoque para los sistemas LTI se generaliza y se refiere a los sistemas LSI.

**Enunciado 3:** El término 'filtro', 'núcleo' o 'matriz de convolución' se establece como la respuesta de un sistema discreto LSI. Este filtro tiene un tamaño de  $2k \times 2k$ , donde  $k$  representa un valor que determina la extensión de la respuesta en la muestra por impulso. Si tomamos  $h[n]$

como un filtro con dimensiones  $2k \times 2k$  e  $I$  como una imagen bidimensional en escala de grises, cada punto con coordenadas  $(i, j)$  recibe una señal resultante de la convolución entre  $h$  e  $I$ :

$$O(i, j) = \sum_{u=-k}^k \sum_{v=-k}^k h(u, v)I(i - u, j - v) \quad \text{Ecuación (9)}$$

En términos intuitivos, una convolución bidimensional implica aplicar un filtro de dimensiones  $(2k + 1) \times (2k + 1)$  sobre la imagen  $I$ . Esta operación se realiza para cada píxel en el centro de la imagen, calculando la operación indicada en la ecuación anterior. Al describir la convolución en cada dirección  $w$  y  $h$ , se pueden establecer algunos parámetros:

**Paso  $S_{w,h}$ :** Esta medida, expresada en píxeles, representa la separación entre aplicaciones consecutivas del filtro (en la dirección correspondiente) durante la convolución. Intuitivamente, es la distancia desde el punto central de la imagen que se está filtrando al moverse desde la posición  $(i, j)$  a la posición  $I_{i+S,j}$  (o  $I_{i,j+S}$  dependiendo de la dirección del movimiento en la imagen).

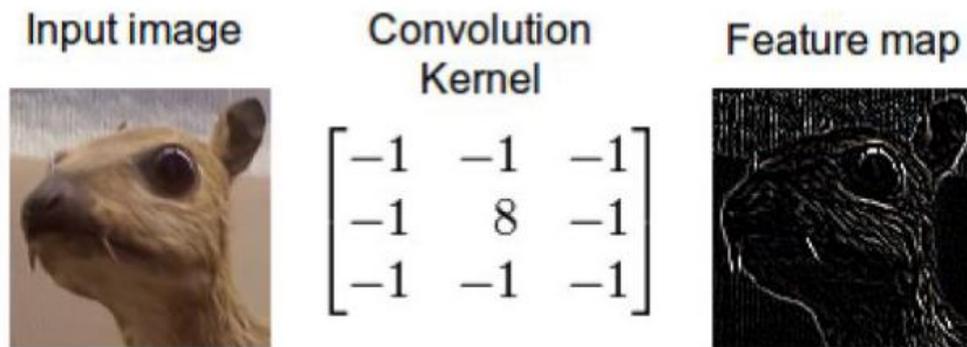
**Relleno cero  $P_{w,h}$ :** Indica la cantidad de ceros que se añaden al borde del resultado de la convolución.

Si asumimos que  $S = S_h = S_w$ ,  $P = P_h = P_w$ , e  $I = I_h = I_w$ , las dimensiones de la imagen filtrada serán:

$$O_w = O_h = \frac{I_s - k + 2P}{S} + 1 \quad \text{Ecuación (10)}$$

El producto será un número entero si el paso se selecciona correctamente para ser compatible con las dimensiones de la imagen de entrada.

En visión artificial, una práctica convencional es la creación manual de filtros para mejorar la calidad de las imágenes o extraer sus características distintivas. Algunos ejemplos notables incluyen el filtro Gaussiano, que reduce el ruido, y el filtro Sobel, utilizado para detectar bordes en la imagen. La imagen siguiente muestra el resultado obtenido al aplicar la convolución de una imagen con un núcleo diseñado para la detección de bordes.

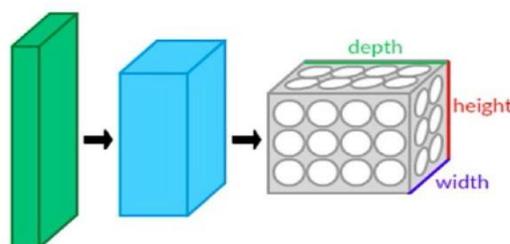


**Figura 7. Ejemplo de convolución con un kernel para la extracción de características en imágenes.**

Extraer características de una imagen es crucial para capacitar a las máquinas en la percepción visual. Esta extracción permite analizar el contenido de la imagen y proporciona a la máquina la capacidad de comprender y clasificar objetos, en lugar de simplemente tratar la imagen como un conjunto de valores organizados en una matriz. Antes de profundizar en los matices de los filtros de convolución, es importante ampliar la definición de convolución para incluir imágenes en múltiples dimensiones.

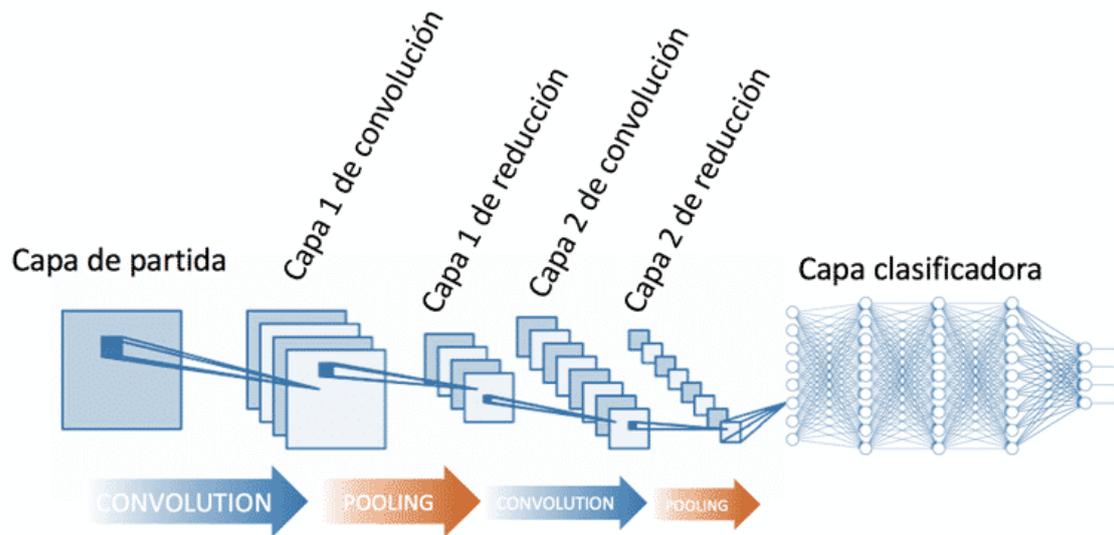
### 1.3.16. Estructura de CNN

Las redes neuronales convolucionales (CNN) se asemejan a esquemas de redes neuronales artificiales de múltiples capas, y están inspiradas en la organización de la corteza visual de los animales. La interpretación visual de este modelo se ilustra en la siguiente figura. [58].



**Figura 8. Estructura de una CNN.**

Cada bloque representa una capa distinta de la CNN, las cuales tienen dimensiones en altura, ancho y profundidad. De izquierda a derecha, se aprecian primero las capas de entrada, seguidas por las capas ocultas, que incluyen las capas convolucionales, de agrupación y de abandono. Finalmente, en la última capa, el modelo produce una clasificación. [70].



**Figura 9. Arquitectura de una red neuronal convolucional.**

Las capas completamente conectadas establecen conexiones locales entre neuronas y las capas adyacentes [67]. Las entradas de estas capas provienen de un subgrupo de neuronas de la capa anterior, asegurando que puedan proporcionar la respuesta óptima. Además, las unidades comparten el mismo peso y sesgo en el mapa de activación, lo que implica que todas las neuronas dentro de una capa específica analizan la misma característica [69].

### 1.3.17. Componentes de la Estructura de la CNN

**Capa convolucional:** En las CNN, un componente crucial es el uso de filtros entrenables que se desplazan sobre la entrada para generar mapas de activación bidimensionales. Cada filtro tiene como objetivo identificar características específicas en regiones particulares de la entrada [66]. Estos mapas se combinan para formar el volumen de salida de la capa convolucional, donde cada elemento representa el resultado de una neurona especializada en una región pequeña de la entrada y comparte parámetros con otras neuronas en el mismo mapa de características. Esta capa es esencial para reconocer patrones en imágenes, como la distinción de dígitos en un fondo específico [66,67].

La convolución en una CNN implica aplicar un filtro a diferentes partes de una imagen, creando un mapa resultante a través de la combinación de pesos, sesgos y valores de píxeles, utilizando una función no lineal [69]. Estos mapas se apilan en la capa convolucional y luego se introducen en la capa de agrupación. El tamaño del resultado se determina por las dimensiones

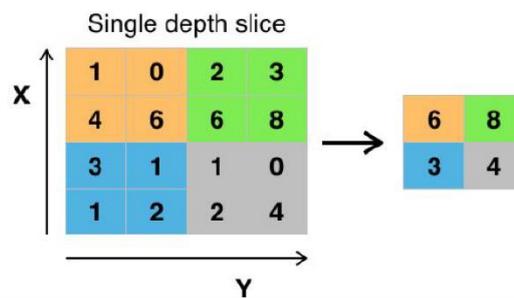
espaciales de los mapas resultantes [70].

La capa de agrupación, ubicada comúnmente entre capas convolucionales sucesivas, simplifica los mapas de características obtenidos de la convolución. Esta reducción dimensional ayuda a mitigar la complejidad del modelo y prevenir el sobreajuste. En esencia, la capa de agrupación simplifica la información de salida de la capa convolucional [58,65].

La operación de agrupación, conocida como 'pooling', reduce los parámetros de la red y se puede conceptualizar como una forma de convolución conjunta de volúmenes. Al tomar un volumen  $I = (W_I; H_I; D)$ , la agrupación genera un volumen  $O = (W_O; H_O; D)$  mediante el desplazamiento de un filtro  $2k \times 2k$ . Este filtro no se entrena; en su lugar, define el campo receptivo de la operación.

En líneas generales, en un volumen cualquiera  $I = (W, H, D) = \{I_1, \dots, I_D\}$ , la operación de agrupación se interpreta como la convolución de  $I$  con un conjunto de  $D$  filtros  $D_i$  iguales. Estos filtros son una muestra de la respuesta al impulso de la función  $f$ , lo que permite reducir la cantidad de parámetros.

El procedimiento se ejecuta en cada píxel del volumen de entrada, deslizando el filtro con un paso  $S$  y completando el resultado con  $P$  ceros. La representación gráfica del resultado de esta operación de agrupación, utilizando la función  $f = \max$  se muestra en la siguiente figura.



**Figura 10. Max-pooling.**

La acción de agrupación, en términos sencillos, consiste en seleccionar regiones de tamaño  $2 \times 2$  y aplicar una función  $f$  a este conjunto de píxeles, del cual se extrae un único valor. Este proceso se repite en la región seleccionada, desplazándose  $S$  píxeles a lo largo del mapa, manteniendo la profundidad del volumen de entrada. Los parámetros típicos incluyen un filtro de tamaño  $2 \times 2$ , un paso igual al tamaño del filtro ( $S = 2$ ) y una función  $f$  que selecciona el valor máximo

entre los píxeles del conjunto [67,68]. Esta técnica reduce significativamente la cantidad de parámetros de entrada en un 75%, facilitando el entrenamiento de las capas subsiguientes con menos información [65,67]. El tipo de agrupación que utiliza la función  $f = \max$  se conoce como max-pooling y ha demostrado ser efectivo en la práctica. Aunque esta función es la más común, es posible explorar diferentes funciones para la fase de agrupación [67].

Las capas ReLu (Unidades Lineales Rectificadas) son frecuentes en las CNN y se emplean a menudo después de cada capa convolucional para agregar no linealidad a la función de activación, preservando los campos receptivos de las capas convolucionales [65]. La función más utilizada en estas capas es  $f(x) = \max(0, x)$ . Existen otras opciones, como  $f(x) = \tanh(x)$ ,  $f(x) = |\tanh(x)|$  o la sigmoide  $f(x) = 1/(1+e^{(-x)})$ . Se pueden usar diferentes funciones en capas distintas dentro de la misma red. [71]. La función  $f(x) = \tanh(x)$  permite un entrenamiento más rápido con un rendimiento similar al de las capas ReLu. Estas capas no tienen parámetros ajustables ni requieren configuración adicional, lo que facilita la retropropagación de errores [72].

La capa completamente conectada en una CNN es análoga a las capas tradicionales en una red neuronal estándar, donde todas las neuronas están conectadas a todas las de la capa anterior [72]. A diferencia de las capas convolucionales, que tienen conectividad local, esta capa se conecta con todo el volumen de entrada, generando un gran número de conexiones individuales [65]. El parámetro ajustable en esta capa es la cantidad de neuronas que la componen. Estas neuronas se conectan con todos los volúmenes de entrada, y su salida es un vector único que contiene las activaciones calculadas [65]. Estas capas se utilizan para agrupar y procesar la información acumulada hasta ese momento, proporcionando datos para la clasificación final en redes neuronales convolucionales. Se emplean múltiples capas completamente conectadas en serie, siendo la última la encargada de clasificar los resultados en las fases de la EA presentes en los datos [63, 68]. Los valores resultantes se envían a la capa de salida para realizar la clasificación mediante una función probabilística. Además de configurar el número de neuronas, existen otros parámetros ajustables como los pesos y el sesgo. Aunque no siempre es necesario establecer valores específicos, se pueden utilizar valores predeterminados [65,72].

La capa de pérdida es la fase en la que se evalúan las predicciones en comparación con los valores reales de las imágenes. Para la clasificación entre K clases de la EA, se utiliza comúnmente el clasificador de pérdida softmax. En el caso de la regresión con etiquetas de imagen, es habitual emplear la función euclidiana. A continuación, se describen estas

funciones:

### Softmax

$$\sigma(Z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{Ecuación (11)}$$

$$Z_j = \sum_{k=0}^d W_{ikXk} \quad \text{Ecuación (12)}$$

donde:

- $z_{\{j\}}$  es un vector de probabilidades a posteriori.
- $j$  representa la  $i$ -ésima neurona de la capa de salida, es decir, de la capa de pérdida.
- $K$  representa el número total de neuronas de la capa de pérdida.
- $W_{\{k\}}$  son los pesos.
- $x_{\{i\}}$  son los valores de entrada que recibe la capa de pérdida.
- $\sigma(z)_{\{j\}}$  es la activación de las  $K$  neuronas de la capa de pérdida.

### Euclídea

$$E = \frac{1}{2K} \sum_{i=0}^k \|Y_i - \hat{Y}_i\|_2^2 \quad \text{Ecuación (13)}$$

donde:

- $K$  representa el número total de neuronas de la capa de pérdida.
- $\hat{y}$ ; representa las predicciones de las imágenes.
- $y$ ; representa los valores reales de las imágenes.

### 1.3.18. Hiperparámetros

La sección anterior ha introducido los conceptos fundamentales de las CNN, cada uno definido por uno o varios grados de libertad: los hiperparámetros. La selección de valores para estos hiperparámetros sigue un proceso guiado por la intuición y carece de bases matemáticas sólidas. La tabla siguiente detalla todos los hiperparámetros asociados con la operación de convolución entre volúmenes. Es crucial notar que incluso la elección del algoritmo de optimización constituye, en sí mismo, un hiperparámetro:

<b>Ecuación</b>	<b>Descripción</b>
$F_d$	Número de filtros que forman la red convolucional. Cada filtro es responsable de detectar características específicas en la entrada.
$2k \times 2k$	Área del filtro de convolución/pooling, que determina cuántos píxeles se evalúan en cada operación de convolución o pooling.
$S$	Paso de la operación de convolución/pooling, que indica la distancia entre las posiciones del filtro al moverse sobre la imagen.
$p$	Número de ceros de relleno para la salida de la convolución/pooling, que permite mantener las dimensiones de la imagen original.
<i>Learning Rate</i>	Tasa de aprendizaje, que determina la magnitud del ajuste que se realiza en los pesos del modelo durante el entrenamiento.
<i>Epochs</i>	Número total de veces que el algoritmo pasará por todo el conjunto de datos de entrenamiento.
<i>Batch Size</i>	Número de muestras que se procesan antes de actualizar los parámetros del modelo.

**Tabla 1 Hiperparámetros para convoluciones.**

Además de los hiperparámetros mencionados anteriormente, cada arquitectura de red neuronal cuenta con múltiples grados de libertad adicionales. Muchos de estos aspectos, que se enumeran a continuación, son temas de investigación abiertos. Las decisiones relacionadas con estos hiperparámetros pueden tener un impacto significativo en el rendimiento general de las redes [73].

- Escalado de entrada: Las imágenes deben ser ajustadas antes de ser procesadas por la red neuronal.
- Capas de convolución: Múltiples capas pueden combinar las características extraídas de la capa anterior para formar nuevas y más complejas.
- Operación de agrupación: Aunque es opcional, realizar una agrupación después de cada capa puede ajustar la cantidad de características.
- Función de agrupación: Si se aplica, puede ser de tipo máximo u otro; su elección puede variar entre las capas de agrupación.
- Tamaño del filtro: Cada capa puede utilizar filtros con diferentes campos receptivos.
- Capa totalmente conectada: Las últimas etapas de la red incluyen capas que combinan las características extraídas. La cantidad de estas capas y el número de neuronas en ellas

son arbitrarios.

- Función de pérdida: Su elección es crucial, ya que influye en cómo la red aprende y en las conexiones entre las neuronas.
- No linealidad: Se elige una función no lineal para activar las neuronas, y esta elección puede variar entre las capas de convolución y las capas completamente conectadas.
- Topología: Las características extraídas pueden combinarse con la entrada original o entre diferentes capas; no es necesaria su combinación inmediata tras una capa de convolución.

### **1.3.19. Convoluciones (1:1)**

En las redes neuronales, se suele aceptar que las capas finales se compongan de capas completamente conectadas, especialmente en tareas de clasificación. Sin embargo, es posible sustituir estas capas por capas convolucionales que tengan volúmenes de dimensiones  $1 \times 1 \times F_d$  (para el aprendizaje). Este enfoque logra resultados equivalentes a una capa completamente conectada sin restringir las dimensiones de entrada.

Tomemos, por ejemplo, la estructura de LeNet-5: su capa completamente conectada combina 16 características obtenidas a partir de filtros de  $5 \times 5$  con 120 neuronas. Este procedimiento implica extraer 120 funciones de un volumen de  $5 \times 5 \times 16$  mediante la convolución entre volúmenes, lo que reduce las dimensiones a (1, 1, 120).

Este resultado, un tensor tridimensional, puede ser manejado eliminando las dimensiones unitarias y considerando las propiedades extraídas como un vector unidimensional de 120 características. Este vector se puede utilizar en una capa completamente conectada mediante el producto matricial con una matriz de pesos. [74].

Como alternativa, al considerar el volumen en su totalidad sin descartar las dimensiones unitarias, se puede establecer una conexión completa entre los valores de entrada y las neuronas de capas posteriores mediante convoluciones entre volúmenes. [75]. Si definimos un volumen de entrada  $I = (1; 1; N)$ , podemos emplear una capa de convolución con dimensiones  $1 \times 1 \times M$  (donde  $M$  representa la cantidad de filtros individuales utilizados para el aprendizaje) y realizar la operación de convolución.

La convolución entre volúmenes implica que los filtros de dimensión unitaria se aplican a cada nivel del volumen de entrada de forma individual, y los resultados se suman. Al utilizar filtros

de dimensión unitaria, la operación de convolución se convierte, en esencia, en una capa completamente conectada que emplea únicamente convoluciones [75].

Existen razones para preferir las convoluciones de dimensiones  $1 \times 1 \times M$  sobre las capas completamente conectadas al final de una CNN.

1. Los marcos de aprendizaje automático en visión artificial están optimizados para realizar convoluciones, ya que son operaciones comunes, a diferencia de otras menos frecuentes, como los productos matriciales.
2. Las convoluciones  $1 \times 1$  permiten que la red trabaje con imágenes de diferentes tamaños durante la fase de prueba, ya que pueden desplazarse a lo largo de cada dimensión del volumen. Esto contrasta con las capas completamente conectadas, que producen salidas unidimensionales.

Se ha demostrado que el aprendizaje automático combina múltiples características complejas. Para lograr esto, se utilizan capas convolutivas en cascada que fusionan las propiedades extraídas [74]. El aumento en la cantidad de estas capas ha dado origen al aprendizaje profundo (Deep Learning), que se centra en crear modelos capaces de abstraer información a través de múltiples niveles. Cada capa se considera un nivel de abstracción que el algoritmo debe aprender durante el entrenamiento [76].

#### **1.4. Antecedentes contextuales**

La aplicación de IA en el ámbito médico, especialmente en la clasificación de enfermedades como la EA, ha experimentado un notable auge en las últimas décadas. Este interés se ha visto impulsado por el acceso a grandes volúmenes de datos médicos y los avances en algoritmos de ML, lo que ha permitido explorar soluciones innovadoras para el diagnóstico precoz y la clasificación de condiciones neurodegenerativas.

Para la automatización del análisis de imágenes en la clasificación de la EA, se emplean varias disciplinas y técnicas avanzadas que incluyen procesamiento de señales, análisis de imágenes médicas y la bioinformática. Una de las técnicas más destacadas es el uso de redes neuronales convolucionales (CNN), que facilitan la extracción automática de características relevantes en imágenes de IRM, permitiendo identificar patrones complejos en las imágenes que resultan cruciales para distinguir las distintas fases de la EA. Asimismo, los algoritmos de segmentación

de imágenes, utilizados para delimitar con precisión las áreas afectadas en el cerebro, complementan este enfoque al proporcionar un análisis más detallado de la patología.

Además, se implementan técnicas de preprocesamiento de imágenes para optimizar los datos antes de su análisis. Entre estas técnicas se incluyen la reducción de ruido y la normalización de las imágenes, lo cual mejora la calidad del análisis automatizado. También se aplican enfoques de aprendizaje no supervisado para detectar patrones ocultos en los datos que pueden ser indicativos de la progresión de la enfermedad. La combinación de estas técnicas proporciona un enfoque integral para el análisis de imágenes en la EA, facilitando intervenciones tempranas y mejorando la precisión del diagnóstico.

Para optimizar el análisis automatizado de imágenes en la detección temprana de la EA, se emplean técnicas como el realce de contraste y la segmentación de regiones específicas en las imágenes de IRM. Estas técnicas permiten identificar con mayor precisión las áreas potencialmente afectadas, lo cual, junto con la capacidad de los algoritmos de aprendizaje automático para manejar grandes volúmenes de datos, facilita el análisis de patrones sutiles y mejora la detección temprana de la enfermedad, promoviendo intervenciones más oportunas.

En la obra seminal de Lee [33], se destaca la relevancia de incorporar tecnologías de vanguardia, como la IA, en la práctica médica para aumentar la precisión y eficiencia en el diagnóstico de enfermedades cerebrales. La capacidad intrínseca de los algoritmos de IA para identificar patrones sutiles en datos biomédicos complejos ha propiciado avances significativos en la identificación temprana de la EA, hallan el camino para intervenciones más efectivas.

Asimismo, la integración de la IA en el ámbito médico plantea interrogantes éticas y regulatorias cruciales [32]. La comunidad científica y los profesionales de la salud reflexionan sobre cómo equilibrar los beneficios potenciales de las tecnologías de IA con consideraciones éticas, la salvaguarda de la privacidad del paciente y la necesidad de validar estrictamente los modelos propuestos.

La EA representa un desafío significativo a nivel global, especialmente dada su alta prevalencia en individuos mayores de 65 años y el impacto tanto en los afectados como en los sistemas de salud pública y privada [4]. La clasificación de las fases de la EA es esencial para una intervención efectiva, pero los métodos actuales son costosos y requieren la experiencia de especialistas. En este contexto, la inteligencia artificial (IA) ofrece una solución prometedora

al integrar tecnologías avanzadas de análisis de imágenes, como la resonancia magnética (IRM), con algoritmos de aprendizaje profundo [1][2].

Desde una perspectiva estadística, la EA afecta a aproximadamente el 10% de las personas mayores de 65 años a nivel mundial [4]. En Ecuador, el impacto de la EA es particularmente significativo, debido a la carga que representa para los sistemas de salud y el bienestar de las personas afectadas. La implementación de técnicas avanzadas de diagnóstico puede aliviar parte de esta carga al ofrecer métodos más accesibles y eficaces. La combinación de grandes volúmenes de datos médicos con algoritmos de aprendizaje automático (ML) ha demostrado ser efectiva para aumentar la precisión en la identificación temprana de la enfermedad [3].

La recolección de datos en el diagnóstico de la EA incluye imágenes de IRM cerebral y datos clínicos detallados. Los enfoques actuales de aprendizaje automático (ML) permiten analizar estos datos complejos, revelando patrones sutiles que los métodos tradicionales podrían pasar por alto [3]. Plataformas como Kaggle ofrecen conjuntos de datos amplios que son fundamentales para el entrenamiento y validación de modelos de IA, facilitando así el desarrollo de herramientas de diagnóstico asistido por computadora (CAD) [8].

Desde el punto de vista empresarial e institucional, la adopción de IA en el diagnóstico de la EA tiene implicaciones profundas. La integración de sistemas de diagnóstico asistido por computadora (CAD) basados en IA en hospitales y clínicas puede optimizar los recursos, aumentar la eficiencia operativa y reducir los costos asociados con el diagnóstico y tratamiento [6]. Esta tecnología no solo fortalece las capacidades diagnósticas del personal médico, sino que también ofrece una herramienta avanzada para la clasificación de las fases de la EA, con potenciales beneficios económicos y operativos para las instituciones de salud [4].

La justificación del problema se apoya en la falta de herramientas diagnósticas accesibles y eficaces para la clasificación de las fases de la EA. La IA ofrece una solución mediante el análisis automatizado de imágenes de IRM, lo que permite una identificación más precisa de patrones indicativos de la enfermedad [12]. Estudios recientes han demostrado que el uso de redes neuronales convolucionales (CNN) puede alcanzar una precisión superior al 90% en la clasificación de las fases de la EA, lo que proporciona una base sólida para la implementación de aplicaciones móviles basadas en IA [14][22]. Esta evidencia empírica respalda la necesidad de desarrollar herramientas tecnológicas avanzadas para mejorar el diagnóstico y tratamiento de la EA.

La solución propuesta consiste en el desarrollo de una aplicación móvil que emplea redes neuronales convolucionales para analizar imágenes de IRM cerebral. Esta aplicación está diseñada para detectar signos tempranos de la EA con alta precisión, superando así las limitaciones de los métodos diagnósticos convencionales. Al automatizar el análisis de imágenes, la herramienta promete una detección más rápida y precisa, facilita intervenciones tempranas y mejora la gestión clínica de la enfermedad [8][12][14].

En este contexto, es esencial situar la investigación en un marco que no solo considere los avances tecnológicos, sino que también aborde los desafíos éticos asociados con la aplicación de la IA en la clasificación de la EA. La sinergia entre el progreso científico y la consideración de aspectos éticos y regulatorios se erige como un elemento fundamental para el desarrollo sostenible y ético en el ámbito médico.

## CAPÍTULO II

### 2. MATERIALES Y MÉTODOS

#### 2.1. Tipo de estudio o investigación

Para abordar de manera integral el problema de la identificación temprana del Alzheimer mediante el uso de aplicaciones móviles, se realizó un estudio exploratorio. Este tipo de investigación inicial permite examinar el tema de forma amplia y sin prejuicios, proporcionando una base sólida para las siguientes fases de la investigación sobre la EA. Un estudio exploratorio tiene como objetivo familiarizarse con el fenómeno en cuestión, identificar variables relevantes y formular hipótesis o preguntas de investigación específicas que guíen estudios posteriores [77].

Este estudio implicó la recopilación y análisis de datos cualitativos y cuantitativos provenientes de diversas fuentes, como encuestas, entrevistas y observaciones [74, 78]. Los métodos utilizados pueden variar según la naturaleza del tema y los objetivos de la investigación, siendo flexibles y adaptativos para permitir una exploración en profundidad [79].

Los resultados de un estudio exploratorio pueden ofrecer una comprensión preliminar del tema, identificar áreas clave para futuras investigaciones y ayudar a formular hipótesis o preguntas de investigación más específicas [80]. Sin embargo, debido a su enfoque inicial y abierto, los hallazgos suelen requerir validación adicional mediante investigaciones más rigurosas y controladas [77].

Se identificó información relevante a través del estudio exploratorio para desarrollar una aplicación móvil. Además, se relacionó la información obtenida con la bibliografía existente y con lo propuesto en el estudio. Se prevé contrastar estos datos con información adicional para comprender mejor cada situación.

En el estudio, se aplicó esta técnica de investigación con el objetivo de identificar herramientas que permitan conocer los avances sobre la temática y comprender su funcionalidad. Esto se realizó para enriquecer los estudios previamente identificados en el estudio exploratorio. Esta técnica se utilizó especialmente en el capítulo I, donde se describen estudios previos relacionados con el desarrollo de aplicaciones móviles para la clasificación de imágenes en la detección del Alzheimer.

## **2.2. Estudio correlacional**

Un estudio correlacional se centra en investigar la relación entre dos o más variables sin intentar establecer una relación causal directa entre ellas [81]. Es decir, busca determinar si existe una asociación entre las variables y en qué medida varían conjuntamente, sin afirmar que una variable cause directamente cambios en la otra [82].

En el estudio correlacional realizado, se recopilaron datos sobre variables relevantes para la clasificación de las fases de la EA, utilizando técnicas estadísticas como el coeficiente de correlación para analizar la fuerza y la dirección de la relación entre estas variables [82]. Este enfoque permitió identificar asociaciones significativas entre los datos de imágenes de IRM y los parámetros clínicos, lo cual es fundamental para establecer patrones que puedan mejorar la precisión en la clasificación de la EA. La correlación positiva o negativa entre las variables puede ofrecer una comprensión más profunda de cómo ciertos factores se asocian con la progresión de la enfermedad [81].

El estudio correlacional es particularmente útil en el contexto de la investigación médica y neurológica, donde no es práctico ni ético manipular ciertas variables independientes, como las condiciones de salud de los pacientes. En este caso, se busca explorar asociaciones entre datos de IRM y parámetros clínicos relacionados con la EA [83]. Es importante destacar que la correlación no implica causalidad; aunque se identifiquen relaciones significativas entre variables, esto no significa que una cause directamente la otra. Factores adicionales no considerados podrían estar influyendo en las asociaciones observadas, lo que resalta la necesidad de un análisis cuidadoso.

## **2.3. Diseño de la investigación**

El diseño de la investigación en este estudio se centra en un enfoque mixto que combina métodos exploratorios y correlacionales para clasificar las fases de la EA utilizando imágenes de IRM. Se ha optado por un diseño no experimental debido a la naturaleza observacional del estudio, lo que implica trabajar con datos recopilados de manera pasiva sin manipulación directa de variables. El enfoque principal es identificar patrones en los datos de IRM que permitan clasificar las fases de la enfermedad con alta precisión. Para ello, se implementarán y evaluarán diferentes algoritmos de aprendizaje automático con el objetivo de determinar cuál

presenta mejor desempeño en términos de precisión y eficiencia. Se introducirá un conjunto adicional de imágenes para validar la eficacia del modelo seleccionado.

### **2.3.1. Enfoque cuantitativo**

Este enfoque se basa en la recopilación y análisis de datos numéricos, como imágenes de IRM y variables clínicas relacionadas con la EA. Se emplean instrumentos estandarizados, lo que permite evaluar la precisión y eficiencia de los algoritmos de clasificación aplicados en el estudio [85, 86]. Los datos recopilados se analizan utilizando métodos estadísticos y técnicas matemáticas para identificar patrones, relaciones y regularidades entre las variables estudiadas.

Una de las características fundamentales del enfoque cuantitativo es su búsqueda de objetividad y replicabilidad, enfocándose en la obtención de resultados que puedan ser verificados y replicados por otros investigadores [87]. Para lograr esto, se utilizan técnicas de muestreo representativas y se aplican procedimientos estadísticos adecuados que aumentan la validez y fiabilidad de los resultados.

El enfoque cuantitativo también se orienta hacia la generalización de los resultados. En este estudio, permitirá analizar la eficacia de los algoritmos aplicados a imágenes de IRM para identificar las fases de la EA, obteniendo conclusiones aplicables a un conjunto mayor de datos clínicos [87]. Esto se logra mediante técnicas estadísticas que extrapolan los hallazgos de la muestra a la población de interés, asegurando la validez estadística. Se midió la eficiencia del algoritmo y su capacidad para ser implementado en una aplicación móvil, con el fin de someterla a validación por expertos en la materia.

Se emplearon técnicas estadísticas, como pruebas de eficiencia y confianza, para evaluar el rendimiento del algoritmo de clasificación de imágenes relacionadas con el Alzheimer en una aplicación móvil. Se analizaron bases de datos abiertas y se aplicaron pruebas estadísticas para medir el desempeño del algoritmo. Finalmente, se hicieron inferencias válidas sobre la eficiencia del algoritmo en una población más amplia de imágenes relacionadas con el Alzheimer.

### **2.4. Población y muestra**

Para este estudio, se utilizó un conjunto de datos adecuado para entrenar el modelo. Se empleó un conjunto de datos preprocesado de IRM obtenido de pacientes con diversos grados de la

EA, disponible en Kaggle. Este conjunto de datos se compone de imágenes correspondientes a las diferentes fases de la EA, que se emplearon en el análisis:

- Fase 1: EA leve (896 imágenes)
- Fase 2: EA moderada (64 imágenes)
- Fase 3: Sin EA (3200 imágenes)
- Fase 4: EA muy leve (2240 imágenes)

## **2.5. Técnicas estadísticas**

Las técnicas estadísticas son herramientas fundamentales para el análisis y la interpretación de los datos recopilados en un estudio de investigación. Estas permiten evaluar la relación entre variables y verificar la eficiencia y validez de los modelos propuestos [88]. Estas técnicas incluyen métodos descriptivos, como las medidas de tendencia central y dispersión, así como técnicas inferenciales, como pruebas de hipótesis y análisis de regresión. La selección de las técnicas estadísticas adecuadas depende de la naturaleza de los datos y de las preguntas de investigación que se buscan responder [89]. Es fundamental que los investigadores comprendan a fondo las técnicas estadísticas empleadas para interpretar los resultados de manera adecuada y extraer conclusiones válidas.

Se empleará una matriz de confusión como parte de la estrategia de análisis estadístico y validación. Esta herramienta es fundamental en el ámbito del AA y la clasificación de datos, ya que permite evaluar la precisión y eficacia de los modelos predictivos al comparar las predicciones generadas con los valores reales de los datos.

## **2.6. Métodos teóricos**

En este estudio se aplicaron métodos teóricos que guían la interpretación de los datos dentro del contexto de la clasificación de fases de la EA. Estos métodos permitieron estructurar la investigación de forma que se relacionen los datos recopilados con teorías existentes en el ámbito del diagnóstico asistido por IA. El enfoque inductivo se utilizó específicamente para generar conclusiones a partir de los datos obtenidos mediante el análisis de imágenes de IRM y para desarrollar nuevos conceptos relacionados con el uso de IA en la identificación de fases de la EA [90]. Al igual que la técnica exploratoria, que permitió identificar y profundizar en conceptos clave relacionados con la clasificación de las fases de la EA. Esta técnica también

facilitó la integración de nuevos hallazgos en el contexto de estudios previos, ayudando a desarrollar una comprensión más clara de cómo las aplicaciones móviles pueden optimizar el uso de IA para mejorar la clasificación de imágenes de IRM.

## 2.7. Metodología CRISP-DM



**Figura 11. Esquema de desarrollo de la aplicación móvil.**

CRISP-DM (Cross Industry Standard Process for Data Mining) es un enfoque estructurado empleado en proyectos de análisis de datos y minería de datos. En este estudio, CRISP-DM se utilizó como guía para estructurar el desarrollo del proyecto, desde la comprensión del problema de clasificación de las fases de la EA hasta la implementación de modelos predictivos basados en imágenes de IRM. Esta metodología permitió abordar de manera sistemática cada una de las etapas del proceso, desde la definición del objetivo del negocio hasta la validación y despliegue de los modelos desarrollados [91].

### 2.7.1. Fase de comprensión del negocio

En esta fase, se colaboró estrechamente con expertos en el campo del Alzheimer y profesionales en análisis de datos para definir claramente los objetivos del proyecto. Se identificaron los problemas específicos que se abordarían, como la clasificación de imágenes de IRM para las

distintas fases de la EA, y se establecieron los objetivos que se esperaba lograr a través del uso de técnicas de clasificación de datos [92].

La comprensión clara de estos objetivos permitió garantizar que el proyecto estuviera alineado con las necesidades de los profesionales del sector médico, facilitando así la adaptación de los algoritmos para lograr una mayor precisión en la clasificación y promoviendo la implementación de la aplicación en un entorno clínico.

### **2.7.2. Fase de comprensión de los datos**

En esta fase, se recopilaron y exploraron los datos del conjunto de imágenes de IRM del Alzheimer disponibles en la base de datos de Kaggle, correspondiente a las distintas fases de la EA (<https://www.kaggle.com/datasets/sachinkumar413/alzheimer-mri-dataset>). Se realizó un análisis inicial para comprender la estructura de los datos, identificar variables clave y detectar posibles valores atípicos o faltantes. Esta exploración preliminar permitió evaluar la calidad y adecuación del conjunto de datos para el análisis [92].

A continuación, se utilizaron herramientas como ImageDataGenerator para mejorar el entrenamiento del algoritmo mediante la ampliación y el enriquecimiento del conjunto de datos. Esto permitió generar una mayor variabilidad en las imágenes de entrada, facilitando el aprendizaje profundo del modelo y aumentando la precisión en la clasificación de las fases de la EA.

### **2.7.3. Fase de preparación de los datos**

En esta fase, los datos se preparan para el análisis mediante la limpieza, transformación y selección de características relevantes [93]. Esto incluye la eliminación de datos incompletos o erróneos, la codificación de variables categóricas y la normalización de las imágenes. La preparación asegura que los datos estén en un formato adecuado y de alta calidad para ser utilizados en el análisis posterior [92]. Al finalizar esta etapa, los datos estarán listos para ser procesados en las fases posteriores de CRISP-DM, como el modelado y la evaluación de los resultados.

Durante este proceso, se aplican técnicas adicionales de preprocesamiento para optimizar el entrenamiento del modelo. Esto incluye la normalización y redimensionamiento de las imágenes para asegurar un tamaño consistente, y el aumento de datos para mejorar la

variabilidad y robustez del conjunto de datos. Los datos preparados se almacenan en una base interna, organizados por tipo de Alzheimer, permitiendo una clasificación más precisa durante el modelado.

#### **2.7.4. Fase de modelado**

En la fase de modelado, se aplican técnicas de modelado de datos para construir modelos predictivos o descriptivos que aborden los objetivos del proyecto, previamente identificados en las fases anteriores. Este proceso incluye la selección y configuración de algoritmos adecuados, evaluando y refinando los modelos para garantizar su rendimiento óptimo [93]. Durante esta etapa, se exploran diversos enfoques de modelado y se ajustan los parámetros de los modelos para mejorar los resultados. Asimismo, se realiza una validación cruzada para evaluar la capacidad de los modelos de generalizar correctamente a datos nuevos y no vistos [91].

Se implementaron modelos de aprendizaje automático utilizando Python y herramientas como TensorFlow o PyTorch. Además, se recurrió al transfer learning para ajustar modelos previamente entrenados, como SVM y CNN, adaptándolos a la problemática específica de la EA. Estos modelos fueron entrenados con el conjunto de datos preprocesado y su rendimiento fue evaluado con métricas como precisión, exhaustividad y el F1-score.

Finalmente, se realizaron ajustes en los hiperparámetros de los modelos para mejorar su rendimiento. Esto incluye la selección de arquitecturas óptimas para redes neuronales convolucionales, la optimización del kernel y la regularización de parámetros en SVM, entre otros. Los algoritmos comparados serán detallados en los resultados, donde se describirá la eficiencia del modelo propuesto en relación con esta información:

#### **2.7.5. PCA**

La descripción del algoritmo aplicado al Análisis de Componentes Principales (PCA) se encuentra en el Anexo 2. El proceso comienza con una función llamada `extract_feature`, la cual extrae características de las imágenes ubicadas en un directorio específico. Primero, las imágenes se leen utilizando `mpimg.imread`, luego se normalizan los valores de píxeles, se redimensionan a 128x128 píxeles y, finalmente, se aplanan para su análisis mediante PCA. Esta función fue aplicada a diferentes conjuntos de imágenes correspondientes a distintos grados de la EA. Posteriormente, combiné todos los datos extraídos y los dividí en conjuntos

de entrenamiento y prueba, escalando los valores para estandarizarlos. Se realizó el PCA con el fin de reducir la dimensionalidad de los datos y se visualizó la varianza explicada acumulativa.

Después, configuré y entrené el Análisis Discriminante Lineal (LDA) para clasificar los datos según el estado de la EA. Finalmente, evalué la precisión del modelo tanto en el conjunto de entrenamiento como en el de prueba, obteniendo una precisión del 90.62% en el entrenamiento.

#### **2.7.6. Modelo SVM con Kernel Lineal**

En este caso (ver Anexo 3), se implementó un modelo de Máquinas de Vectores de Soporte (SVM) utilizando las etapas de la EA y las funciones necesarias de la biblioteca sklearn. Específicamente, se importó la clase SVC desde sklearn.svm para definir y entrenar el modelo SVM con un kernel lineal. También se importaron algunas métricas de evaluación desde sklearn.metrics para medir el rendimiento del modelo.

Se creó una instancia del modelo SVM con un kernel lineal, ajustándolo al conjunto de entrenamiento. Además, se definió una función llamada evaluate\_model para calcular y mostrar las métricas de rendimiento del modelo, como precisión, recall, puntuación F1 y la matriz de confusión, tanto para el conjunto de entrenamiento como para el de prueba.

Posteriormente, se realizaron predicciones en ambos conjuntos, y se utilizó la función evaluate\_model para mostrar las métricas correspondientes. Este enfoque permite realizar una evaluación completa del rendimiento del modelo SVM en los dos conjuntos de datos. En este caso, el modelo presentó una eficiencia en el conjunto de entrenamiento del 96.34%

#### **2.7.7. Modelo SVM con Kernel Polinomial**

Para este caso, se utilizó la biblioteca scikit-learn para entrenar un modelo de Máquinas de Vectores de Soporte (SVM) con un kernel polinomial de grado 2 y evaluar su rendimiento en los conjuntos de entrenamiento y prueba. Se importaron las funciones necesarias de scikit-learn para el SVM, junto con las métricas de evaluación, como precisión, recall, puntuación F1 y la matriz de confusión. Posteriormente, se creó una instancia del clasificador SVM con un kernel polinomial de grado 2, y se ajustó al conjunto de entrenamiento (train\_x, train\_y).

Además, se diseñó una función llamada `evaluate_model` (ver Anexo 4), que toma un modelo entrenado, los conjuntos de características ( $x$ ) y etiquetas ( $y$ ), y el tipo de conjunto de datos (entrenamiento o prueba). Esta función realiza predicciones con el modelo, calcula y muestra las métricas como precisión, recall, puntuación F1 y matriz de confusión. Luego, se llamó a `evaluate_model` para evaluar el rendimiento del modelo SVM en ambos conjuntos de datos.

### **2.7.8. Modelo SVM Kernel rbf**

Este fragmento de código (ver Anexo 5) en Python utiliza la biblioteca `scikit-learn` para entrenar un modelo de Máquinas de Vectores de Soporte (SVM) con un kernel RBF (Radial Basis Function) y evaluar su rendimiento en los conjuntos de entrenamiento y prueba. Se importaron las funciones necesarias de `scikit-learn` para el SVM, así como las métricas de evaluación, incluyendo precisión, recall, puntuación F1 y la matriz de confusión. A continuación, se creó una instancia del clasificador SVM con un kernel RBF, y se ajustó al conjunto de entrenamiento (`train_x`, `train_y`).

Además, se definió una función llamada `evaluate_model`, que toma un modelo entrenado, los conjuntos de características ( $x$ ) y etiquetas ( $y$ ), y el tipo de conjunto de datos (entrenamiento o prueba). Esta función realiza predicciones con el modelo, calcula y muestra las métricas como precisión, recall, puntuación F1 y matriz de confusión. Se llamó a `evaluate_model` tanto para evaluar el rendimiento del modelo SVM en el conjunto de entrenamiento como en el conjunto de prueba, permitiendo una evaluación exhaustiva de su eficacia.

## **2.8. Fase de evaluación:**

En la fase de evaluación, se evalúan los modelos desarrollados en la fase anterior para determinar su eficacia y capacidad para cumplir con los objetivos del proyecto. Se utilizan métricas de rendimiento específicas, como precisión, exhaustividad, exactitud y la relación sesgo-varianza, para comparar y seleccionar los mejores modelos [93]. Además, se realizan pruebas de sensibilidad y análisis de errores para entender mejor el comportamiento de los modelos en diversos escenarios y condiciones [94].

Para esta evaluación, se utilizó una matriz de confusión, lo que permitió evaluar el rendimiento de los modelos entrenados y comprender cómo se clasificaron las distintas fases de la EA, identificando posibles errores recurrentes. Adicionalmente, se aplicaron técnicas como la

validación cruzada para obtener estimaciones más robustas del rendimiento del modelo, asegurando que los resultados sean generalizables a otros conjuntos de datos.

## **2.9. Fase de despliegue:**

La fase de despliegue es la etapa final del proceso CRISP-DM, en la que se implementan y ponen en producción los modelos seleccionados. Esta fase implica la integración de los modelos en los sistemas existentes de la organización, la creación de interfaces de usuario para su uso práctico y la capacitación del personal en su correcta utilización [95]. Además, se establecen procedimientos de monitoreo y mantenimiento para garantizar que los modelos sigan funcionando de manera eficiente en un entorno operativo. El objetivo de esta fase es asegurar que los beneficios obtenidos del análisis de datos se traduzcan en mejoras tangibles en el negocio [96].

En este proyecto, se implementó el backend utilizando Python y la biblioteca Flask, permitiendo crear endpoints de API para realizar inferencias con el modelo entrenado. Para la visualización de resultados, se desarrolló una interfaz gráfica de usuario (GUI) en React Native y JavaScript. Además, se utilizaron herramientas como Firebase, Firestore Database y Local Storage para el almacenamiento adicional de datos y resultados del análisis, lo que facilita una gestión más efectiva de la información.

## CAPÍTULO III

### 3. DESARROLLO DE LA APLICACIÓN MÓVIL

En este capítulo, se describen los resultados obtenidos durante el desarrollo del proyecto, con un enfoque particular en la creación y diseño de los mockups, así como en la distribución de la aplicación. Se detalla la estructura de la interfaz de usuario de la aplicación, destacando diversas secciones fundamentales. Una de las principales secciones es la portada o página de inicio, que actúa como el punto de entrada principal a la aplicación. Esta página presenta una interfaz visualmente atractiva, diseñada con botones funcionales para facilitar la carga de datos, además de proporcionar acceso a información relevante sobre el Alzheimer y a un manual de usuario detallado.

Se resaltarán la importancia de diseñar una interfaz de fácil uso, lo cual es fundamental para asegurar que el software pueda ser utilizado en diversos campos de aplicación de manera eficiente. Posteriormente, se detallará la sección destinada a la evaluación de neuroimágenes, donde se describe el proceso de verificación de imágenes para detectar posibles signos de la EA. Este proceso se dividirá en etapas específicas, como la carga inicial de imágenes y la clasificación de los diferentes estados de la enfermedad. En esta clasificación, se presentarán categorías que reflejan los distintos niveles de gravedad de la EA. Además, se explicará cómo los usuarios pueden visualizar los resultados obtenidos y regresar al inicio para realizar nuevas evaluaciones. Los resultados de las pruebas de evaluación, obtenidos a partir de las fases de entrenamiento y prueba, se describen y analizan en los apartados siguientes.

#### **3.1. Aplicación de CRISP-DM en la selección de modelos de ML para la clasificación de fases de la EA**

##### **3.1.1. Fase de comprensión del negocio**

Se colaboró con expertos en el dominio de la EA y profesionales en análisis de datos para establecer una comprensión clara de los objetivos del proyecto y los requisitos del negocio. Se identificaron problemas específicos relacionados con la clasificación de imágenes de la EA y se definieron objetivos concretos que se esperan alcanzar mediante la aplicación de técnicas de clasificación de datos.

### **3.1.2. Fase de comprensión de los datos**

Se recopilaron y exploraron los datos relevantes para el proyecto, obtenidos de la base de datos Kaggle sobre imágenes de la EA. Se realizó un análisis inicial para comprender la estructura, calidad y distribución de los datos. Además, se utilizaron herramientas como ImageDataGenerator para aumentar la variabilidad del conjunto de datos y optimizar el entrenamiento del modelo.

### **3.1.3. Fase de preparación de los datos**

Se aplicaron técnicas de preprocesamiento, como la normalización y el redimensionado de imágenes, para asegurar un tamaño uniforme y mejorar la calidad del conjunto de datos. Las imágenes fueron agrupadas en una base de datos interna, clasificadas según las diferentes fases de EA.

### **3.1.4. Fase de modelado**

Se implementaron modelos de aprendizaje automático utilizando Python, empleando herramientas como TensorFlow y PyTorch. Se recurrió al transfer learning para ajustar modelos previamente entrenados, como SVM y CNN, a la problemática específica de la clasificación de fases de la EA. Los modelos fueron entrenados con el conjunto de datos preprocesado y su rendimiento fue evaluado mediante métricas como precisión, exhaustividad y F1-score. Además, se realizaron ajustes en los hiperparámetros para optimizar el rendimiento, incluyendo la optimización del kernel y los parámetros de regularización en el caso del SVM.

#### **3.1.4.1. PCA**

Se empleó PCA para reducir la dimensionalidad de los datos y facilitar la visualización de la varianza explicada acumulativa. Posteriormente, se entrenó un modelo de Análisis Discriminante Lineal (LDA) para clasificar los datos según el estado de la EA, logrando una precisión del 90.62% en el conjunto de entrenamiento.

#### **3.1.4.2. Modelo SVM con Kernel Lineal**

Se entrenó un modelo SVM con kernel lineal, y se evaluó su rendimiento mediante métricas como precisión, recuperación, F1-score y matriz de confusión, alcanzando una eficiencia del 96.34% en el conjunto de entrenamiento.

#### **3.1.4.3. Modelo SVM con Kernel Polinomial**

Se implementó un modelo SVM con kernel polinomial de grado 2, y su rendimiento fue evaluado mediante métricas estándar, mostrando resultados relevantes tanto en el conjunto de entrenamiento como en el de prueba.

#### **3.1.4.4. Modelo SVM con Kernel RBF**

Se desarrolló un modelo SVM con kernel RBF, evaluado mediante las métricas habituales, como precisión y otros indicadores clave, para medir su rendimiento.

#### **3.1.5. Fase de evaluación**

Se evaluaron los modelos utilizando una matriz de confusión y validación cruzada para obtener estimaciones robustas del rendimiento y detectar posibles errores comunes.

#### **3.1.6. Fase de despliegue**

Se implementó el backend del proyecto en Python utilizando Flask para crear endpoints de API que permitan realizar inferencias con el modelo entrenado. Para la visualización de resultados, se desarrolló una interfaz gráfica de usuario (GUI) con React Native y JavaScript, mientras que Firebase se empleó para el almacenamiento de datos y resultados.

Durante esta fase, se aplicó la matriz de confusión como parte de la evaluación y validación de los modelos de clasificación de imágenes de Alzheimer desarrollados. La matriz de confusión se utilizó para analizar la precisión de los modelos al comparar las predicciones de clasificación con las fases reales de la EA presentes en las imágenes.

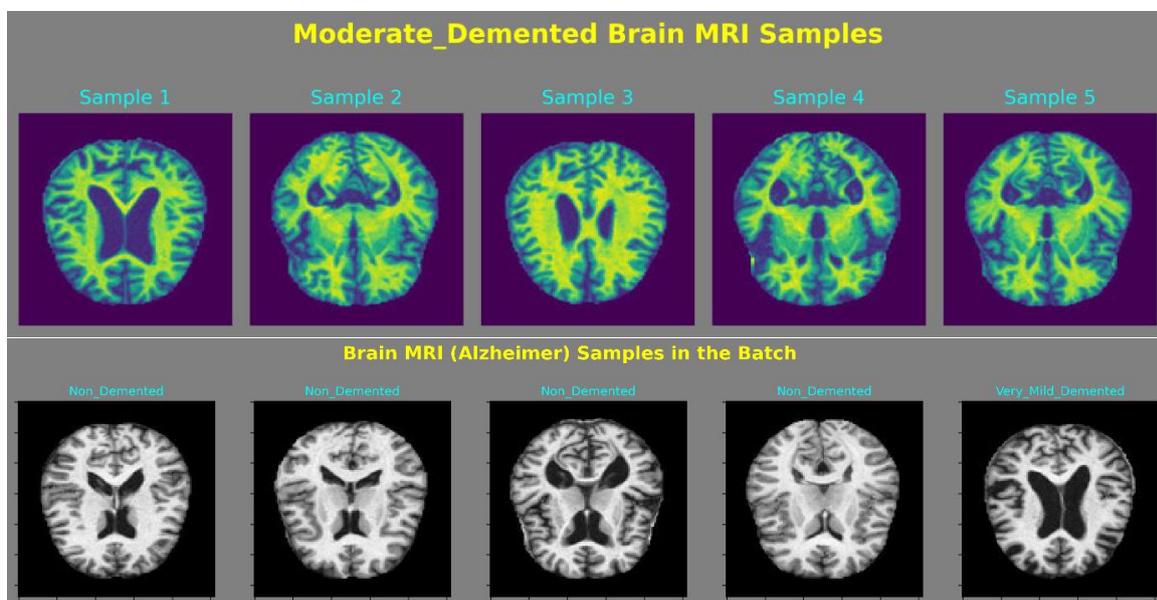
Además, se emplearon técnicas estadísticas inferenciales, como pruebas de hipótesis, para evaluar la significancia de cualquier mejora observada en la precisión de la clasificación entre diferentes variantes de modelos experimentales. Durante esta fase de desarrollo, se refinaron y ajustaron los algoritmos de clasificación en función de los resultados de la evaluación estadística y la retroalimentación proporcionada por expertos en el dominio del Alzheimer.

El desarrollo y funcionamiento de la aplicación móvil para la clasificación de imágenes relacionadas con el Alzheimer sigue un proceso estructurado que abarca varias fases clave. Estas fases son esenciales para garantizar que el modelo final sea preciso, eficiente y cumpla con los objetivos del proyecto. A continuación, se describirán cada una de las fases en detalle,

destacando su importancia en el desarrollo del modelo y su contribución al éxito general de la aplicación móvil:

En primer lugar, se estableció una comprensión clara de los objetivos del negocio y los requisitos del proyecto. Se colaboró estrechamente con expertos en el dominio del Alzheimer y profesionales en análisis de datos para identificar los problemas clave que se abordarían y definir los objetivos específicos. Esta colaboración aseguró que el desarrollo del proyecto estuviera alineado con las necesidades y prioridades de la organización.

Para ello, se recopiló y exploró el conjunto de datos relevante para el proyecto, obtenido de la base de datos de Kaggle. Se llevó a cabo un análisis exhaustivo de los datos para comprender su estructura, calidad y distribución. Se identificaron variables clave y se formularon hipótesis iniciales sobre posibles patrones o tendencias presentes en los datos.



**Figura 12. Modificación de la escala de colores obtenida dentro de la aplicación móvil.**

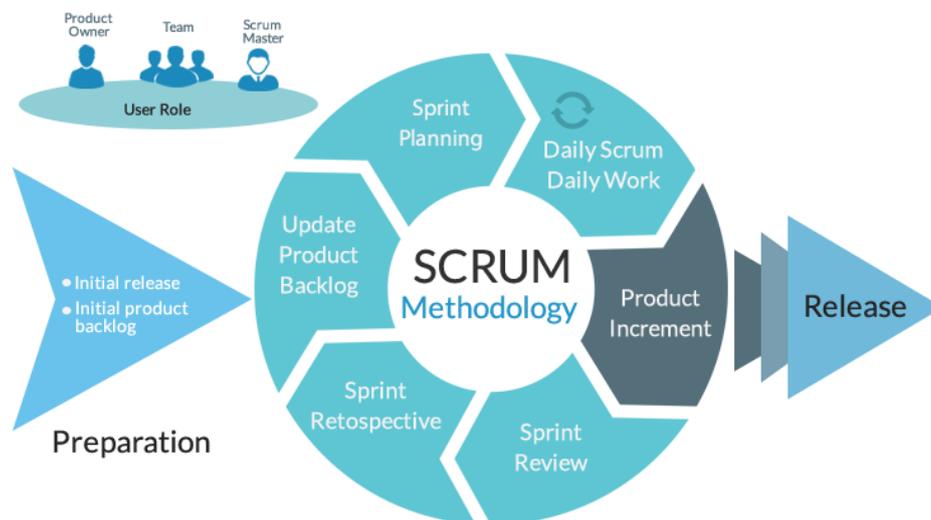
Cada una de las imágenes dentro del modelo de clasificación fue convertida a escala de grises para estandarizar la información cargada en la aplicación móvil y facilitar su clasificación.

Los datos fueron preparados meticulosamente para el análisis. Se eliminaron registros incompletos o incorrectos, se codificaron las variables categóricas y se normalizaron los valores numéricos. Además, se generaron nuevas variables derivadas para mejorar la calidad y relevancia del conjunto de datos. Esta fase garantizó que los datos estuvieran en un formato adecuado y listo para su posterior análisis.

En el anexo 5 se describe cómo, en el código de Python, se define una función llamada `extract_feature`. A continuación, se detalla lo que este fragmento de código realiza:

Primero, se definió una función llamada `extract_feature`, que toma un argumento llamado `dir_path`, el cual representa la ruta de un directorio que contiene una imagen. Dentro de esta función, se comienza leyendo la imagen ubicada en la ruta especificada por `dir_path`. Posteriormente, se normalizan los valores de los píxeles de la imagen dividiéndolos por 255.0, lo que asegura que los valores de los píxeles estén en el rango [0, 1]. Luego, la función redimensiona la imagen a una resolución de 128x128 píxeles mediante una función de redimensionamiento. Finalmente, se aplana la imagen en una matriz unidimensional de tamaño 128x384, obteniendo así imágenes estandarizadas para un procesamiento adecuado de la información.

### 3.2. Desarrollo de una aplicación móvil que integra el modelo de ML seleccionado para la clasificación de las fases de la EA utilizando la metodología SCRUM



**Figura 13. Metodología SCRUM aplicada para la aplicación de modelado de la aplicación.**

En este apartado se detalla el enfoque utilizado para definir y organizar los requisitos del proyecto, centrándose en la metodología Scrum y el uso de la herramienta Jira para la gestión ágil. Las historias de usuario, fundamentales en Scrum, capturan las necesidades y expectativas de los usuarios finales, guiando el desarrollo hacia la creación de funcionalidades que aporten valor real.

A continuación, se aborda el diagrama de casos de uso, que proporciona una visión clara de las interacciones del usuario con la aplicación. Este diagrama ofrece una perspectiva integral de las funcionalidades y su relación entre sí, siendo crucial para entender cómo cada historia de usuario se traduce en acciones concretas dentro de la aplicación, y cómo estas interacciones se integran en el conjunto global del proyecto

Adicionalmente, en el tablero de Jira se presenta la organización y priorización de las tareas dentro de cada Sprint. Este enfoque permite un seguimiento claro del progreso y facilita la adaptabilidad a los cambios. Finalmente, se describen los Sprints y las ceremonias de Scrum: la planificación del Sprint, las reuniones diarias, las revisiones y las retrospectivas. Este enfoque iterativo e incremental es esencial para adaptarse a los requisitos cambiantes y para la mejora continua del equipo y del producto.

La descripción de los mockups o la distribución de la aplicación se organiza en torno a una estructura que comprende varias secciones fundamentales. En primer lugar, se destaca la portada o página de inicio, que actúa como el punto de entrada a la aplicación. Esta sección presenta una interfaz visualmente atractiva con botones funcionales que facilitan la carga de datos y proporcionan acceso a información relevante sobre la EA, además de un manual de usuario que detalla el funcionamiento de la aplicación.

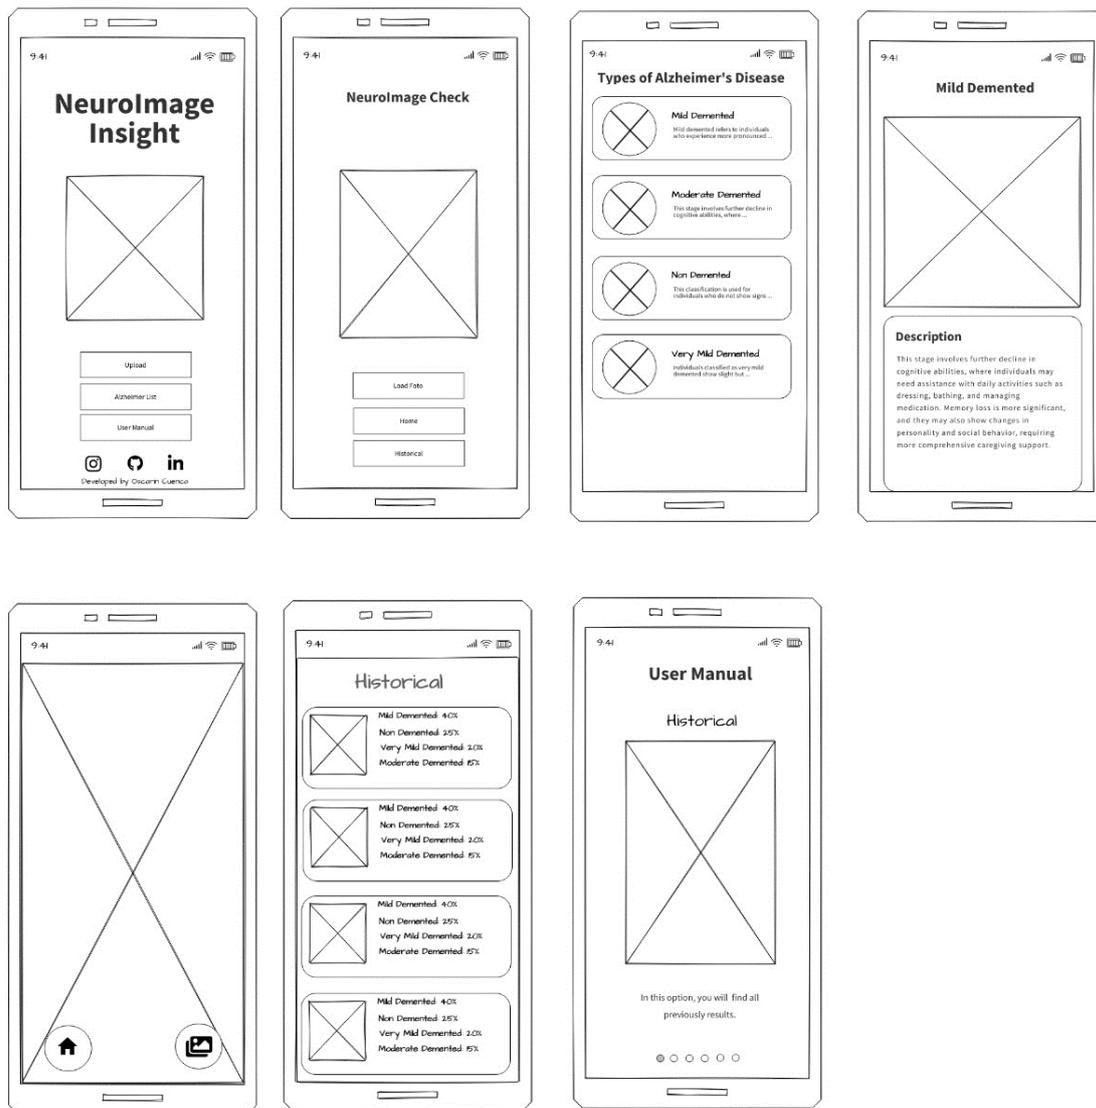
El uso del software se extiende a diversos campos según las necesidades. En la siguiente sección, se aborda la evaluación de neuroimágenes, donde se realiza un proceso de verificación para detectar posibles signos de la enfermedad. Este proceso está organizado en varias etapas de demencia de la EA:

<b>Funcionalidad</b>	<b>Descripción</b>
Portada/Página de Inicio	Interfaz visualmente atractiva con botones funcionales para facilitar la carga de datos y acceso a información sobre la enfermedad de Alzheimer y al manual de usuario.
Carga de Imágenes	Opción para cargar imágenes de neuroimágenes para su posterior análisis.
Clasificación de Estados de Demencia	Categorización de las imágenes según el estado de demencia: 'Leve demencia', 'Demencia moderada', 'Sin demencia' y 'Demencia muy leve'.
Visualización de Resultados	Presentación de los resultados de la evaluación de neuroimágenes.
Retroceso	Función que permite a los usuarios retroceder al inicio para realizar nuevas acciones.
Historial de Clasificación	Apartado que muestra información sobre la clasificación de las imágenes en cada categoría de enfermedad, enumeran los resultados obtenidos en cada sitio de interés.
Manual de Usuario	Detalles sobre el funcionamiento de la aplicación y cómo utilizar sus diferentes características.

**Tabla 2 Descripción de la interfaz visual de la aplicación móvil**

Además, se incluye un apartado adicional denominado 'Historial', que proporciona información sobre la clasificación de las imágenes en cada una de las categorías de enfermedades. También

se enumeran los resultados obtenidos en cada sitio de interés. Las características presentes en el diseño de la aplicación móvil se ilustran en la Figura 14.



**Figura 14. Prototipo Mockups de la parte visual de la aplicación móvil**

## CAPÍTULO IV

### 4. EVALUACIÓN DE LA PROPUESTA Y DISCUSIÓN DE RESULTADOS

#### 4.1. Matriz de confusión

De todos los modelos evaluados se detalla el modelo con mayor precisión. Este modelo se aplicó desde el inicio, descrito dentro de la matriz de confusión, la cual proporciona una representación detallada de cómo el modelo de clasificación identificó los diferentes tipos de demencia. Cada uno de los tipos identificados por el algoritmo y las especificaciones de las bases de datos generaron respuestas de evaluación. En la categoría "Mild\_Demented", el modelo acertó en 72 casos, sin clasificaciones incorrectas como "Moderate\_Demented", pero cometió algunos errores al clasificar 1 caso como "Non\_Demented" y 2 casos como "Very\_Mild\_Demented". En la categoría "Moderate\_Demented", todos los 5 casos fueron correctamente identificados como tal, demostrando una precisión perfecta para esta etapa. La etapa más numerosa, "Non\_Demented", fue clasificada correctamente en 325 casos, con solo 2 casos erróneamente clasificados como "Very\_Mild\_Demented". Por último, en la categoría "Very\_Mild\_Demented", el modelo acertó en 227 casos, pero cometió errores al clasificar 1 caso como "Mild\_Demented" y 5 casos como "Non\_Demented"

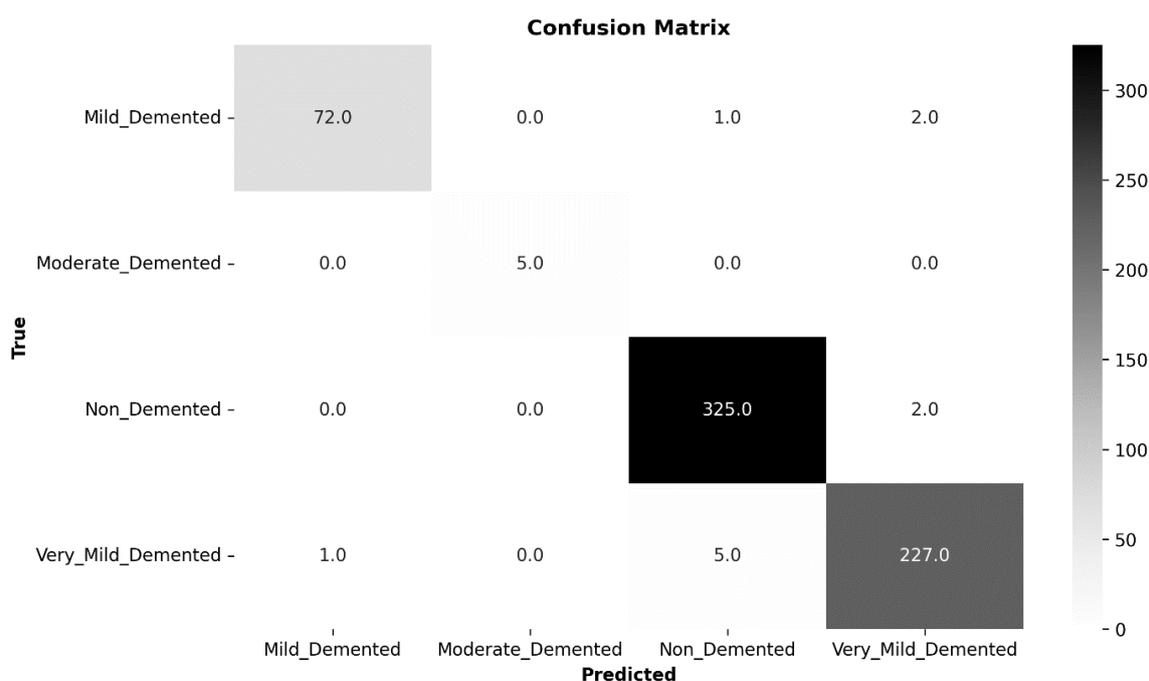


Figura 15. Matriz de confusión del entrenamiento.

La matriz de confusión permitió identificar la eficiencia del modelo de clasificación para cada una de las categorías, proporcionándonos una visión clara de cómo se comportó el modelo. La eficiencia de cada uno de los modelos demuestra su capacidad para discriminar correctamente entre las categorías. Una manera de reducir los errores del modelo es implementar técnicas de data augmentation o aumentar el número de datos utilizados para el entrenamiento.

#### 4.2. Matriz de observación

El modelo evaluado mostró un desempeño sobresaliente en la tarea de clasificación de tipos de demencia. En general, logró una precisión del 98%, lo que indica que la gran mayoría de las predicciones positivas fueron correctas. En términos de recall (sensibilidad), es decir, la capacidad del modelo para identificar correctamente los casos positivos, también obtuvo resultados muy altos, con un promedio del 98%. Esto demuestra que el modelo es efectivo tanto en la identificación correcta de los casos de demencia leve, moderada y muy leve, como en distinguir aquellos que no presentan signos de demencia. Cada una de las categorías y su eficiencia se describen a continuación:

	precision	recall	f1-score	support
Mild_Demented	0.99	0.96	0.97	75
Moderate_Demented	1.00	1.00	1.00	5
Non_Demented	0.98	0.99	0.99	327
Very_Mild_Demented	0.98	0.97	0.98	233
accuracy			0.98	640
macro avg	0.99	0.98	0.98	640
weighted avg	0.98	0.98	0.98	640

**Figura 16. Métricas de precisión, recall y F1-score para las categorías de clasificación de los modelos**

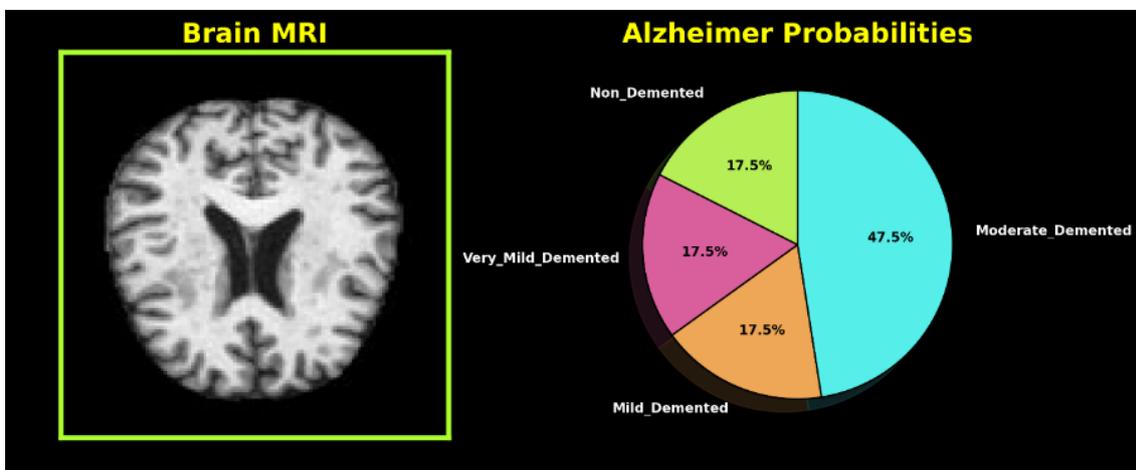
Específicamente, destacan los siguientes puntos:

- Para la etapa de "Demencia Leve", el modelo logró una precisión del 99% y un recall del 96%, lo que muestra una capacidad sólida para identificar correctamente estos casos.

- En la etapa "Demencia Moderada", alcanzó un rendimiento perfecto con una precisión y recall del 100%, indica una capacidad excepcional para identificar esta categoría, aunque con un soporte menor de solo 5 casos.
- En "No Demencia", el modelo obtuvo una precisión del 98% y un recall del 99%, indica una alta precisión en la identificación de individuos sin demencia.
- Finalmente, para "Demencia Muy Leve", el modelo reportó una precisión del 98% y un recall del 97%, muestra consistencia en la identificación de casos de esta categoría.

### 4.3. Resultados de la prueba de eficiencia

Los resultados del modelo son muy prometedores, con altos niveles de precisión y recall en todas las fases de demencia de la EA evaluadas. Esto sugiere que el modelo es capaz de realizar una clasificación confiable y precisa de los distintos tipos de demencia en el conjunto de datos utilizado.



**Figura 17. Descripción visual de la probabilidad de clasificación para cada una de las fases de la EA**

Los resultados de la clasificación muestran cómo el modelo asigna probabilidades a diferentes fases de la EA para tres imágenes distintas. En cada caso, el modelo tiende a preferir una fase en particular, aunque con variaciones entre las imágenes. Esto sugiere que el modelo podría estar sesgado hacia ciertas categorías dependiendo de las características visuales específicas de cada imagen.

Por ejemplo, en la primera imagen ('mild.jpg'), el modelo predice 'Mild\_Demented' con la mayor probabilidad. En la segunda imagen ('moderate.jpg'), la fase 'Moderate\_Demented'

obtiene la probabilidad más alta, mientras que en la tercera imagen ('verymild.jpg'), la predicción principal es 'Very\_Mild\_Demented'. Esta variabilidad podría indicar la sensibilidad del modelo a características específicas de cada fase de demencia, lo cual podría ser investigado para mejorar la consistencia y generalización del modelo en futuras aplicaciones clínicas o de investigación.

Se aplicaron diversas técnicas de modelado de datos con el objetivo de construir modelos predictivos y descriptivos enfocados en la clasificación de las fases de la EA. Se seleccionaron y configuraron los algoritmos más adecuados para este tipo de problema, como SVM y CNN, y se ajustaron los parámetros de cada modelo para optimizar su rendimiento. Además, se utilizó la técnica de transfer learning, ajustando modelos previamente entrenados para adaptarlos a la clasificación de imágenes relacionadas con el Alzheimer.

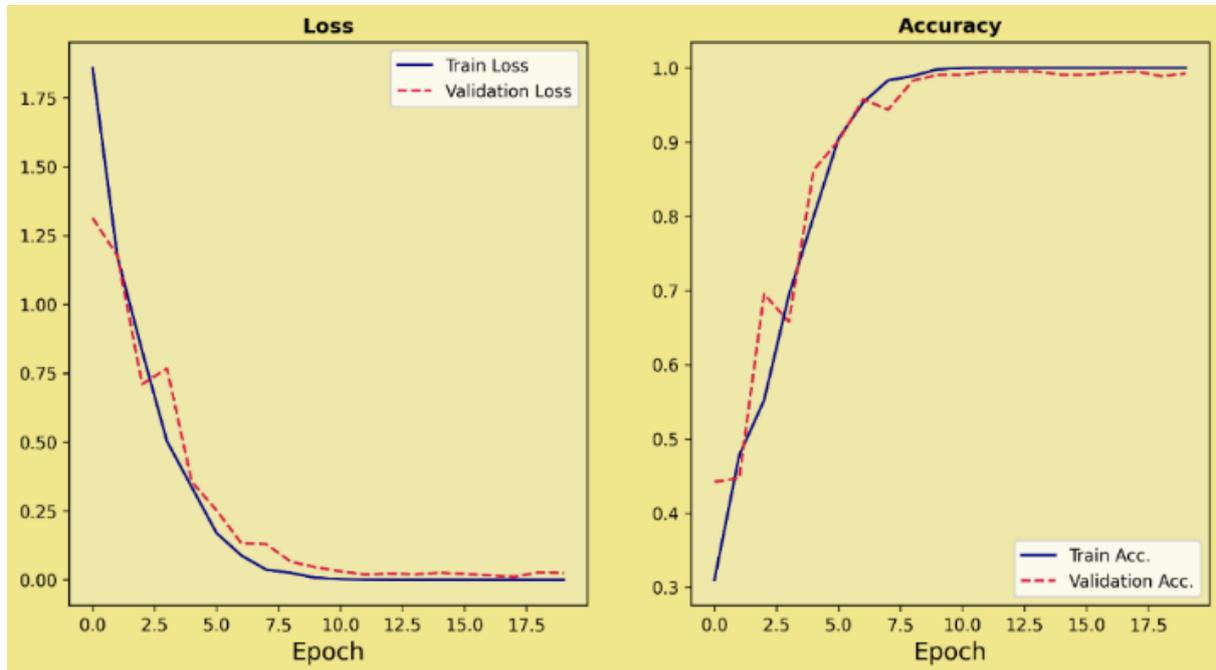
```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
conv2d (Conv2D)              (None, 126, 126, 16)       448
max_pooling2d (MaxPooling2D) (None, 63, 63, 16)         0
conv2d_1 (Conv2D)            (None, 61, 61, 32)         4640
max_pooling2d_1 (MaxPooling2D) (None, 30, 30, 32)         0
conv2d_2 (Conv2D)            (None, 28, 28, 128)        36992
max_pooling2d_2 (MaxPooling2D) (None, 14, 14, 128)        0
flatten (Flatten)            (None, 25088)               0
dense (Dense)                 (None, 128)                 3211392
dense_1 (Dense)               (None, 64)                  8256
dense_2 (Dense)               (None, 4)                   260
-----
Total params: 3261988 (12.44 MB)
Trainable params: 3261988 (12.44 MB)
Non-trainable params: 0 (0.00 Byte)

```

**Figura 18. Arquitectura del modelo CNN utilizada en la evaluación del algoritmo**

Se evaluaron los modelos desarrollados para determinar su eficacia y capacidad para cumplir con los objetivos del proyecto. Se utilizaron métricas de rendimiento específicas, como la precisión, exhaustividad y exactitud, para comparar y seleccionar los modelos más adecuados. Además, se realizaron pruebas de sensibilidad y análisis de errores con el fin de comprender mejor el comportamiento de los modelos bajo diferentes escenarios y condiciones.



**Figura 19. Perdida y precisión de la clasificación de las imágenes en el entrenamiento.**

Finalmente, se implementaron y desplegaron los modelos seleccionados en un entorno de producción. Los modelos se integraron en los sistemas existentes de la organización y se desarrollaron interfaces de usuario para facilitar su uso práctico. Además, se establecieron procedimientos de monitoreo y mantenimiento para garantizar un rendimiento constante de los modelos en el entorno operativo. Esta fase asegura que los resultados obtenidos del análisis de datos se traduzcan en mejoras tangibles para la organización.

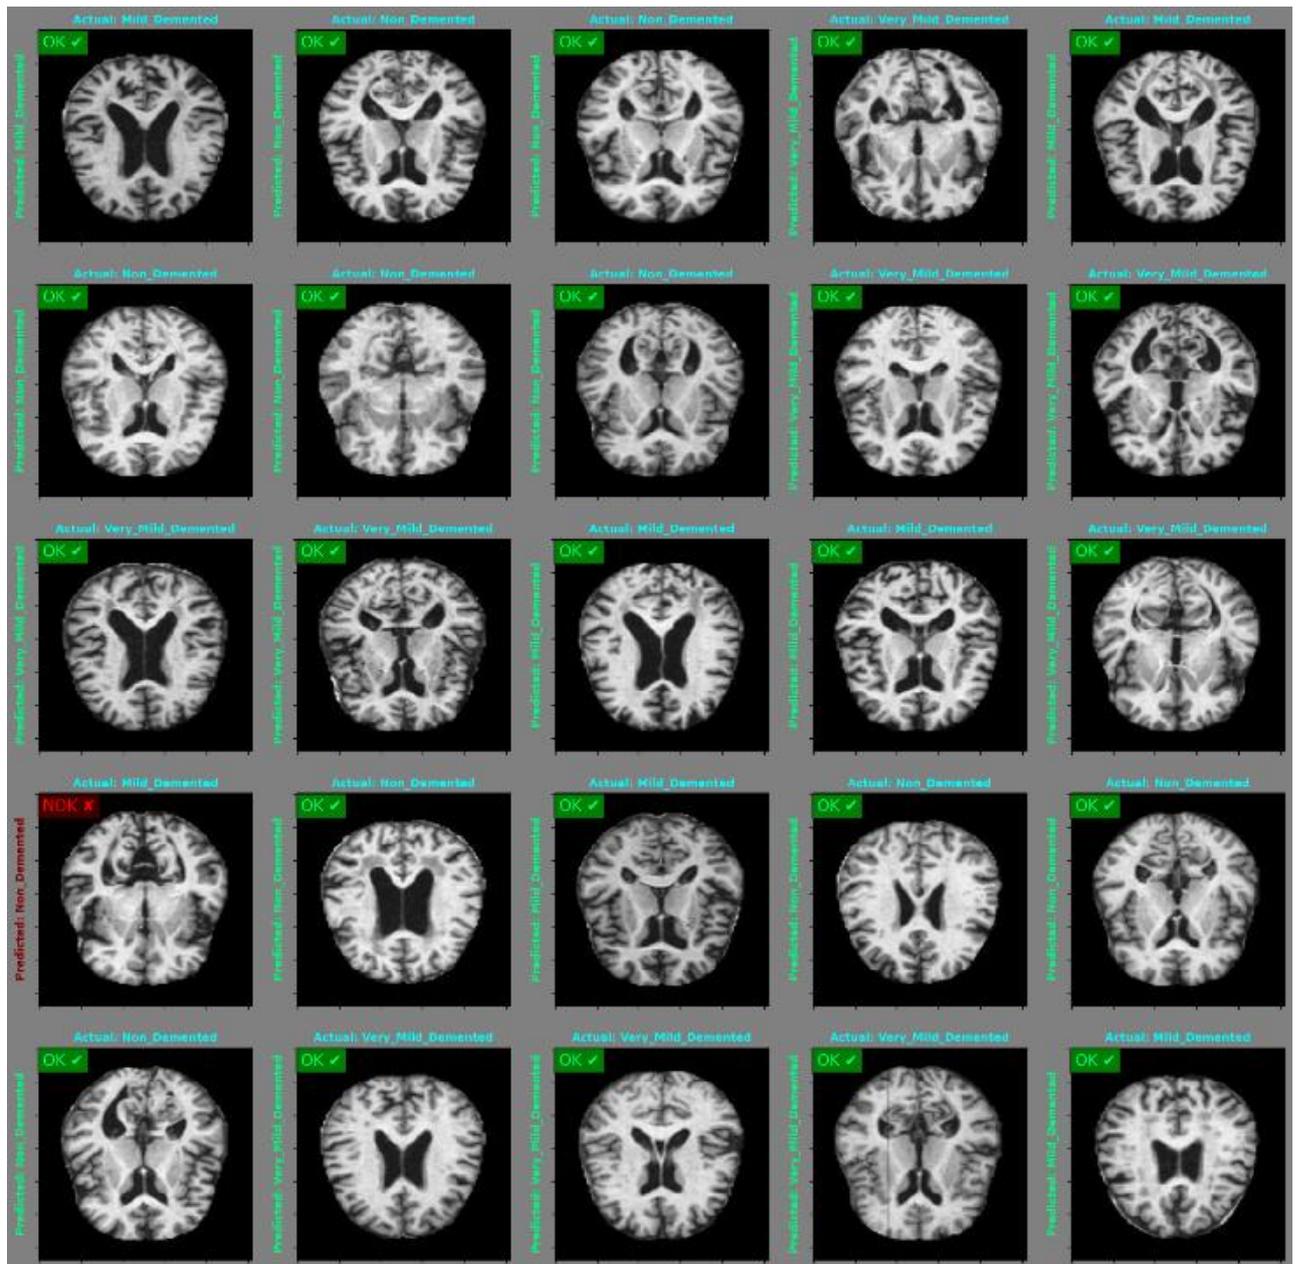
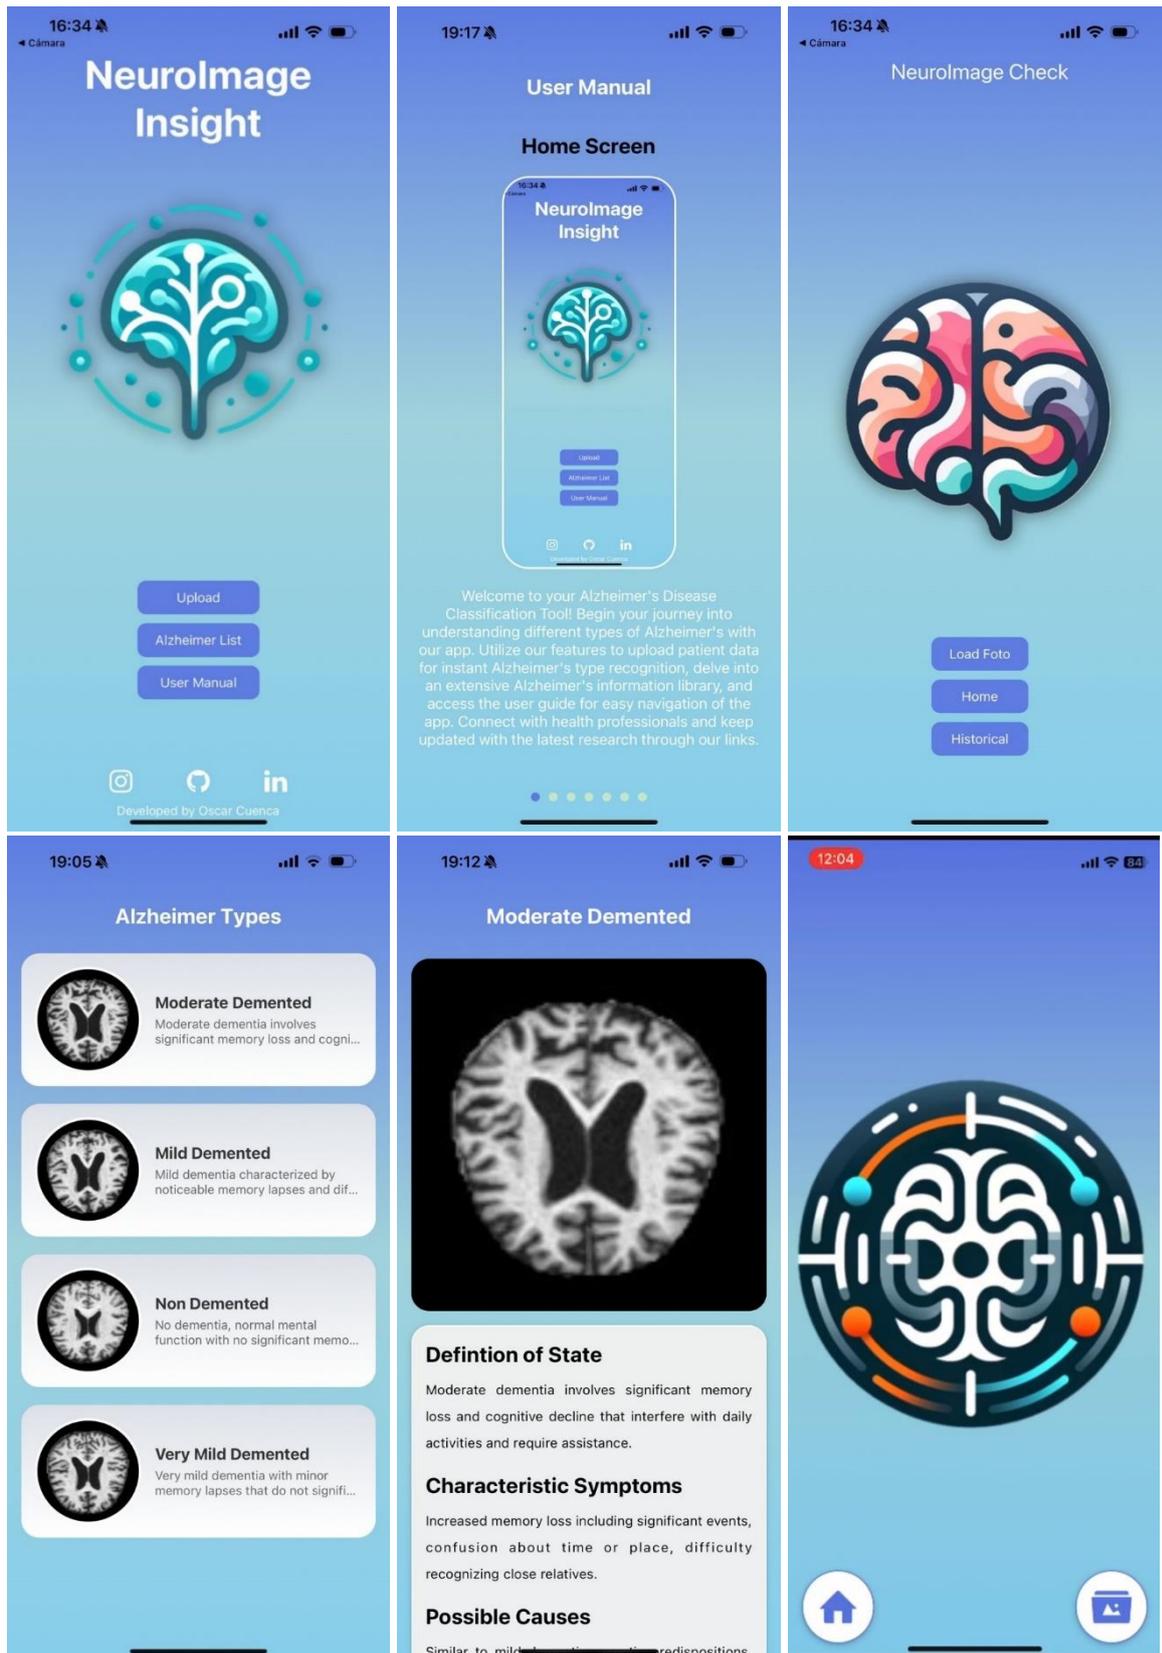
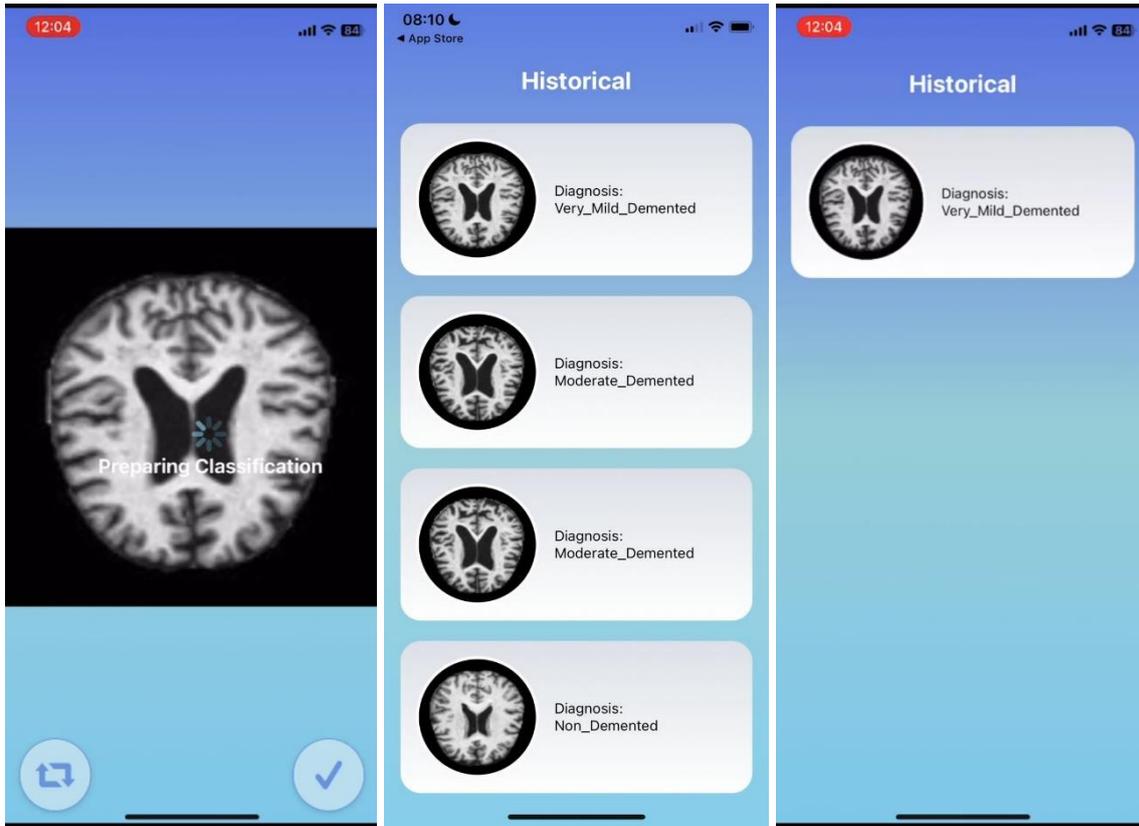


Figura 20. Descripción gráfica de la precisión de los tipos en la clasificación.

#### 4.4. Descripción visual de la aplicación móvil en funcionamiento





**Figura 21. Descripción visual de la interfaz de la aplicación móvil**



**Figura 22. Diagrama de flujo de la interfaz de usuario de la aplicación móvil**

Se realizaron pruebas de funcionalidad en dispositivos móviles, evaluando el rendimiento del modelo de clasificación en diferentes plataformas. No se encontraron errores en la

funcionalidad del modelo, desde la carga de imágenes, la lectura del manual de usuario, hasta la simplicidad de uso de cada uno de los modelos y mockups probados dentro de la aplicación.

#### **4.5. Discusión de resultados**

Los resultados muestran que el modelo de clasificación de imágenes de IRM para identificar diferentes etapas de demencia en la EA presenta un rendimiento notablemente alto en términos de precisión y recall en todas las fases evaluadas. Con una precisión general del 98% y un recall promedio del 98%, el modelo demuestra una capacidad significativa para discriminar entre las categorías 'Mild\_Demented', 'Moderate\_Demented', 'Non\_Demented' y 'Very\_Mild\_Demented'. Estos resultados son consistentes con la literatura actual sobre el uso de IA en la clasificación de la EA y otras formas de demencia.

Estudios previos han demostrado que la IA es una herramienta valiosa para el diagnóstico temprano y el seguimiento de la EA. Falcón [1] subraya la importancia de identificar factores de riesgo asociados tanto a los pacientes como a sus cuidadores, sugiriendo que las herramientas de IA podrían mejorar la detección precoz. Sin embargo, el modelo presentado en este estudio muestra una precisión significativamente más alta en comparación con las técnicas tradicionales de evaluación cognitiva.

Según García-Herranz et al. [2], el seguimiento del deterioro cognitivo leve (DCL) mediante pruebas neuropsicológicas, como el TAVEC, puede ser complementado con métodos de IA para mejorar la detección de las fases de la EA. Este enfoque híbrido ofrece una visión más completa del estado cognitivo del paciente, combinando tanto datos objetivos (IA) como subjetivos (evaluaciones clínicas). En nuestro modelo, su capacidad para distinguir con alta precisión entre diferentes tipos de demencia refuerza la idea de que la IA puede ser un complemento eficaz a las herramientas de diagnóstico tradicionales.

El rendimiento casi perfecto del modelo en la fase 'Moderate\_Demented' (precisión y recall del 100%) indica una capacidad excepcional para identificar esta categoría, lo cual es significativo dada la dificultad documentada para clasificar los casos de demencia moderada con técnicas tradicionales [3]. Battista et al. [3] sostienen que las medidas neuropsicológicas, en combinación con algoritmos de IA como las redes neuronales convolucionales (CNN), pueden aumentar sustancialmente la precisión diagnóstica, especialmente en las fases más avanzadas de la enfermedad.

Además, el uso de IA para el diagnóstico a partir de imágenes de resonancia magnética estructural, como se ha hecho en este estudio, coincide con los hallazgos de Zhao et al. [5], quienes destacan que las técnicas de IA basadas en aprendizaje profundo ofrecen un rendimiento superior en comparación con los métodos basados en características manuales. El éxito del modelo al identificar correctamente la fase 'Moderate\_Demented', a pesar de tener un soporte relativamente bajo (solo 5 casos), sugiere que estos algoritmos pueden manejar eficientemente el problema de desequilibrio en las fases de demencia de la EA, un desafío común en la detección de enfermedades raras o poco frecuentes [5].

La implementación de técnicas de transfer learning para ajustar modelos previamente entrenados, como SVM y CNN, ha demostrado ser efectiva en este estudio. Subasi [4] y Liu et al. [13] señalan que el uso de aprendizaje transferencial permite adaptar modelos generalistas a dominios específicos con conjuntos de datos limitados, mejorando así la generalización sin necesidad de grandes volúmenes de datos de entrenamiento.

La precisión del 99% en la etapa Mild\_Demented y del 98% en Non\_Demented demuestra que el modelo es capaz de manejar eficientemente diferentes niveles de gravedad de la demencia. Esto sugiere que técnicas de ajuste fino del modelo, como la regularización de hiperparámetros y la optimización de funciones de costo, son fundamentales para alcanzar un rendimiento óptimo [4, 13].

Aunque los resultados son prometedores, existen algunos desafíos a considerar. La sensibilidad del modelo a características específicas de las imágenes, como se observa en la variabilidad de las predicciones para diferentes imágenes, puede ser un indicio de que el modelo aún no ha logrado una generalización completa. Fabrizio et al. [8] y de la Fuente García et al. [9] enfatizan la necesidad de garantizar que los modelos de IA sean generalizables y robustos ante la variabilidad en los datos de entrada para evitar sesgos que podrían afectar su aplicación clínica.

La variabilidad en la clasificación de imágenes sugiere la importancia de continuar en el uso de técnicas avanzadas de preprocesamiento de datos y aumento de datos para aumentar la consistencia del modelo. Estudios como los de Winchester et al. [18] y Frizzell et al. [19] sugieren que la integración de enfoques multimodales, combina datos de imágenes con otros biomarcadores (por ejemplo, datos genéticos o de fluidos biológicos), podría aumentar aún más la precisión y la robustez de los modelos predictivos.

## CONCLUSIONES

Se concluye que la aplicación móvil cumple eficazmente con el objetivo general de facilitar la detección de etapas de demencia de la EA mediante el análisis automatizado de imágenes de IRM. Utilizando CNN, la aplicación no solo logra una alta precisión en la clasificación de distintos estados de demencia, sino que también proporciona una herramienta accesible y práctica para su uso en contextos clínicos

Los resultados obtenidos demuestran que la selección de la base de datos de Kaggle ha sido clave para el éxito del modelo. La calidad y cantidad de datos disponibles permitieron entrenar y evaluar un modelo robusto, lo cual se refleja en una precisión global del 98% y un recall elevado en todas las categorías evaluadas. Este nivel de rendimiento sugiere que el modelo desarrollado puede identificar correctamente diferentes grados de deterioro cognitivo, desde 'Sin Demencia' hasta 'Demencia Moderada', lo que podría aumentar significativamente la precisión y eficacia en el diagnóstico temprano de la EA.

El diseño y desarrollo del modelo de IA basado en CNN ha sido particularmente exitoso. La arquitectura del modelo ha demostrado ser adecuada para este tipo de análisis de imágenes médicas, confirmando la utilidad de las CNN para identificar patrones complejos en los datos de IRM cerebral. Además, la implementación del modelo en una aplicación móvil ha permitido extender su accesibilidad a una amplia gama de usuarios, profesionales de la salud y pacientes, lo cual puede ayudar a reducir la barrera de acceso al diagnóstico temprano de la EA.

Las pruebas exhaustivas realizadas, así como la evaluación de resultados a través de métricas como matrices de confusión, precisión y recall, han validado la eficacia del modelo de IA propuesto. A pesar de estos resultados prometedores, es importante destacar que la mejora continua del modelo es fundamental. Ampliar el conjunto de datos de entrenamiento y ajustar aún más la arquitectura del modelo podrían aumentar su capacidad de generalización y su precisión en diferentes contextos clínicos y demográficos.

## **RECOMENDACIONES**

Para mejorar aún más la precisión del modelo, se recomienda continuar con la ampliación y diversificación del conjunto de datos utilizado para el entrenamiento. La inclusión de imágenes de resonancia magnética de diferentes poblaciones y en distintas etapas de la EA podría ayudar a aumentar la generalización del modelo.

Se recomienda explorar técnicas de aprendizaje profundo adicionales, como arquitecturas más avanzadas de redes neuronales y enfoques de aprendizaje federado, para optimizar el rendimiento del modelo y reducir posibles sesgos en la clasificación.

Incluir funcionalidades adicionales en la aplicación, como la capacidad de integrar datos clínicos complementarios, tales como evaluaciones cognitivas y genéticas, podría ofrecer un diagnóstico más completo y preciso.

Implementar un sistema de monitoreo continuo del rendimiento del modelo y la aplicación en su uso real. Además, se recomienda actualizar periódicamente el modelo con nuevos datos para mantener su precisión y relevancia.

## BIBLIOGRAFÍA

- [1] Falcón JCE. Factores de riesgo asociados a pacientes con enfermedad de Alzheimer y sus cuidadores. *Revista Cubana de Medicina General Integral* 2020;36:1–18.
- [2] García-Herranz S, Díaz-Mardomingo MC, Peraita H. Evaluación y seguimiento del envejecimiento sano y con deterioro cognitivo leve (DCL) a través del TAVEC. *Anales de Psicología* 2014;30. <https://doi.org/10.6018/analesps.30.1.150711>.
- [3] Battista P, Salvatore C, Berlingeri M, Cerasa A, Castiglioni I. Artificial intelligence and neuropsychological measures: The case of Alzheimer’s disease. *Neurosci Biobehav Rev* 2020;114:211–28. <https://doi.org/10.1016/j.neubiorev.2020.04.026>.
- [4] Subasi A. Use of artificial intelligence in Alzheimer’s disease detection. *Artificial Intelligence in Precision Health*, Elsevier; 2020, p. 257–78. <https://doi.org/10.1016/B978-0-12-817133-2.00011-2>.
- [5] Zhao X, Ang CKE, Acharya UR, Cheong KH. Application of Artificial Intelligence techniques for the detection of Alzheimer’s disease using structural MRI images. *Biocybern Biomed Eng* 2021;41:456–73. <https://doi.org/10.1016/j.bbe.2021.02.006>.
- [6] Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *Gastrointest Endosc* 2020;92:807–12. <https://doi.org/10.1016/j.gie.2020.06.040>.
- [7] Hassani H, Silva ES, Unger S, TajMazinani M, Mac Feely S. Artificial Intelligence (AI) or Intelligence Augmentation (IA): What Is the Future? *AI* 2020;1:143–55. <https://doi.org/10.3390/ai1020008>.
- [8] Fabrizio C, Termine A, Caltagirone C, Sancesario G. Artificial Intelligence for Alzheimer’s Disease: Promise or Challenge? *Diagnostics* 2021;11:1473. <https://doi.org/10.3390/diagnostics11081473>.
- [9] de la Fuente Garcia S, Ritchie CW, Luz S. Artificial Intelligence, Speech, and Language Processing Approaches to Monitoring Alzheimer’s Disease: A Systematic Review. *Journal of Alzheimer’s Disease* 2020;78:1547–74. <https://doi.org/10.3233/JAD-200888>.
- [10] Ursin F, Timmermann C, Steger F. Ethical Implications of Alzheimer’s Disease Prediction in Asymptomatic Individuals through Artificial Intelligence. *Diagnostics* 2021;11:440. <https://doi.org/10.3390/diagnostics11030440>.
- [11] Tsuji S, Hase T, Yachie-Kinoshita A, Nishino T, Ghosh S, Kikuchi M, et al. Artificial intelligence-based computational framework for drug-target prioritization and inference of novel repositionable drugs for Alzheimer’s disease. *Alzheimers Res Ther* 2021;13:92. <https://doi.org/10.1186/s13195-021-00826-3>.

- [12] Silva-Spínola A, Baldeiras I, Arrais JP, Santana I. The Road to Personalized Medicine in Alzheimer's Disease: The Use of Artificial Intelligence. *Biomedicines* 2022;10:315. <https://doi.org/10.3390/biomedicines10020315>.
- [13] Liu X, Chen K, Wu T, Weidman D, Lure F, Li J. Use of multimodality imaging and artificial intelligence for diagnosis and prognosis of early stages of Alzheimer's disease. *Translational Research* 2018;194:56–67. <https://doi.org/10.1016/j.trsl.2018.01.001>.
- [14] Sudar KM, Nagaraj P, Nithisaa S, Aishwarya R, Aakash M, Lakshmi SI. Alzheimer's Disease Analysis using Explainable Artificial Intelligence (XAI). 2022 International Conference on Sustainable Computing and Data Communication Systems (ICSCDS), IEEE; 2022, p. 419–23. <https://doi.org/10.1109/ICSCDS53736.2022.9760858>.
- [15] El-Sappagh S, Alonso JM, Islam SMR, Sultan AM, Kwak KS. A multilayer multimodal detection and prediction model based on explainable artificial intelligence for Alzheimer's disease. *Sci Rep* 2021;11:2660. <https://doi.org/10.1038/s41598-021-82098-3>.
- [16] Martin W, Sheynkman G, Lightstone FC, Nussinov R, Cheng F. Interpretable artificial intelligence and exascale molecular dynamics simulations to reveal kinetics: Applications to Alzheimer's disease. *Curr Opin Struct Biol* 2022;72:103–13. <https://doi.org/10.1016/j.sbi.2021.09.001>.
- [17] Lombardi A, Diacono D, Amoroso N, Biecek P, Monaco A, Bellantuono L, et al. A robust framework to investigate the reliability and stability of explainable artificial intelligence markers of Mild Cognitive Impairment and Alzheimer's Disease. *Brain Inform* 2022;9:17. <https://doi.org/10.1186/s40708-022-00165-5>.
- [18] Winchester LM, Harshfield EL, Shi L, Badhwar A, Khleifat A Al, Clarke N, et al. Artificial intelligence for biomarker discovery in Alzheimer's disease and dementia. *Alzheimer's & Dementia* 2023;19:5860–71. <https://doi.org/10.1002/alz.13390>.
- [19] Frizzell TO, Glashutter M, Liu CC, Zeng A, Pan D, Hajra SG, et al. Artificial intelligence in brain MRI analysis of Alzheimer's disease over the past 12 years: A systematic review. *Ageing Res Rev* 2022;77:101614. <https://doi.org/10.1016/j.arr.2022.101614>.
- [20] Mishra R, Li B. The Application of Artificial Intelligence in the Genetic Study of Alzheimer's Disease. *Aging Dis* 2020;11:1567. <https://doi.org/10.14336/AD.2020.0312>.

- [21] Fang J, Zhang P, Wang Q, Chiang C-W, Zhou Y, Hou Y, et al. Artificial intelligence framework identifies candidate targets for drug repurposing in Alzheimer's disease. *Alzheimers Res Ther* 2022;14:7. <https://doi.org/10.1186/s13195-021-00951-z>.
- [22] Farooq A, Anwar S, Awais M, Alnowami M. Artificial intelligence based smart diagnosis of alzheimer's disease and mild cognitive impairment. 2017 International Smart Cities Conference (ISC2), IEEE; 2017, p. 1–4. <https://doi.org/10.1109/ISC2.2017.8090871>.
- [23] Fabrizio C, Termine A, Caltagirone C, Sancesario G. Artificial Intelligence for Alzheimer's Disease: Promise or Challenge? *Diagnostics* 2021;11:1473. <https://doi.org/10.3390/diagnostics11081473>.
- [24] Liu X, Chen K, Wu T, Weidman D, Lure F, Li J. Use of multimodality imaging and artificial intelligence for diagnosis and prognosis of early stages of Alzheimer's disease. *Translational Research* 2018;194:56–67. <https://doi.org/10.1016/j.trsl.2018.01.001>.
- [25] Sudar KM, Nagaraj P, Nithisaa S, Aishwarya R, Aakash M, Lakshmi SI. Alzheimer's Disease Analysis using Explainable Artificial Intelligence (XAI). 2022 International Conference on Sustainable Computing and Data Communication Systems (ICSCDS), IEEE; 2022, p. 419–23. <https://doi.org/10.1109/ICSCDS53736.2022.9760858>.
- [26] Battista P, Salvatore C, Berlingeri M, Cerasa A, Castiglioni I. Artificial intelligence and neuropsychological measures: The case of Alzheimer's disease. *Neurosci Biobehav Rev* 2020;114:211–28. <https://doi.org/10.1016/j.neubiorev.2020.04.026>.
- [27] Arroyo-Anlló EM, Díaz-Marta JP, Chamorro Sánchez J. Técnicas de rehabilitación neuropsicológica en demencias: hacia la ciber-rehabilitación neuropsicológica. *Pensamiento Psicológico* 2012;10:107–27.
- [28] Lubrini G. Estimulación Cognitiva. Barcelona: FUOC; 2009.
- [29] Lanfranco G, Manriquez-Navarro R, Avello G L, Canales-Johnson A. Evaluación de la enfermedad de Alzheimer en etapa temprana: biomarcadores y pruebas neuropsicológicas. *Revista Médica de Chile* 2012;140:1191–200.
- [30] Caja López C. Guía de Práctica Clínica sobre la Atención Integral a las Personas con Enfermedad de Alzheimer y otras Demencias. Madrid: Ministerio de Ciencia e Innovación; 2010.
- [31] Jurczynska P, Ortiz E, M., Miguel LDS De, C., Llanero Luque M, et al. Impacto social de la EA y otras demencias. Actualización. Madrid: Informe de la Fundación del Cerebro; 2017.

- [32] Fabrizio C, Termine A, Caltagirone C, Sancesario G. Artificial Intelligence for Alzheimer's Disease: Promise or Challenge? *Diagnostics* 2021;11:1473. <https://doi.org/10.3390/diagnostics11081473>.
- [33] Lee D, Yoon SN. Application of Artificial Intelligence-Based Technologies in the Healthcare Industry: Opportunities and Challenges. *Int J Environ Res Public Health* 2021;18:271. <https://doi.org/10.3390/ijerph18010271>.
- [34] Rojas-Valles EU, Sánchez-Godínez JY, Bautista-González AI, Garduño-Torres AE, González Y. Biomarcadores exosomales: nuevas perspectivas para el diagnóstico y pronóstico de las enfermedades respiratorias. *NCT Neumología y Cirugía de Tórax* 2021;80:269–85. <https://doi.org/10.35366/103452>.
- [35] Abajian A, Murali N, Savic LJ, Laage-Gaupp FM, Nezami N, Duncan JS, et al. Predicting Treatment Response to Intra-arterial Therapies for Hepatocellular Carcinoma with the Use of Supervised Machine Learning—An Artificial Intelligence Concept. *Journal of Vascular and Interventional Radiology* 2018;29:850-857.e1. <https://doi.org/10.1016/j.jvir.2018.01.769>.
- [36] Bruna O, Roig T, Puyuelo M, Junqué C, Ruano Á. *Rehabilitación neuropsicológica: intervención y práctica clínica*. Barcelona: Elsevier/Masson; 2011.
- [37] King A, Bodi I, Troakes C. The Neuropathological Diagnosis of Alzheimer's Disease—The Challenges of Pathological Mimics and Concomitant Pathology. *Brain Sci* 2020;10:479. <https://doi.org/10.3390/brainsci10080479>.
- [38] Cui H, Su S, Cao Y, Ma C, Qiu W. The Altered Anatomical Distribution of ACE2 in the Brain With Alzheimer's Disease Pathology. *Front Cell Dev Biol* 2021;9. <https://doi.org/10.3389/fcell.2021.684874>.
- [39] Trejo-Lopez JA, Yachnis AT, Prokop S. Neuropathology of Alzheimer's Disease. *Neurotherapeutics* 2022;19:173–85. <https://doi.org/10.1007/s13311-021-01146-y>.
- [40] Rivera MM, González MM, Catalayud M, Piñeira P. Biomarcadores para la Enfermedad de Alzheimer y otras demencias degenerativas. *Archivos de Medicina* 2008;4.
- [41] Sharma P, Sharma A, Fayaz F, Wakode S, Pottoo FH. Biological Signatures of Alzheimer's Disease. *Curr Top Med Chem* 2020;20:770–81. <https://doi.org/10.2174/1568026620666200228095553>.
- [42] Srivastava S, Ahmad R, Khare SK. Alzheimer's disease and its treatment by different approaches: A review. *Eur J Med Chem* 2021;216:113320. <https://doi.org/10.1016/j.ejmech.2021.113320>.

- [43] Bracko O, Cruz Hernández JC, Park L, Nishimura N, Schaffer CB. Causes and consequences of baseline cerebral blood flow reductions in Alzheimer's disease. *Journal of Cerebral Blood Flow & Metabolism* 2021;41:1501–16. <https://doi.org/10.1177/0271678X20982383>.
- [44] Martínez J, Vilches MC. Versión española del cuestionario de Yesavage abreviado para el despistaje de depresión en mayores de 65 años: adaptación y validación. *MEDIFAM* 2002;12:620–30.
- [45] Rahman MA, Rahman MS, Uddin MJ, Mamum-Or-Rashid ANM, Pang M-G, Rhim H. Emerging risk of environmental factors: insight mechanisms of Alzheimer's diseases. *Environmental Science and Pollution Research* 2020;27:44659–72. <https://doi.org/10.1007/s11356-020-08243-z>.
- [46] Kamer AR, Craig RG, Niederman R, Fortea J, de Leon MJ. Periodontal disease as a possible cause for Alzheimer's disease. *Periodontol 2000* 2020;83:242–71. <https://doi.org/10.1111/prd.12327>.
- [47] Breijyeh Z, Karaman R. Comprehensive Review on Alzheimer's Disease: Causes and Treatment. *Molecules* 2020;25:5789. <https://doi.org/10.3390/molecules25245789>.
- [48] Tanveer M, Richhariya B, Khan RU, Rashid AH, Khanna P, Prasad M, et al. Machine Learning Techniques for the Diagnosis of Alzheimer's Disease. *ACM Transactions on Multimedia Computing, Communications, and Applications* 2020;16:1–35. <https://doi.org/10.1145/3344998>.
- [49] A A, M P, Hamdi M, Bourouis S, Rastislav K, Mohamed F. Evaluation of Neuro Images for the Diagnosis of Alzheimer's Disease Using Deep Learning Neural Network. *Front Public Health* 2022;10. <https://doi.org/10.3389/fpubh.2022.834032>.
- [50] Bilal M, Barani M, Sabir F, Rahdar A, Kyzas GZ. Nanomaterials for the treatment and diagnosis of Alzheimer's disease: An overview. *NanoImpact* 2020;20:100251. <https://doi.org/10.1016/j.impact.2020.100251>.
- [51] Dubois B, Villain N, Frisoni GB, Rabinovici GD, Sabbagh M, Cappa S, et al. Clinical diagnosis of Alzheimer's disease: recommendations of the International Working Group. *Lancet Neurol* 2021;20:484–96. [https://doi.org/10.1016/S1474-4422\(21\)00066-1](https://doi.org/10.1016/S1474-4422(21)00066-1).
- [52] Pandey BP, Wardle M. The non-ideal finite Larmor radius effect in the solar atmosphere. *Mon Not R Astron Soc* 2022;513:1842–57. <https://doi.org/10.1093/mnras/stac1028>.

- [53] Crestetto A, Crouseilles N, Prel D. Multiscale Numerical Schemes for the Collisional Vlasov Equation in the Finite Larmor Radius Approximation Regime. *Multiscale Modeling & Simulation* 2023;21:1210–36. <https://doi.org/10.1137/22M1496839>.
- [54] Park S, Jung SM, Lee MB, Rhee HY, Ryu C-W, Cho AR, et al. Application of High-Frequency Conductivity Map Using MRI to Evaluate It in the Brain of Alzheimer's Disease Patients. *Front Neurol* 2022;13. <https://doi.org/10.3389/fneur.2022.872878>.
- [55] Nielsen RB, Parbo P, Ismail R, Dalby R, Tietze A, Brændgaard H, et al. Impaired perfusion and capillary dysfunction in prodromal Alzheimer's disease. *Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring* 2020;12. <https://doi.org/10.1002/dad2.12032>.
- [56] Guo X-Y, Kwon HJ, Rhee HY, Park S, Cho AR, Ryu C-W, et al. Microvascular morphology alteration using relaxation rate change with gadolinium-based magnetic resonance imaging contrast agent in patients with Alzheimer's disease. *Quant Imaging Med Surg* 2023;13:1–16. <https://doi.org/10.21037/qims-22-524>.
- [57] Madsen LS, Parbo P, Ismail R, Gottrup H, Østergaard L, Brooks DJ, et al. Capillary dysfunction correlates with cortical amyloid load in early Alzheimer's disease. *Neurobiol Aging* 2023;123:1–9. <https://doi.org/10.1016/j.neurobiolaging.2022.12.006>.
- [58] Kattenborn T, Leitloff J, Schiefer F, Hinz S. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 2021;173:24–49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>.
- [59] Aracena C, Villena F, Arias F, Dunstan J. Aplicaciones de aprendizaje automático en salud. *Revista Médica Clínica Las Condes* 2022;33:568–75. <https://doi.org/10.1016/j.rmcl.2022.10.001>.
- [60] De-La-Hoz EJ, De-La-Hoz EJ, Fontalvo TJ. Metodología de Aprendizaje Automático para la Clasificación y Predicción de Usuarios en Ambientes Virtuales de Educación. *Información Tecnológica* 2019;30:247–54. <https://doi.org/10.4067/S0718-07642019000100247>.
- [61] Álvarez Vega M, Quirós Mora LM, Cortés Badilla MV. Inteligencia artificial y aprendizaje automático en medicina. *Revista Medica Sinergia* 2020;5:e557. <https://doi.org/10.31434/rms.v5i8.557>.
- [62] Díaz-Ramírez J. Aprendizaje Automático y Aprendizaje Profundo. *Ingeniare Revista Chilena de Ingeniería* 2021;29:180–1. <https://doi.org/10.4067/S0718-33052021000200180>.

- [63] Muñoz González V, Gómez-López M, Granero-Gallegos A. Relación entre la satisfacción con las etapas de demencia de la EA de Educación Física, su importancia y utilidad y la intención de práctica del alumnado de Educación Secundaria Obligatoria. *Revista Complutense de Educación* 2019;30. <https://doi.org/10.5209/RCED.57678>.
- [64] Zhinin-Vera L, Zhiminaicela-Cabrera J, Pretel E, Suárez P, Chang O, Castro FA, et al. Artificial Vision Technique to Detect and Classify Cocoa Beans, 2023, p. 217–28. [https://doi.org/10.1007/978-3-031-43078-7\\_18](https://doi.org/10.1007/978-3-031-43078-7_18).
- [65] Ahlawat S, Choudhary A, Nayyar A, Singh S, Yoon B. Improved Handwritten Digit Recognition Using Convolutional Neural Networks (CNN). *Sensors* 2020;20:3344. <https://doi.org/10.3390/s20123344>.
- [66] Desai M, Shah M. An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN). *Clinical EHealth* 2021;4:1–11. <https://doi.org/10.1016/j.ceh.2020.11.002>.
- [67] Zhang Q, Xiao J, Tian C, Chun-Wei Lin J, Zhang S. A robust deformed convolutional neural network (CNN) for image denoising. *CAAI Trans Intell Technol* 2023;8:331–42. <https://doi.org/10.1049/cit2.12110>.
- [68] Rahman T, Chowdhury MEH, Khandakar A, Islam KR, Islam KF, Mahbub ZB, et al. Transfer Learning with Deep Convolutional Neural Network (CNN) for Pneumonia Detection Using Chest X-ray. *Applied Sciences* 2020;10:3233. <https://doi.org/10.3390/app10093233>.
- [69] Lu J, Tan L, Jiang H. Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification. *Agriculture* 2021;11:707. <https://doi.org/10.3390/agriculture11080707>.
- [70] Liu Y, Pu H, Sun D-W. Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices. *Trends Food Sci Technol* 2021;113:193–204. <https://doi.org/10.1016/j.tifs.2021.04.042>.
- [71] Al-Adhaileh MH. Diagnosis and classification of Alzheimer’s disease by using a convolution neural network algorithm. *Soft Comput* 2022;26:7751–62. <https://doi.org/10.1007/s00500-022-06762-0>.
- [72] Heenaye-Mamode Khan M, Boodoo-Jahangeer N, Dullull W, Nathire S, Gao X, Sinha GR, et al. Multi- class classification of breast cancer abnormalities using Deep Convolutional Neural Network (CNN). *PLoS One* 2021;16:e0256500. <https://doi.org/10.1371/journal.pone.0256500>.

- [73] Amini M, Pedram MM, Moradi A, Ouchani M. Diagnosis of Alzheimer's Disease Severity with fMRI Images Using Robust Multitask Feature Extraction Method and Convolutional Neural Network (CNN). *Comput Math Methods Med* 2021;2021:1–15. <https://doi.org/10.1155/2021/5514839>.
- [74] Mehmood A, Maqsood M, Bashir M, Shuyuan Y. A Deep Siamese Convolution Neural Network for Multi-Class Classification of Alzheimer Disease. *Brain Sci* 2020;10:84. <https://doi.org/10.3390/brainsci10020084>.
- [75] Wen J, Thibeau-Sutre E, Diaz-Melo M, Samper-González J, Routier A, Bottani S, et al. Convolutional neural networks for classification of Alzheimer's disease: Overview and reproducible evaluation. *Med Image Anal* 2020;63:101694. <https://doi.org/10.1016/j.media.2020.101694>.
- [76] Fu'adah YN, Wijayanto I, Pratiwi NKC, Taliningsih FF, Rizal S, Pramudito MA. Automated Classification of Alzheimer's Disease Based on MRI Image Processing using Convolutional Neural Network (CNN) with AlexNet Architecture. *J Phys Conf Ser* 2021;1844:012020. <https://doi.org/10.1088/1742-6596/1844/1/012020>.
- [77] Segovia-García N. Percepción y uso de los chatbots entre estudiantes de posgrado online: Un estudio exploratorio. *Revista de Investigación En Educación* 2023;21:335–49. <https://doi.org/10.35869/reined.v21i3.4974>.
- [78] Duarte ES, De Moura FS, De Oliveira LP, Garcia LF. Aspectos bioéticos da utilização de sistemas de inteligência artificial no campo da saúde: um estudo exploratório. *Rev Bioet Derecho* 2023;263–85. <https://doi.org/10.1344/rbd2023.57.35146>.
- [79] Gómez-Acosta A, Vinaccia-Alpi S, Sierra-Barón W. Propiedades psicométricas de la escala de salud mental positiva en jóvenes colombianos: un estudio exploratorio. *CES Psicología* 2020;13:102–12. <https://doi.org/10.21615/cesp.13.2.7>.
- [80] Chávez Orovio LE, Delgado Togra DS, Lozana Astudillo DE, Astudillo García ML, Alcivar Mora AE. Desempeño de algoritmos de inteligencia artificial (IA) en problemas cognitivos con enfermos de alzheimer (EA). *Ciencia Latina Revista Científica Multidisciplinar* 2023;7:768–82. [https://doi.org/10.37811/cl\\_rcm.v7i2.5358](https://doi.org/10.37811/cl_rcm.v7i2.5358).
- [81] Wang Y-Y, Wang Y-S. Development and validation of an artificial intelligence anxiety scale: an initial application in predicting motivated learning behavior. *Interactive Learning Environments* 2022;30:619–34. <https://doi.org/10.1080/10494820.2019.1674887>.

- [82] Damerji H, Salimi A. Mediating effect of use perceptions on technology readiness and adoption of artificial intelligence in accounting. *Accounting Education* 2021;30:107–30. <https://doi.org/10.1080/09639284.2021.1872035>.
- [83] Giuggioli G, Pellegrini MM. Artificial intelligence as an enabler for entrepreneurs: a systematic literature review and an agenda for future research. *International Journal of Entrepreneurial Behavior & Research* 2023;29:816–37. <https://doi.org/10.1108/IJEER-05-2021-0426>.
- [84] Ramos Vidal I. El análisis de redes sociales en la investigación en salud pública: una revisión sistemática. *Revista de Salud Pública* 2019;21:109–14. <https://doi.org/10.15446/rsap.v21n1.68530>.
- [85] Guisasola Aranzabal J, Ametller J, Zuza K. Investigación basada en el diseño de Secuencias de Enseñanza-Aprendizaje: una línea de investigación emergente en Enseñanza de las Ciencias. *Revista Eureka Sobre Enseñanza y Divulgación de Las Ciencias* 2021;18:1–18. [https://doi.org/10.25267/Rev\\_Eureka\\_ensen\\_divulg\\_cienc.2021.v18.i1.1801](https://doi.org/10.25267/Rev_Eureka_ensen_divulg_cienc.2021.v18.i1.1801).
- [86] Yousefi Nooraie R, Sale JEM, Marin A, Ross LE. Social Network Analysis: An Example of Fusion Between Quantitative and Qualitative Methods. *J Mix Methods Res* 2020;14:110–24. <https://doi.org/10.1177/1558689818804060>.
- [87] Ataro G. Methods, methodological challenges and lesson learned from phenomenological study about OSCE experience: Overview of paradigm-driven qualitative approach in medical education. *Annals of Medicine and Surgery* 2020;49:19–23. <https://doi.org/10.1016/j.amsu.2019.11.013>.
- [88] Rott B. Inductive and deductive justification of knowledge: epistemological beliefs and critical thinking at the beginning of studying mathematics. *Educational Studies in Mathematics* 2021;106:117–32. <https://doi.org/10.1007/s10649-020-10004-1>.
- [89] Kyngäs H. *Qualitative Research and Content Analysis. The Application of Content Analysis in Nursing Science Research*, Cham: Springer International Publishing; 2020, p. 3–11. [https://doi.org/10.1007/978-3-030-30199-6\\_1](https://doi.org/10.1007/978-3-030-30199-6_1).
- [90] Proudfoot K. Inductive/Deductive Hybrid Thematic Analysis in Mixed Methods Research. *J Mix Methods Res* 2023;17:308–26. <https://doi.org/10.1177/15586898221126816>.
- [91] Pontello V, Beckmann H, Lanquillon C. Meta-learning approach for implementation of AI methods in the context of CRISP-DM with case studies from master data management. 2021 IEEE International Conference on Engineering, Technology and

- Innovation (ICE/ITMC), IEEE; 2021, p. 1–9.  
<https://doi.org/10.1109/ICE/ITMC52061.2021.9570265>.
- [92] Al Gharbi S, Al-Majed A, Abdulraheem A, Patil S, Elkatatny S. Using Data-Mining CRISP-DM Methodology to Predict Drilling Troubles in Real-Time. Day 1 Tue, June 08, 2021, SPE; 2021. <https://doi.org/10.2118/201026-MS>.
- [93] Ayele WY. Adapting CRISP-DM for Idea Mining. International Journal of Advanced Computer Science and Applications 2020;11. <https://doi.org/10.14569/IJACSA.2020.0110603>.
- [94] Bokrantz J, Subramaniyan M, Skoogh A. Realising the promises of artificial intelligence in manufacturing by enhancing CRISP-DM. Production Planning & Control 2023:1–21. <https://doi.org/10.1080/09537287.2023.2234882>.
- [95] Maataoui S, Bencheikh G, Bencheikh G. Predictive Maintenance in the Industrial Sector: A CRISP-DM Approach for Developing Accurate Machine Failure Prediction Models. 2023 Fifth International Conference on Advances in Computational Tools for Engineering Applications (ACTEA), IEEE; 2023, p. 223–7. <https://doi.org/10.1109/ACTEA58025.2023.10193983>.
- [96] Parra-Sánchez JS. Potencialidades de la Inteligencia Artificial en Educación Superior: Un Enfoque desde la Personalización. Revista Tecnológica-Educativa Docentes 2022;14:19–27. <https://doi.org/10.37843/rted.v14i1.296>.

## ANEXOS

ARTÍCULOS	TÉCNICAS	RESULTADOS
Impacto del Alzheimer y aplicación de IA - Falcón, 2020	Revisión bibliográfica del uso de resonancia magnética y aprendizaje profundo para la detección de etapas de demencia de la EA de AD	Propuesta de aplicación de IA para detección de etapas de demencia de la EA mediante aprendizaje profundo
Revisión de IA en el AD - de la Fuente Garcia et al., 2020	Procesamiento de lenguaje natural y análisis de voz mediante pruebas TAVEC para la clasificación automática de pacientes	Aumentas en el monitoreo del AD a través de la IA mediante la automatización de análisis de pruebas TAVEC
Modelo explicativo de AD - El-Sappagh et al., 2021	Multicapa y multimodalidad en la detección mediante modelo de dos capas con bosque aleatorio (RF) como algoritmo clasificador.	Mayor claridad y confiabilidad en los diagnósticos obtiene una precisión mediante validación cruzada del 93,95%. Resultado no solos preciso sino también confiable el modelo de clasificación.
Promesas y desafíos de la IA en AD - Fabrizio et al., 2021	Herramientas de diagnóstico asistido por computadora mediante el análisis de IA de completos grupos de Big Data para aumentar el entendimiento de la AD	Identificación de desafíos en la implementación análisis y diagnostico mediante IA con las cuales se puede respaldar potencialmente las practicas clínicas y predicción de riesgo.
Medidas neuropsicológicas y AD - Battista et al., 2020	Metaanálisis de la contribución de la aplicación de ML para clasificación y medida neuropsicológicas para la automatización de pacientes con deterioro cognitivo leve.	Alta precisión en la clasificación mediante ML aplicada a medidas neuropsicológicas permite obtener categorías relevantes de pruebas maximiza la clasificación.

Revisión de IA en el análisis de MRI - Frizzell et al., 2022	Estudio de IA que utilizan imágenes de resonancia magnética para investigar el deterioro cognitivo y la demencia de AD mediante criterios PROBAST.	Aumenta significativa en la precisión del diagnóstico para capturar y cuantificar múltiples cambios sutiles en resonancias, para aumentar la calidad de diagnóstico.
Diagnóstico de etapas de demencia de la EA de AD - Sudar et al., 2022	Aplicación de inteligencia artificial mediante método de propagación con técnicas de LRP, algoritmos vvg-16 y CNN.	Mayor confiabilidad y comprensión de los resultados para conseguir una explicación de análisis.
IA en medicina personalizada - Silva-Spínola et al., 2022	Uso de IA para análisis de enormes cantidades de datos para comprender la dinamica paciente enfermedad.	Traducción rápida de hallazgos a terapias personalizadas con aplicaciones en campo de biomarcadores y fármacos.
IA para biomarcadores en AD - Winchester et al., 2023	Aplicación de IA en el descubrimiento de biomarcadores mediante aprendizaje ML	Identificación de biomarcadores relevantes mediante datos multimodales enriquecidos en la IA e innovación corporativa.
IA en detección de biomarcadores – Rojas et al., 2021	Análisis de imágenes de Tomografía por Emisión de Positrones (PET) y biomarcadores séricos mediante modelos de predicción ML	Identificación eficiente de biomarcadores claves mediante IA
IA en predicción de respuesta a terapias - Abajian et al., 2018	Análisis de datos clínicos y moleculares para comprender modelos de regresión logística LR y de bosque aleatorio RF, medidos mediante validación cruzada.	Aumenta en la predicción de la respuesta a tratamientos identificación se pueden prevenir mediante el uso de técnica de IA y ML.

**Anexo 1. Resumen de las investigaciones, técnicas y resultados existentes.**

```
[ ] def extract_feature(dir_path):
    img = mpimg.imread(dir_path)
    img = img / 255.0 # Normalizar valores de pixel
    img = resize(img, (128, 128, 3)) # Reducir resolución de todas las imágenes a 128x128
    img = np.reshape(img, (128, 384)) # Aplanar la imagen para PCA
    return img
```

```
[ ] non_ALZ = [extract_feature(filename) for filename in tqdm(non)]
vmild_ALZ = [extract_feature(filename) for filename in tqdm(very_mild)]
mild_ALZ = [extract_feature(filename) for filename in tqdm(mild)]
moderate_ALZ = [extract_feature(filename) for filename in tqdm(moderate)]
ALZ = vmild_ALZ + mild_ALZ + moderate_ALZ
print('Todos los datos extraídos y combinados')

# Preparación para PCA
all_data = np.concatenate((np.array(non_ALZ), np.array(ALZ)))
all_data = all_data.reshape(all_data.shape[0], np.product(all_data.shape[1:]))
scaler = StandardScaler()
X = scaler.fit_transform(all_data)
y = [0] * len(non_ALZ) + [1] * len(ALZ)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2)
print('Datos escalados y divididos')

# PCA
pca = decomposition.PCA(600)
X_train_proj = pca.fit_transform(X_train)
var_cumulative = np.cumsum(pca.explained_variance_ratio_) * 100 # Convertir a porcentaje
k = np.argmax(var_cumulative > 80)
print(f"Número de componentes que explican el 80% de la varianza: {k}")

# Visualización de la varianza explicada acumulativa
plt.figure(figsize=[10,5])
plt.title('Varianza explicada acumulativa por componentes principales')
plt.ylabel('Varianza explicada acumulativa')
plt.xlabel('Componentes principales')
plt.axvline(x=k, color="k", linestyle="--")
plt.axhline(y=80, color="r", linestyle="--")
plt.plot(var_cumulative)
plt.show()
```

## Anexo 2. Descripción de algoritmo metodología PCA.

```
[ ] from sklearn import svm
    from sklearn.metrics import accuracy_score, precision_score, recall_score, f1_score, confusion_matrix

    # Crear y entrenar el modelo SVM con un kernel lineal
    clf = svm.SVC(kernel='linear')
    clf.fit(train_x, train_y)

    # Función para evaluar y imprimir las métricas del modelo
    def evaluate_model(predictions, truths, dataset_type="Training"):
        print(f"--- {dataset_type} Data ---")
        print("Accuracy :", accuracy_score(truths, predictions))
        print("Precision:", precision_score(truths, predictions))
        print("Recall   :", recall_score(truths, predictions))
        print("F1 Score :", f1_score(truths, predictions))
        print("Confusion Matrix:\n", confusion_matrix(truths, predictions))

    # Evaluar el rendimiento del modelo en el conjunto de entrenamiento
    y_pred_train = clf.predict(train_x)
    evaluate_model(y_pred_train, train_y, "Training")

    # Evaluar el rendimiento del modelo en el conjunto de prueba
    y_pred_test = clf.predict(test_x)
    evaluate_model(y_pred_test, test_y, "Testing")
```

### Anexo 3. Descripción del algoritmo modelo SVM KernelLineal.

```
[ ] from sklearn import svm
    from sklearn.metrics import accuracy_score, precision_score, recall_score, f1_score, confusion_matrix

    # Entrenar un modelo SVM utilizando un kernel polinomial de grado 2
    clf_poly = svm.SVC(kernel='poly', degree=2)
    clf_poly.fit(train_x, train_y)

    # Función para evaluar y imprimir las métricas del modelo, reutiliza la función 'evaluate_model' definida previamente
    def evaluate_model(model, X, y, dataset_type="Training"):
        predictions = model.predict(X)
        print(f"--- {dataset_type} Data ---")
        print("Accuracy :", accuracy_score(y, predictions))
        print("Precision:", precision_score(y, predictions))
        print("Recall   :", recall_score(y, predictions))
        print("F1 Score :", f1_score(y, predictions))
        print("Confusion Matrix:\n", confusion_matrix(y, predictions))

    # Evaluar el rendimiento del modelo en el conjunto de entrenamiento
    evaluate_model(clf_poly, train_x, train_y, "Training")

    # Evaluar el rendimiento del modelo en el conjunto de prueba
    evaluate_model(clf_poly, test_x, test_y, "Testing")
```

### Anexo 4. Modelo SVM Kernelpolinomial.

```
[ ] from sklearn import svm
    from sklearn.metrics import accuracy_score, precision_score, recall_score, f1_score, confusion_matrix

    # Entrenar un modelo SVM utilizando un kernel RBF
    clf_rbf = svm.SVC(kernel='rbf')
    clf_rbf.fit(train_x, train_y)

    # Función para evaluar y imprimir las métricas del modelo, reutiliza la función 'evaluate_model' definida previamente
    def evaluate_model(model, X, y, dataset_type="Training"):
        predictions = model.predict(X)
        print(f"--- {dataset_type} Data ---")
        print("Accuracy :", accuracy_score(y, predictions))
        print("Precision:", precision_score(y, predictions))
        print("Recall   :", recall_score(y, predictions))
        print("F1 Score :", f1_score(y, predictions))
        print("Confusion Matrix:\n", confusion_matrix(y, predictions))

    # Evaluar el rendimiento del modelo en el conjunto de entrenamiento
    evaluate_model(clf_rbf, train_x, train_y, "Training")

    # Evaluar el rendimiento del modelo en el conjunto de prueba
    evaluate_model(clf_rbf, test_x, test_y, "Testing")
```

### Anexo 5. Descripción del algoritmo Kernel rbf.

```
[ ] def extract_feature(dir_path):  
    img = mpimg.imread(dir_path)  
    img = img / 255.0 # Normalizar valores de pixel  
    img = resize(img, (128, 128, 3)) # Reducir resolución de todas las imágenes a 128x128  
    img = np.reshape(img, (128, 384)) # Aplanar la imagen para PCA  
    return img
```

**Anexo 6.** Código fase de preparación de datos.