

Universidad Nacional Mayor de San Marcos



Facultad de Ingeniería de Sistemas e Informática

Escuela Profesional de Ingeniería de Sistemas

Sistema basado en Deep Learning para detectar la enfermedad del Alzheimer mediante imágenes médicas.

TRABAJO DE TESIS (MET)

AUTORES

Kevin Renzo, Pantoja Pimentel

Sebastian, Quintanilla Jaimes

ASESOR

Dr. Hugo Vega Huerta

Lima, Perú

2023

Índice

Pág.

Índice

1. Introducción.....	5
2. Capítulo I: Visión del Proyecto.....	6
2.1. Antecedentes.....	6
2.2. Problema.....	8
2.2.1. Realidad Problemática.....	8
2.2.2. Descripción del Problema.....	8
2.3. Objetivos de la investigación.....	10
2.3.1. Marco Lógico.....	10
2.3.1.1. Árbol del Problema.....	10
2.3.1.2. Árbol de Objetivos.....	10
2.3.2. Objetivo General.....	10
2.3.3. Objetivos Específicos.....	11
2.4. Justificación.....	11
2.5. Importancia.....	12
2.6. Motivación.....	13
3. Capítulo II: Marco Teórico.....	14
3.1. Alzheimer.....	14
3.1.1. Definición.....	14
3.2. Síntomas.....	14
3.3. Tratamiento.....	14
3.4. Deep Learning.....	15
3.5. Resonancia Magnética.....	15
4. Capítulo III: Estado del arte.....	16
4.1. Artículos.....	16
4.1.1. Alzheimer's disease classification using pre-trained deep networks(Shanmugam et al., 2022).....	16
4.1.2. An Alzheimer's disease classification method using fusion of features from brain Magnetic Resonance Image transforms and deep convolutional networks(Asgharzadeh-Bonab et al., 2023).....	19
4.1.3. A systematic review on machine learning and deep learning techniques in the effective diagnosis of Alzheimer's disease (Deep Arya et al., 2022).....	21
4.1.4. An MRI-based deep learning approach for accurate detection of Alzheimer's disease (EL-Geneedy et al., 2023).....	23
4.1.5. Medical image classification for Alzheimer's using a deep learning approach (Bamber & Vishvakarma, 2023).....	26
4.1.6. Alzheimer's disease diagnosis and classification using deep learning techniques (Al Shehri, 2022).....	27
4.1.7. Multimodal deep learning models for early detection of Alzheimer's disease stage (Venugopalan et al., 2021).....	30
4.1.8. A Transfer Learning Approach for Early Diagnosis of Alzheimer's Disease on MRI Images (Mehmood et al., 2021).....	32
4.1.9. Four-way classification of Alzheimer's disease using deep Siamese convolutional neural network with triplet-loss function (Hajamohideen et al., 2023).....	33

4.1.10. Early Detection of Alzheimer's Disease Using Magnetic Resonance Imaging: A Novel Approach Combining Convolutional Neural Networks and Ensemble Learning (Pan et al., 2020).....	36
4.1.11. Early Multi-model and multi-slice ensemble learning architecture based on 2D convolutional neural networks for Alzheimer's disease diagnosis (Kang et al., 2021).....	37
4.1.12. Machine Learning and Deep Learning Approaches for Brain Disease Diagnosis: Principles and Recent Advances (Khan et al., 2021).....	39
5. Capítulo IV: Modelado de Negocio.....	41
5.1. Reglas del Negocio.....	41
5.2. Caso de Uso del Negocio.....	42
5.2.1. Diagrama de Casos de Uso del Negocio.....	42
5.2.1.1. Actores del Negocio.....	42
5.2.1.2. Casos de Uso del Negocio.....	43
5.2.2. Especificación de casos de uso de negocio.....	43
6. Capítulo V: Requerimientos del proyecto.....	49
6.1. Funcionales.....	49
6.2. No funcionales.....	49
6.3. Casos de uso del sistema.....	50
6.4. Prototipo.....	50
7. Capítulo VI: Arquitectura.....	50
7.1. Modelo conceptual.....	50
7.2. Arquitectura lógica.....	50
7.3. Arquitectura Tecnológica.....	51
7.4. Arquitectura física.....	52
7.5. Vistas de Casos de Uso más Significativos.....	53
7.6. Modelo de despliegue.....	53

Acrónimos

- OMS: Organización Mundial de la Salud
- INEI: Instituto Nacional de Estadística e Informática
- Minsa: Ministerio de Salud del Perú

1. Introducción

2. Capítulo I: Visión del Proyecto

Con el propósito de enfocar adecuadamente el estudio abordado en esta tesis y tener una comprensión precisa para lograr los objetivos establecidos en la detección de la enfermedad del Alzheimer, es esencial familiarizarse con las investigaciones previas y sus conclusiones. Esto permitirá identificar y analizar los aspectos que resultarán beneficiosos y contribuirán significativamente a la ejecución de la investigación que se presenta a continuación.

2.1. Antecedentes

Las enfermedades neurológicas en todo el mundo están en aumento lo que conlleva a un aumento en costo en atención médica y también en una disminución en la calidad de vida de los pacientes(Dipietro et al., 2023).

Son afecciones que afectan a las células del cerebro llamadas neuronas y uno de los tipos más comunes de las enfermedades o trastornos degenerativos es la enfermedad del Alzheimer(Huang et al., 2023).

Según (OPS) la enfermedad del Alzheimer es la forma más común de demencia y contribuye al 60-70% de los casos, no es parte normal del envejecimiento y no afecta exclusivamente a las personas mayores.

La detección del Alzheimer ha sido ampliamente estudiada, e implica varios problemas y desafíos.

(Helaly et al., 2022) Adopta un enfoque de aprendizaje profundo utilizando redes neuronales convolucionales (CNN) para abordar la detección de la enfermedad de Alzheimer (EA). Se realizan cuatro etapas de clasificación multiclase en el espectro de EA. Además, se llevan a cabo clasificaciones binarias de imágenes médicas entre las etapas de EA en pares separados. Dos

métodos se utilizan para la clasificación de imágenes médicas y la detección de la EA.

(Yiğit & Işık, 2020) Se centró en utilizar biomarcadores de neuroimagen para diagnosticar la enfermedad de Alzheimer y la demencia de manera no invasiva. Se emplearon imágenes de resonancia magnética estructural (RM) del cerebro como entrada para un modelo de predicción. Se implementaron modelos de redes neuronales convolucionales (CNN) que utilizaron las imágenes cerebrales preprocesadas, y se realizó el entrenamiento y la evaluación de estos modelos CNN utilizando dos conjuntos de datos diferentes.

(Jaiswal & Sadana, 2022) Se enfocan en la aplicación de técnicas de aprendizaje profundo en imágenes de resonancia magnética estructural (RM) para el diagnóstico de enfermedades. Los autores proponen un nuevo enfoque que involucra el uso de transformadores de cuello de botella basados en autoatención, combinados con un minimizador consciente de la nitidez. El objetivo principal de este enfoque es la detección temprana de la enfermedad de Alzheimer.

(Ma et al., 2023) Introduce un nuevo modelo de conjunto amplio y profundo basado en BLS para la detección temprana de la enfermedad de Alzheimer. Se emplea un conjunto de datos de imágenes de resonancia magnética de la Iniciativa de Neuroimagen de la Enfermedad de Alzheimer (ADNI) para entrenar el modelo, y posteriormente se compara el rendimiento del modelo propuesto con trabajos anteriores y diagnósticos médicos, el modelo propuesto

no necesita el proceso de pre-entrenamiento de su módulo de profundidad, lo que reduce en gran medida el tiempo de entrenamiento y la dependencia del hardware.

2.2. Problema

2.2.1. Realidad Problemática

Enfrentar los considerables desafíos vinculados con la detección temprana y precisa de la enfermedad del Alzheimer en la población peruana es un proceso de gran complejidad. A pesar del incremento en la frecuencia de esta afección, más de 200 mil personas mayores de 60 años según una publicación del MINSA del año 2019, es común encontrar una limitada disponibilidad de recursos médicos altamente especializados y la experiencia necesaria para llevar a cabo el diagnóstico en diversas áreas del país, podemos evidenciar estas limitaciones ya que según una publicación del año 2017 el Ministerio de Salud brinda servicios especializados en salud mental a 3,309 adultos mayores que padecen de Alzheimer en el país. Esta situación conlleva a retrasos en la fase de diagnóstico y tratamiento, lo cual afecta negativamente la calidad de vida tanto de los pacientes como de sus seres queridos. Sumado a ello, las restricciones geográficas y económicas obstaculizan el acceso a evaluaciones médicas de expertise, llevando a una porción significativa de la población a carecer de opciones para una detección temprana.

2.2.2. Descripción del Problema

El problema de investigación se centra en la detección de la enfermedad del Alzheimer. Esta enfermedad afecta a millones de


personas en el mundo y en el caso peruano hay cientos de miles de adultos mayores que padecen de esta forma de demencia. En este marco identificamos las El número de muertes por EA aumentó entre 2000 y 2017 (145%). Además, Alto porcentaje de personas de 65 años o más tienen Alzheimer (10.7%) por lo cual se tiene especial preocupación por la población mayor a 65 años que aumentan de forma exponencial hasta los 85 años. Al igual se observa que se tiene una complejidad en la Interpretación de Imágenes de Alzheimer debido a las Variaciones Individuales por la cantidad de casos distintos que se tienen que atender.

La detección tardía o no detección de la enfermedad del Alzheimer conlleva a un diagnóstico tardío, dificultades en el tratamiento y Descoordinación en la atención médica, pérdida de datos críticos y dificultades en la toma de decisiones, lo cual afecta negativamente la calidad de vida tanto de los pacientes como de sus seres queridos. Sumado a ello, se produce un retraso en la detección temprana y decisiones de tratamiento menos precisas.


2.3. Objetivos de la investigación

2.3.1. Marco Lógico

2.3.1.1. Árbol del Problema



2.3.1.2. Árbol de Objetivos



2.3.2. Objetivo General

Diseñar e implementar un sistema de inteligencia artificial usando Deep Learning para detectar la enfermedad del Alzheimer mediante imágenes

médicas con el fin de [Detectar la Enfermedad del Alzheimer Mediante Imágenes Médicas](#) y en consecuencia brindar al paciente la oportunidad de planificar el futuro y tomar decisiones informadas sobre su atención médica.

2.3.3. Objetivos Específicos

- Desarrollar un modelo de deep learning altamente preciso y robusto para la detección multietapa de la enfermedad del alzheimer mediante imágenes médicas, abordando las características específicas y evolutivas de la enfermedad en diferentes etapas.
- Implementar una interfaz de usuario interactiva y personalizable que permita a los profesionales médicos analizar, interpretar y validar los resultados del modelo de detección de manera intuitiva.
- Investigar y evaluar rigurosamente diferentes modelos de aprendizaje profundo con el propósito de identificar aquellos que contribuyan de manera significativa a la mejora de la precisión del sistema de detección de la enfermedad del alzheimer en imágenes médicas.

2.4. Justificación

La presente investigación se sustenta en una sólida justificación que abarca aspectos teóricos, prácticos y metodológicos, respaldando la pertinencia y relevancia del desarrollo de un sistema de detección de la enfermedad del Alzheimer a través de la inteligencia artificial.

En el ámbito teórico, esta investigación se ancla en el marco conceptual de las neurociencias y la medicina, enriquecido por los avances de la inteligencia artificial y el aprendizaje profundo. Existe una base sólida de conocimiento que establece la relación entre las imágenes médicas y los patrones característicos de la enfermedad del Alzheimer en sus diferentes etapas. Además, el uso de modelos de aprendizaje profundo se alinea con los avances teóricos en la detección y análisis de patrones complejos en datos biomédicos. La justificación teórica radica en la capacidad de aprovechar esta intersección entre la medicina y la inteligencia artificial para desarrollar una herramienta precisa y confiable que permita la detección temprana y precisa de la enfermedad.

En términos prácticos, la detección temprana y precisa de la enfermedad del Alzheimer tiene implicaciones significativas para la atención médica y la calidad de vida de los pacientes. La carga económica y emocional de esta enfermedad es innegable, tanto para los pacientes como para sus familias y el sistema de salud en general. La falta de herramientas especializadas y de recursos médicos altamente capacitados en el país crea un escenario en el cual la detección temprana enfrenta obstáculos considerables. La implementación de un sistema de detección basado en inteligencia artificial responde a esta problemática práctica al proporcionar una herramienta accesible y precisa que puede ser utilizada por profesionales médicos en diversas regiones del país.

2.5. Importancia

La utilización del deep learning en la detección de la enfermedad del Alzheimer tiene una importancia crucial en el ámbito médico y científico. Esta tecnología ofrece la capacidad de analizar con precisión y rapidez una amplia gama de datos biomédicos, como imágenes cerebrales permitiendo así una detección

temprana y precisa de los signos incipientes de la enfermedad ya que su avance progresivo hace que la identificación temprana sea fundamental para ralentizar su avance y aplicar tratamientos eficaces en las primeras etapas. Además, la implementación de sistemas de detección automatizada basados en Deep Learning puede ayudar a los doctores especializados, sirviéndoles como una herramienta de apoyo más no de sustitución ya que les permite acelerar el proceso de diagnóstico, por lo que su aplicación del Deep Learning en la detección del Alzheimer ofrece un gran potencial para mejorar la atención médica y la salud mental de la población

2.6. Motivación

La detección precisa y temprana de la enfermedad del Alzheimer es un desafío crucial en la investigación médica, y el uso de técnicas de aprendizaje profundo, como el deep learning, ha suscitado un profundo interés y motivación en este campo. La motivación detrás de emplear el deep learning en la detección de esta enfermedad radica en su capacidad para procesar y analizar grandes cantidades de datos complejos, como imágenes médicas de una manera automática y eficiente, además que ayuda a superar las limitaciones de recursos humanos y la carga de trabajo en los sistemas de atención médica mediante la proporción de herramientas

eficaces y eficientes mejorando los resultados clínicos, reduciendo los costos de atención médica y mejorando la calidad de vida de los pacientes afectados por esta enfermedad

3. Capítulo II: Marco Teórico

3.1. Alzheimer

3.1.1. Definición

El alzheimer es un tipo de trastorno cerebral de tipo neurodegenerativo que se caracteriza por la pérdida progresiva e irreversible de las neuronas que es considerada también la causa más común de la demencia (C. Park et al., 2023)

También lo definen como un trastorno neurodegenerativo crónico que se llega a manifestar clínicamente con una disminución progresiva de las funciones cognitivas y la memoria (Rita et al., 2023), y se puede dividir en 3 etapas, entre ellas está la etapa cognitivamente no deteriorada, deterioro cognitivo leve y la demencia de Alzheimer (S. W. Park, Yeo, Kim, et al., 2023)

3.2. Síntomas

Se tiene como síntomas comenzando por la pérdida de memoria aparentemente leve y se va intensificando gradualmente a una pérdida de la capacidad de mantener conversaciones y de responder al entorno ya que afecta el pensamiento, lenguaje y memoria (Balasundaram et al., 2023).

3.3. Tratamiento

(S. W. Park, Yeo, Lee, et al., 2023) Indica que actualmente no existe un tratamiento estándar para el Alzheimer por lo que la estrategia de tratamiento clínico es reducir la progresión de la enfermedad y

establecer biomarcadores para el diagnóstico precoz y su intervención. Ningún medicamento que se ha aprobado puede prevenir o retrasar la progresión del Alzheimer a pesar de la variedad de objetivos potenciales que han sido identificados para el tratamiento (Alamro et al., 2023).

3.4. Deep Learning

3.5. Resonancia Magnética

La resonancia magnética se ha desarrollado como un método poderoso para cuantificar las alteraciones de la conectividad estructural del cerebro que están asociadas con el Alzheimer (Liang et al., 2023).

3.6. palabra 1

4. Capítulo III: Estado del arte

4.1. Artículos

4.1.1. Alzheimer's disease classification using pre-trained deep networks(Shanmugam et al., 2022)

(DOI: 10.1016/j.bspc.2021.103217) 36 citaciones, Scopus

El presente artículo los autores centran su investigación en la [detección temprana de varias etapas de deterioro cognitivo y Alzheimer mediante el uso de imágenes de resonancia magnéticas utilizando el enfoque de Aprendizaje por Transferencia \(TL\)](#), las técnicas de imágenes tienen un papel importante en el diagnóstico y tratamiento de la EA ya que estas técnicas [han revolucionado el proceso en el diagnóstico de enfermedades por lo no invasivo que resulta para el cuerpo](#), para ello se usó tres [redes pre entrenadas GoogLeNet, AlexNet y ResNet-18](#) para la clasificación.


Se tiene como resultado que para la detección de la enfermedad del alzheimer GoogleNet, AlexNet y ResNet-18 tiene como precisión 96.39%, 94.08% y 97.51% respectivamente.

Algunas técnicas de imágenes que son utilizadas para el diagnóstico del Alzheimer.


- Tomografía computarizada(TC) de rayos X




- Resonancia magnética(RM)



- Imagen de tensor de difusión(DTI)



- Tomografía por emisión de positrones(PET)




Utilidad del Artículo

Gracias a este artículo se deduce que la [utilización de imágenes](#) desempeña un papel fundamental en la [detección temprana](#) y precisa de la [enfermedad del Alzheimer](#), estas técnicas permiten a los profesionales de la salud identificar patrones de atrofia cerebral ya que no solo facilitan un diagnóstico más temprano y preciso, sino que también son cruciales para monitorear la progresión de la enfermedad y evaluar la eficacia de posibles tratamientos. También se deduce que [las imágenes brindan una visión detallada de la estructura cerebral](#) y permiten [identificar](#) cambios sutiles en el tejido cerebral que son [característicos](#) de esta enfermedad neurodegenerativa. Debido a ello se usará las imágenes de [resonancia magnéticas](#) ya que son las modalidades de imagen más utilizadas y también aprovecha las capacidades de alta resolución y no invasivas, los médicos y los investigadores pueden obtener información esencial sobre la progresión y la extensión del Alzheimer en el cerebro, lo que a su vez facilita una detección temprana más precisa, un diagnóstico diferencial más confiable y una evaluación eficaz de las terapias en desarrollo.

4.1.2. An Alzheimer's disease classification method using fusion of features from brain Magnetic Resonance Image transforms and deep convolutional networks(Asgharzadeh-Bonab et al., 2023)

(DOI: 10.1016/j.health.2023.100223) 16 citaciones, Scopus

El presente artículo presenta dos esquemas de fusión eficientes para combinar las características profundas obtenidas de la imagen de resonancia magnética cerebral y sus transformaciones, presenta los esquemas de fusión a nivel de decisión y característica para combinar la información de diferentes entradas ya que la combinación de fuentes con información diferente aumenta la cantidad de información y puede ayudar a la toma de decisiones confiables para la clasificación del Alzheimer. Considera los diferentes modelos y clasificadores de CNN para clasificar las imágenes de RM cerebral en tres escenarios de dos clases. Tiene como resultado que EfficientNet-B7 con una red neuronal artificial (RNA) proporciona la mayor precisión.



Utilidad del Artículo

Gracias a este artículo se infiere que la aplicación de la Inteligencia Artificial (IA) se ha revelado como un recurso invaluable en la detección del Alzheimer, proporcionando un enfoque innovador y altamente efectivo. Al utilizar algoritmos de aprendizaje automático y técnicas de análisis de datos avanzadas, la IA puede procesar grandes conjuntos de datos biomédicos, como imágenes cerebrales. También se infiere que esta tecnología puede contribuir a una detección temprana más precisa y a un diagnóstico diferencial más confiable al identificar señales sutiles que podrían no ser evidentes para los médicos. Debido a ello se usará la tecnología Deep Learning ya que ha demostrado ser una herramienta excepcionalmente prometedora. Al aprovechar la capacidad de las redes neuronales profundas para aprender patrones complejos y sutiles en datos biomédicos, como imágenes de resonancia magnética.

4.1.3. A systematic review on machine learning and deep learning techniques in the effective diagnosis of Alzheimer's disease (Deep Arya et al., 2022)

(DOI: 10.1186/s40708-023-00195-7) 16 citaciones, Scopus

Esta investigación aborda el análisis de métodos utilizados en diversos artículos de la literatura reciente sobre la detección de la enfermedad del Alzheimer mediante inteligencia artificial, se puede dividir el artículo en la siguiente estructura:


- Conjunto de datos: se presenta un análisis de las fuentes de datos más recurrentes en la revisión de la literatura, en las que se destaca ADNI, OASIS y Kaggle como las principales.
- Preprocesamiento de datos: comparte buenas prácticas utilizadas en el procesamiento en las que resaltan la limpieza de datos (eliminación o corrección de datos incompleta, inconsistentes o erróneas), transformación de datos (normalización y estandarización para manejar formatos que mejoren el análisis), normalización de imágenes (ajuste de valores de intensidad de la imagen mediante técnicas de ecualización de histogramas, etc.) y el aumento de imágenes (usando rotaciones, inversiones y escalando las imágenes se puede mejorar la solidez del análisis)
- Modelos de aprendizaje utilizados: se realiza un análisis de modelos de aprendizaje automático convencionales y modelos de aprendizaje profundo. En el ámbito de las técnicas tradicionales de aprendizaje automático, se ha logrado una precisión del 85,71% en la clasificación

CN/AD mediante el uso de clasificadores SVM, mientras que en el aprendizaje profundo, nos presentan los modelos más conocidos de redes neuronales convolucionales (ResNet-101, VGG, VoxCNN, DenseNet) y nos detallan el funcionamiento de una red neuronal recurrente. Los clasificadores CNN han alcanzado un impresionante 98,6% de precisión y los RNN, un 91,2%. La investigación subraya la fiabilidad y exactitud mejorada al tomar decisiones basadas en predicciones multimodales en contraposición a depender de una única modalidad.

Por último mediante un gráfico de barras podemos validar que los modelos de aprendizaje profundo son los más usados por los investigadores actualmente y presentan un porcentaje de precisión bastante alto.

Fig. 6

From: [A systematic review on machine learning and deep learning techniques in the effective diagnosis of Alzheimer's disease](#)



Frequency of methods used in different articles taken in the study, and average accuracy using different classifiers

- Medidas de desempeño: nos presentan una explicación de las medidas de desempeño de un modelo de clasificación más utilizados con una matriz de confusión 2x2, entre los que destacan la exactitud, la precisión y el área bajo la curva (AUC)

Utilidad del Artículo

Gracias a este artículo se rescatan excelentes prácticas en el preprocesamiento de los datos que permiten mejorar la precisión final del modelo e inclusive reducir el tiempo de análisis, también nos comparte fuentes confiables en las que podemos obtener set de datos de imágenes médicas (especialmente MRI y PET) para entrenar modelos de inteligencia artificial para la detección de la enfermedad del Alzheimer. Además nos brinda visibilidad sobre la eficacia y el uso recurrente de modelos de inteligencia artificial lo cual corrobora la confianza que tiene la comunidad en el aprendizaje profundo sobre aplicaciones de predicción y clasificación de enfermedades. Debido a ello en nuestro trabajo de investigación se realizarán las técnicas de limpieza de datos, normalización de imágenes, aumento de imágenes y recorte y cambio de tamaño de imágenes en la fase de preprocesamiento ya que mejorará la precisión del modelo y optimizará el tiempo de análisis y entrenamiento. Además se usarán data sets de las fuentes especificadas en el artículo para el entrenamiento de los modelos.

4.1.4. An MRI-based deep learning approach for accurate detection of Alzheimer's disease (EL-Geneedy et al., 2023)
(DOI: DOI10.1016/j.aej.2022.07.062) 11 citaciones, WOS

El artículo toma como dataset las imágenes cerebrales proporcionadas por OASIS, específicamente la OASIS-3, las cuales se clasifican en 4 etapas dependiendo del grado de demencia.





Fig. 1 MR image examples for different Dementia stages: (a) None Demented(ND), (b) Moderated Demented (MoD), (c) Mild Demented (MD), and (d) Very Mild Demented (VmD), from left to right, respectively.

Propone un marco de trabajo dividido en las clásicas etapas de división de la data, construcción y entrenamiento del modelo y clasificación. En la división utiliza 20% de la data para el teste y destina el 80% para el entrenamiento.






Fig. 5 The CNN model architecture used for AD diagnosis. Note that, ReLU stands for rectified linear unit.

Centrándose en el modelo propuesto utiliza CNN y evalúa las arquitecturas VGG16, ResNet50, Inception V3, EfficientNetB7, and DenseNet121 architectures. Todos los modelos se trabajaron con un número de épocas iguales a 100, dado que el estudio mediante un análisis comparativo demostró ser superior en todas las medidas de evaluación al resto de número de épocas propuestos (20, 40 y 50)




Fig. 9 Performance of proposed framework across different numbers of epochs.

Los resultados arrojan que el método VGG16 obtuvo la mayor precisión alcanzando un 96,39%

Table 3 Proposed Model evaluation against other CNN that employs transfer learning. Here, “SEN”, “SPE”, “AUC”, and “NA” stand for Sensitivity, Specificity, Area Under the Curve, and Not Applicable, respectively.

Model	Train Accuracy	Test Accuracy	SEN	SPE	AUC
VGG 16	100	96.39	99.29	100	0.9988
DenseNet121	98.54	96.29	100	100	0.9981
Resnet50	92.46	89.85	100	100	0.9869
InceptionV3	91.38	87.71	99.12	100	0.9804
EfficientNetB7	49.78	48.68	NA	NA	0.7922
Proposed	100	99.68	100	100	1.00

Utilidad del Artículo

Gracias a este artículo se deduce que la CNN es un modelo apto para el procesamiento de imágenes médicas debido a su orientación hacia imágenes 2D y 3D. Además, se rescata que la arquitectura VGG16 con el parámetro de número de épocas establecido en 100 resulta ser altamente precisa para la detección de la enfermedad del Alzheimer. Debido a ello en nuestro trabajo nos guiaremos del marco de trabajo propuesto, incluiremos la arquitectura VGG16 en el modelo propuesto y evaluaremos el parámetro 100 del número de épocas en la implementación.


4.1.5. Medical image classification for Alzheimer's using a deep learning approach (Bamber & Vishvakarma, 2023)

(DOI: 10.1186/s44147-023-00211-x) 16 citaciones, Scopus

El artículo tiene como objetivo desarrollar un modelo de red neuronal convolucional para diagnosticar la enfermedad de Alzheimer. Tiene como resultado 91,12% correcto, 85,2% sensible y 94,01% específico.

Los autores mencionan la importancia y el uso de las imágenes médicas en el campo de la detección y diagnóstico del Alzheimer y otras enfermedades. Describe cómo las imágenes médicas, como las obtenidas a través de diversas técnicas de imagenología como rayos X, CT, MRI y ultrasonido, son fundamentales para comprender el funcionamiento y la estructura interna del cuerpo humano. Estas imágenes brindan una visión detallada de los tejidos y órganos, permitiendo a los científicos, médicos y clínicos investigar y diagnosticar problemas de salud, también hace referencia a un diagrama de alto nivel que representa las etapas

principales del procedimiento propuesto para la detección del Alzheimer en el artículo.



Utilidad del Artículo

Gracias a este artículo se infiere que la CNN tiene un alto impacto en la detección y clasificación de la enfermedad, también habla del uso creciente de técnicas de aprendizaje profundo en la clasificación de la enfermedad de Alzheimer y nos muestra un diagrama y/o esquema del procedimiento para la detección para su detección . Debido a ello en nuestro trabajo de investigación se realizará un diagrama y/o esquema que muestre los pasos que realiza el sistema inteligente para la detección del Alzheimer ya que facilitará el entendimiento del aporte debido a que se presentará en un esquema de alto nivel.

4.1.6. Alzheimer's disease diagnosis and classification using deep learning techniques (Al Shehri, 2022)


(DOI: 10.7717/peerj-cs.1177) 16 citaciones, Web of science

El presente trabajo de investigación plantea la necesidad de soluciones automáticas para el análisis de imágenes médicas en pacientes con EA, y se mencionan las tecnologías emergentes como el Internet de las cosas médicas (IoMT) y los enfoques de aprendizaje automático y aprendizaje profundo como posibles soluciones en este contexto médico.

Dado que los síntomas de la EA a menudo son leves en las etapas iniciales, existen desafíos significativos en su diagnóstico temprano. El estudio busca abordar estos desafíos y contribuir al campo de la investigación sobre la EA en varios aspectos clave:

- **Diagnóstico Preciso y Temprano:** El objetivo principal de la investigación es proporcionar una solución que permita el diagnóstico preciso, oportuno y temprano de la EA.
- **Uso de Arquitecturas CNN:** En el estudio, se emplean dos arquitecturas de redes neuronales convolucionales (CNN), específicamente DenseNet169 y ResNe50. Estas arquitecturas se utilizan para validar las técnicas propuestas en la clasificación de imágenes en dos categorías: imágenes normales y anormales (correspondientes a casos de EA). Además, se clasifican las imágenes de EA en cuatro etapas diferentes.

Propuesta de metodología modelo:



Los autores también realizan el proceso de evaluación del modelo utilizado en el estudio. El propósito de esta evaluación es determinar qué tan bien funciona el modelo en función de los datos de entrenamiento y un conjunto de datos de prueba. En particular, se utiliza la medida de evaluación llamada "precisión" para evaluar el rendimiento del modelo propuesto.

La fórmula para calcular la precisión se presenta de la siguiente manera:

$$A c c u r a c y = A a / A c * 100$$

Aa: Representa el número de resultados clasificados correctamente por el modelo.

Ac: Es el número total de resultados evaluados.

La precisión se utiliza como una métrica clave para evaluar qué tan bien el modelo es capaz de hacer clasificaciones precisas. Cuanto mayor sea

el valor de precisión, mejor será el rendimiento del modelo en la tarea de clasificación.

Utilidad del Artículo

Por medio de este artículo se tomará en cuenta la métrica de precisión ya que es clave para evaluar cuán preciso es tu modelo DL ya que garantiza una detección temprana confiable de la enfermedad. Esto es fundamental para proporcionar a los pacientes y a los profesionales de la salud una base sólida para tomar decisiones informadas y reducir la ocurrencia de falsos positivos (pacientes diagnosticados incorrectamente con Alzheimer) y falsos negativos (pacientes con Alzheimer que no son identificados). Esto es crucial para garantizar un diagnóstico preciso y evitar tratamientos innecesarios o la falta de tratamiento.

4.1.7. Multimodal deep learning models for early detection of Alzheimer's disease stage (Venugopalan et al., 2021)

(DOI: 10.1038/S41598-020-74399-W) 142 citaciones, Web of science

La investigación se centra en utilizar múltiples fuentes de datos, como imágenes médicas, información genética y datos clínicos, para mejorar la detección temprana de la EA. También se menciona algunos puntos claves como:

- Fusión Multimodal de Datos: El estudio promueve la fusión de datos de múltiples fuentes, incluidas imágenes de resonancia magnética, datos clínicos y datos genómicos (SNP), para predecir la etapa de la EA. Utiliza codificadores automáticos y redes neuronales convolucionales 3D

para procesar y extraer características de estas diferentes modalidades de datos.

- **Modelos de Integración:** Después de entrenar redes separadas para cada modalidad de datos, el estudio [combina los resultados utilizando varios enfoques de clasificación, como árboles de decisión, bosques aleatorios, máquinas de vectores de soporte \(SVM\) y k-vecinos más cercanos \(kNN\)](#). Esto permite una toma de decisiones más precisa y holística.
- **Comparación de Modelos:** Se compararon modelos profundos (DL) con modelos superficiales, como k-vecinos más cercanos (kNN), máquinas de vectores de soporte (SVM) de codificación uno contra uno, bosques aleatorios y árboles de decisión, en términos de su capacidad para predecir las etapas de la EA.
- **Interpretación de Modelos Profundos:** Uno de los [desafíos clave en el uso de modelos de DL en el ámbito clínico es la interpretación de estos modelos](#). El estudio aborda este desafío desarrollando enfoques de interpretación basados en perturbaciones y análisis de agrupación para identificar las características más relevantes y significativas en la toma de decisiones.

Utilidad del Artículo

Por medio de este artículo se tomará en cuenta la [Fusión Multimodal de Datos](#) ya que [se puede demostrar cómo la fusión de datos de diferentes modalidades, como imágenes médicas, datos clínicos y genéticos, mejora](#)

la precisión del diagnóstico de la enfermedad de Alzheimer en comparación con el uso de cada modalidad de forma independiente. Esto es esencial para una detección más precisa y temprana de la enfermedad además que destaca cómo la fusión multimodal de datos reduce la incertidumbre y la variabilidad en los resultados del diagnóstico al combinar múltiples fuentes de información.

4.1.8. A Transfer Learning Approach for Early Diagnosis of Alzheimer's Disease on MRI Images (Mehmood et al., 2021)
(DOI:10.1016/j.neuroscience.2021.01.002) 76 citaciones, Web of science

Este estudio se centra en el uso de resonancia magnética (RM) y aprendizaje profundo para detectar el deterioro cognitivo leve (DCL) y la enfermedad de Alzheimer (EA) en sus etapas tempranas, utiliza técnicas de aprendizaje profundo, en particular, la arquitectura VGG, que ya ha sido entrenada previamente con un gran conjunto de datos. Esto es parte del enfoque de transferencia de aprendizaje, donde un modelo preentrenado se ajusta para tareas específicas, también se realiza una segmentación de tejidos en las imágenes cerebrales para extraer la información de la materia gris. Esta segmentación permite que el modelo se centre en las características relevantes de las imágenes.

Se destaca que los métodos basados en el aprendizaje profundo, como los autocodificadores dispersos y las redes neuronales convolucionales

(CNN), están proporcionando soluciones óptimas para la clasificación en diversos dominios, incluyendo la visión por computadora y el procesamiento de imágenes médicas

El modelo propuesto logra tasas de [precisión](#) notables en la clasificación de diferentes estados cognitivos. Por ejemplo, la precisión en distinguir entre pacientes con EA y controles normales es del 98.73%. También logra una precisión sólida en la clasificación de otras categorías, como EMCI (deterioro cognitivo leve temprano) y LMCI (deterioro cognitivo leve tardío).

Utilidad del Artículo


Por medio de este artículo se tomara en cuenta la [segmentación de tejidos](#) en las imágenes cerebrales ya que es un componente crucial en la [detección](#) y [diagnóstico](#) de enfermedades neurológicas como la enfermedad de Alzheimer, esto puede [ayudar a los médicos a identificar con mayor confiabilidad regiones del cerebro afectadas por la enfermedad](#), lo que a su vez puede llevar a un tratamiento más temprano y efectivo.

4.1.9. Four-way classification of Alzheimer's disease using deep Siamese convolutional neural network with triplet-loss function (Hajamohideen et al., 2023)


(DOI:10.1186/s40708-023-00184-w) 3 citaciones, Scopus

En este trabajo de investigación los autores se enfocan en la **detección temprana de la enfermedad de Alzheimer (EA)** utilizando imágenes de **resonancia magnética (MRI)** del cerebro y técnicas de **aprendizaje profundo**, en particular una arquitectura de **red neuronal convolucional siamesa (SCNN)** esta arquitectura de red neuronal convolucional siamesa es un tipo de red neuronal **utilizada en tareas de comparación o similitud**, donde dos ramas de la red comparten los mismos pesos y arquitectura. Esta red toma imágenes de resonancia magnética cerebral como entrada, emplea una función de pérdida triple, que es comúnmente utilizada en tareas de aprendizaje por siamesa. Esta función se utiliza para aprender representaciones significativas de las imágenes de MRI en un espacio de incrustación de k dimensiones.

También se muestran los bloques de construcción de la CNN siamesa utilizando la función de pérdida de tripletes para clasificar la EA.



También se muestra la arquitectura de la red siamesa:



El modelo se evaluó utilizando dos conjuntos de datos: [ADNI y OASIS](#). Los resultados obtenidos mostraron una alta [precisión](#) en la clasificación de pacientes con Alzheimer, con una precisión del 91,83% en ADNI y del 93,85% en OASIS.

Utilidad del Artículo

Por medio de este artículo se tomara en cuenta la existencia de la [red neuronal convolucional siamesa \(SCNN\)](#) ya que su comprensión y/o entendimiento nos permitirá conocer una técnica de vanguardia, lo que puede aumentar la innovación y originalidad en nuestro trabajo, además que la red neuronal ha demostrado [eficaz en tareas de comparación o similitud](#), lo que puede ser relevante en muchas aplicaciones, como el diagnóstico médico.

4.1.10. Early Detection of Alzheimer's Disease Using Magnetic Resonance Imaging: A Novel Approach Combining Convolutional Neural Networks and Ensemble Learning (Pan et al., 2020)

(DOI:10.3389/fnins.2020.00259) 121 citaciones, Scopus

Este trabajo de investigación se enfoca en el uso de técnicas de aprendizaje profundo, específicamente una combinación de Redes Neuronales Convolucionales (CNN) y Aprendizaje en Conjunto (EL), para la detección temprana de la enfermedad de Alzheimer (EA) y el deterioro cognitivo leve (DCL) a partir de imágenes de resonancia magnética (IRM) del cerebro.

La metodología que se propone es un enfoque llamado CNN-EL, que combina modelos de Redes Neuronales Convolucionales (CNN) entrenados en diferentes cortes de IRM (sagital, coronal, transversal) para clasificar sujetos en tres categorías: EA vs. cognición sana (HC), DCL que progresará a EA (MC1c) vs. HC, y MC1c vs. DCL que no progresará a EA (MC1nc).

Mencionan algunas de las ventajas de las CNN, como su capacidad para procesar datos de imágenes directamente, aprovechar la información espacial en las imágenes y reducir la cantidad de parámetros del modelo mediante técnicas como el uso de campos receptivos locales y el uso compartido de pesos y aprendizaje en conjunto que implica la combinación de múltiples sistemas de aprendizaje, ha demostrado ser

beneficioso tanto en términos de rendimiento como de robustez. Esto se ha aplicado también al análisis de resonancia magnética.

En los resultados se evaluó el rendimiento de este enfoque utilizando validación cruzada. Los resultados mostraron una alta tasa de [precisión](#) para las tres tareas de [clasificación](#), lo que indica que este enfoque puede ser efectivo en la detección de EA y DCL.

Utilidad del Artículo

Por medio de este artículo se tomará en cuenta la existencia del [aprendizaje en conjunto](#) ya que es una [técnica poderosa en el campo del aprendizaje automático](#) por su capacidad para [mejorar la precisión de los modelos](#), también el [aprendizaje en conjunto puede reducir el sobreajuste \(overfitting\)](#) en comparación con modelos individuales. Esto es especialmente relevante si trabaja con conjuntos de datos pequeños.

4.1.11. Early Multi-model and multi-slice ensemble learning architecture based on 2D convolutional neural networks for Alzheimer's disease diagnosis (Kang et al., 2021)

(DOI:10.1016/j.combiomed.2021.104678) 35 citaciones, Wos

El presente trabajo de investigación se enfoca en la detección y predicción de la progresión de la enfermedad de Alzheimer (EA) utilizando técnicas de [aprendizaje automático](#) y [redes neuronales convolucionales bidimensionales \(CNN 2D\)](#) ya que es una enfermedad neurodegenerativa crónica para la cual actualmente no existen tratamientos efectivos su [detección](#) temprana y precisa es esencial para la práctica clínica y la investigación médica, [el estudio utiliza datos de](#)

neuroimagen, específicamente cortes coronales de mapas de densidad de materia gris, para realizar clasificaciones entre diferentes grupos de sujetos, incluyendo individuos cognitivamente normales (CN), personas con deterioro cognitivo leve (DCL) y pacientes con EA por la cual se propone una arquitectura basada en el aprendizaje en conjunto. Esto significa que se utilizan múltiples modelos de CNN 2D, entrenados en diferentes segmentos de datos, y sus decisiones se combinan mediante un esquema de votación mayoritaria para tomar una decisión final. Después de construir el modelo de conjunto, se aplica el aprendizaje por transferencia para adaptar estos modelos a otras tareas, lo que significa que pueden ser utilizados para clasificar diferentes grupos de pacientes y no se limitan solo a la clasificación AD versus CN.

El enfoque propuesto logra tasas de precisión del 90.36% para la clasificación AD versus CN, 77.19% para AD versus MCI y 72.36% para MCI versus CN. Estos resultados indican una capacidad efectiva y precisa para diagnosticar diferentes etapas de la EA.

Se realizó la evaluación del rendimiento de los clasificadores que se utilizan para clasificar diferentes grupos de pacientes, como aquellos con enfermedad de Alzheimer (AD) y sujetos cognitivamente normales (CN), entre otros.

Tabla 2. Resultado de la clasificación de tres clasificadores para la clasificación AD frente a la clasificación NC.				
Métodos	Precisión (%)	Sensibilidad (%)	Especificidad (%)	AUC (%)
Discriminador	90.36	91.43	86.49	89.98
VGG16	87.95	84.62	89.19	88.07
Resnet50	83.13	79.49	83.78	83.20

Tabla 3. Resultados de EL multimodelo para cuatro clasificaciones binarias.				
Tareas	Precisión (%)	Sensibilidad (%)	Especificidad (%)	AUC (%)
AD versus CN	90.36	93.94	83.78	89.72
EA versus DCL	77.19	68.97	54.06	71.18
DCL versus CN	72.36	74.71	84.42	68.29
MCIC versus MCInc	63.49	57.56	64.29	62.50

Utilidad del Artículo

Por medio de este artículo se tomará en cuenta **las métricas de rendimiento** ya que su uso y la evaluación adecuada de estos son fundamentales en la investigación y desarrollo de algoritmos de aprendizaje automático. Entre las métricas se destacan la **precisión, sensibilidad, especificidad y Área Bajo la Curva (AUC)** ya que se puede explorar cómo se comportan diferentes métricas en problemas de clasificación multiclase y cuáles son las mejores para cada caso.

4.1.12. Machine Learning and Deep Learning Approaches for Brain Disease Diagnosis: Principles and Recent Advances (Khan et al., 2021)

(DOI:10.1109/ACCESS.2021.3062484) 28 citaciones, Wos

El presente estudio trata sobre el uso de la inteligencia artificial, en particular el [aprendizaje automático y el aprendizaje profundo](#), para la [detección de enfermedades cerebrales](#), específicamente la enfermedad de [Alzheimer](#), los tumores cerebrales, la epilepsia y la enfermedad de Parkinson por lo que el estudio revisa 147 [artículos recientes que se centran en el uso de técnicas de aprendizaje automático y aprendizaje profundo para la detección y diagnóstico de enfermedades cerebrales](#), también se analizan veintidós conjuntos de datos que se utilizan comúnmente en estos estudios para proporcionar datos médicos necesarios para el [entrenamiento y evaluación de algoritmos de inteligencia artificial](#) y se discuten las diferentes técnicas de extracción de características utilizadas en el [diagnóstico](#) de enfermedades cerebrales. Esto se refiere a cómo se seleccionan y procesan los datos para que los algoritmos puedan comprenderlos y tomar decisiones.

Utilidad del Artículo

Por medio de este artículo se tomará en cuenta el conocimiento de [múltiples bases de datos relacionados con enfermedades cerebrales](#), entre ellas está el Alzheimer, ya que esto permitirá una amplia variedad de datos para poder realizar nuestro [preprocesamiento y/o entrenamiento](#). Entre la base de datos están ADNI, NACC, OASIS, etc

5. Capítulo IV: Modelado de Negocio

5.1. Reglas del Negocio

Se propone el modelo de negocio que se basa en la interacción de los doctores con el sistema inteligente que les permite cargar radiografías de pacientes y proporcionar una evaluación para determinar si el paciente muestra signos de Alzheimer.

RN: Los doctores podrán crear, modificar y eliminar datos de los pacientes.

RN2: Los doctores deben estar debidamente autorizados y capacitados para utilizar el sistema inteligente.

RN3: El sistema debe mantener registros detallados de todas las evaluaciones realizadas, incluyendo la fecha y hora de la evaluación, la radiografía analizada y el resultado obtenido


RN4: Los doctores podrán ingresar las radiografías de los pacientes en el sistema inteligente

RN5:El sistema debe mantener registros detallados de todas las evaluaciones realizadas, incluyendo la fecha y hora de la evaluación, la radiografía analizada y el resultado obtenido.

RN6:Los resultados de las evaluaciones deben ser confidenciales y solo accesibles por personal autorizado, como los doctores y el paciente mismo. El sistema no debe divulgar resultados a terceros sin el consentimiento explícito del paciente.

5.2. Caso de Uso del Negocio

5.2.1. Diagrama de Casos de Uso del Negocio




5.2.1.1. Actores del Negocio

Los actores del negocio que interactúan con el sistema inteligente son los siguientes:

- **Doctor:** Encargado de registrar a los nuevos pacientes a los que se evaluarán sus Resonancia Magnética.

- **Paciente:** Persona que será evaluada mediante su Resonancia Magnética y podrá visualizar los resultados de la evaluación de su Resonancia Magnética en el sistema inteligente.



5.2.1.2. Casos de Uso del Negocio

Los casos de uso del negocio a especificar son los siguientes:

- Registro de Resonancia Magnética
- Visualizar Resultados

5.2.2. Especificación de casos de uso de negocio

6. Capítulo V: Requerimientos del proyecto

6.1. Funcionales

Los requisitos funcionales se relacionan con las capacidades y el modo en que se espera que el sistema se comporte cuando un usuario se involucra con él. Cada requisito funcional se identifica mediante un código que incluye dos letras iniciales que señalan su tipo y un número que indica su orden en la secuencia. La columna de nombre y descripción proporciona una breve y completa explicación de lo que implica ese requisito.

ID Requisito	Requisito	Descripción
RF - 001	Registrar Doctor	El sistema debe permitir registrar a los nuevos doctores que usaran el sistema inteligente
RF - 002	Mantener información del doctor	El sistema debe permitir modificar o eliminar la información del doctor a buscar
RF - 003	Registrar Paciente	El sistema debe permitir registrar al paciente a quien se le realizará la evaluación de su resonancia magnetica
RF - 004	Mantener información del paciente	El sistema debe permitir modificar o eliminar la información del paciente a buscar
RF - 005	Registrar resonancia magnética	El sistema debe permitir registrar la resonancia magnética del paciente a quien se le realizará la evaluación
RF - 006	Visualizar Resultados	El sistema debe permitir visualizar los resultados obtenidos luego de evaluar la resonancia magnética del paciente con su DNI.


6.2. No funcionales

ID Requisito	Requisito	Descripción
RNF - 001	Rapidez de respuesta	El sistema permitirá al usuario una respuesta rápida al pedido

		solicitada al sistema.
RF - 002	Navegabilidad	El sistema deberá presentar una interfaz amigable para el usuario que les permita facilitar el trabajo que requieran realizar y sin complicaciones o confusiones.
RF - 003	Mantenibilidad	El sistema debe dar la posibilidad de realizar modificaciones o reparaciones a un proceso sin afectar la continuidad del servicio.
RF - 004	Almacenamiento	El sistema debe contar con almacenamiento seguro para las imágenes de resonancia magnética como la información de los pacientes y/o doctores.
RF - 005	Seguridad	El sistema debe garantizar a los usuarios seguridad en cuanto a la información que se procede en el sistema.

6.3. Casos de uso del sistema

6.3.1. Diagrama de Actores del Sistema




6.3.1.1. Especificación de los Actores del Sistema


ACTORES	REQUERIMIENTOS
Administrador	Registro de doctores, mantener información de los doctores.
Doctor	Registrar pacientes, mantener información de pacientes, registro

	de resonancia magnética, visualizar resultados.
Paciente	Visualizar resultados.

6.3.2. Módulo de Paquetes



6.3.3. Diagrama de Casos de Uso del Sistema



6.3.4. Especificaciones CUS

- Registrar Doctores

Caso de uso	Registrar Doctores
Objetivo	El sistema debe permitir registrar doctores que utilizaran el sistema inteligente
Actor	Administrador
Precondición	El usuario ha sido admitido en el sistema con el rol de Administrador
Postcondición	El sistema ha permitido registrar al doctor
Flujo normal	
1. El caso de uso se inicia cuando el Administrador indica “Registrar Doctores”, . 2. El Administrador indica “Registrar” 3. El Administrador ingresa el nombre del Doctor 4. El sistema solicita. · Nombres · Apellidos · Teléfono · DNI · Colegiatura · Contraseña 5. El Administrador ingresa los datos solicitados 6. El Administrador indica “Guardar”. 7. El sistema registra los datos del nuevo Doctor. 8. El caso finaliza exitosamente.	

Flujo alternativo
6.1 Colegiatura ya registrado 1. El sistema indica “Colegiatura ingresada ya existe en el sistema”.

- Mantener Informacion de Doctores

Caso de uso	Mantener información de Doctores
Objetivo	El sistema debe permitir modificar o eliminar a un doctor del sistema inteligente.
Actor	Administrador
Precondición	El usuario ha sido admitido en el sistema con el rol de Administrador
Postcondición	El sistema ha permitido modificar o eliminar los datos del Doctor.
Flujo normal	
1. El caso de uso se inicia cuando el Administrador indica “Modificar Doctor” o “Eliminar Doctor”. 2. El administrador indica “Modificar Doctor”. 3. El administrador ingresa el nombre o código del doctor. 4. El sistema muestra una nueva interfaz en la que se muestra toda la información del Doctor buscado: los nombres, apellidos, teléfono, DNI, colegiatura y contraseña.. 5. Para cada campo de la información del doctor, el Administrador puede cambiar cualquiera de ella. 6. El Administrador cambia el campo que desea modificar y pulsa el botón de “Modificar datos”. 7. El sistema registra y almacena la información modificada y la guarda en la base de datos. 8. El caso de uso finaliza.	
Flujo alternativo	
2.b. El encargado de RRHH selecciona en el sistema la opción de “Eliminar trabajador”. 1. El encargado ingresa el nombre o código del trabajador	

2. El sistema muestra los datos del trabajador y solicita confirmar eliminación
3. La encargado indica “Confirmar”
4. El caso finaliza exitosamente.
3.1 Error al ingresar el nombre o código del doctor
1. El sistema indica “Error al ingresar código o nombre del Doctor”.

● Registrar Paciente

Caso de uso	Registrar Paciente
Objetivo	El sistema debe permitir registrar pacientes a los que se les hará el análisis de la resonancia magnética..
Actor	Doctor
Precondición	El usuario ha sido admitido en el sistema con el rol de Doctor
Postcondición	El sistema ha permitido registrar al paciente
Flujo normal	
1. El caso de uso se inicia cuando el Administrador indica “Registrar Paciente”, . 2. El Doctor indica “Registrar” 3. El Doctor ingresa el nombre del Paciente 4. El sistema solicita. · Nombres · Apellidos · Teléfono · DNI · Dirección 5. El Doctor ingresa los datos solicitados 6. El Doctor indica “Guardar”.	

7. El sistema registra los datos del nuevo paciente.
8. El caso finaliza exitosamente.
Flujo alternativo
6.1 DNI ya registrado
2. El sistema indica “DNI ingresada ya existe en el sistema”.

- Mantener Información de Pacientes

Caso de uso	Mantener información de Pacientes
Objetivo	El sistema debe permitir modificar o eliminar a un paciente del sistema inteligente.
Actor	Doctor
Precondición	El usuario ha sido admitido en el sistema con el rol de Doctor
Postcondición	El sistema ha permitido modificar o eliminar los datos del paciente.
Flujo normal	
1. El caso de uso se inicia cuando el Doctor indica “Modificar Paciente” o “Eliminar Paciente”. 2. El Doctor indica “Modificar Paciente”. 3. El Doctor ingresa el DNI del paciente. 4. El sistema muestra una nueva interfaz en la que se muestra toda la información del paciente buscado: los nombres, apellidos, teléfono, DNI y dirección.. 5. Para cada campo de la información del paciente, el Doctor puede cambiar	

cualquiera de ella. 6. El Doctor cambia el campo que desea modificar y pulsa el botón de “Modificar datos”. 7. El sistema registra y almacena la información modificada y la guarda en la base de datos. 8. El caso de uso finaliza.
Flujo alternativo
2.b. El encargado de RRHH selecciona en el sistema la opción de “Eliminar Paciente”. 1. El encargado ingresa el DNI del paciente. 2. El sistema muestra los datos del Paciente y solicita confirmar eliminación 3. La encargado indica “Confirmar” 4. El caso finaliza exitosamente. 3.1 Error al ingresar el DNI del paciente 2. El sistema indica “Error al ingresar DNI del paciente”.

- Registro de Resonancia Magnética

Caso de uso	Registro de Resonancia Magnética
Objetivo	El sistema debe permitir registrar la resonancia magnética del paciente para su evaluación en el sistema inteligente
Actor	Doctor
Precondición	El usuario ha sido admitido en el sistema con el rol de Doctor
Postcondición	El sistema ha permitido registrar la resonancia magnética del paciente

Flujo normal

1. El caso de uso se inicia cuando el Doctor indica “Realizar Evaluación de Alzheimer”
2. El sistema muestra una nueva interfaz donde podrá ingresar el dni del paciente a quien registrará su resonancia magnetica.
3. El doctor indica “Ingresar DNI”
4. El sistema muestra una nueva interfaz en la que se muestra toda la información del paciente buscado: los nombres, apellidos, teléfono, DNI y dirección.
5. El doctor indicar “Registrar Resonancia Magnética”.
6. El doctor registra la resonancia magnética.
7. El sistema procesa la resonancia magnética.
8. El sistema muestra los resultados y los almacena en la DB.
9. Caso de uso finaliza.

Flujo alternativo

3.1 Error al ingresar el DNI del paciente

1. El sistema indica “Error al ingresar DNI del paciente”.

- Visualizar Resultados

Caso de uso	visualizar Resultados
Objetivo	El sistema debe permitir visualizar los resultados luego de realizar la evaluación a la resonancia magnética del paciente
Actor	Doctor y/o Paciente
Precondición	El usuario ha sido admitido en el sistema con el rol de Doctor y/o Paciente
Postcondición	El sistema ha permitido visualizar los resultados del paciente
Flujo normal	
1. El caso de uso se inicia cuando el doctor y/o paciente indica “Buscar Resultados”. 2. El doctor y/o paciente ingresa el DNI del paciente a buscar. 3. El sistema muestra toda la información del paciente y el resultado obtenido luego de la evaluación de la resonancia magnética. 4. Caso de uso finaliza.	
Flujo alternativo	
2.1 Error al ingresar el DNI del paciente no existe 2. El sistema indica “Error al ingresar DNI del paciente no existe”.	

6.4. Prototipo

7. Capítulo VI: Arquitectura

7.1. Modelo conceptual

7.2. Arquitectura lógica

En la Figura X se presenta una arquitectura que agrupa los componentes en capas de presentación, de negocio y de datos. La persona interesada utiliza su dispositivo personal con acceso a internet para interactuar con la capa de presentación a través de la interfaz de usuario. La principal tarea de esta interfaz es facilitar la carga de imágenes de resonancia magnética cerebral para su procesamiento y permitir consultas de resultados del historial del paciente que incluye las resonancias magnéticas y los resultados del clasificador. La capa de negocio tiene 2 componentes principales. El modelo clasificador se comunica inicialmente con el modelo clasificador de deep learning de la capa de datos y en caso se detecte demencia se invoca el modelo segmentador de deep learning que permitirá conocer el área de la resonancia magnética principalmente afectada por la enfermedad del Alzheimer. Si se detecta la enfermedad del Alzheimer según la resonancia magnética revisada el resultado del componente clasificadores de la capa de negocio se mostrará en la interfaz de usuario. Otro componente importante de la capa de negocio es la consulta de resultados históricos que permitirá comunicarse con la base de datos que almacena la relación de resonancia magnética y resultado del modelo clasificador y de esta manera realizar un seguimiento de la evolución del estado de la demencia y del área afectada por la EA.




Figura X. Diagrama de arquitectura lógica

Fuente: Elaboración propia

7.3. Arquitectura Tecnológica

Se implementará una página web mediante el marco MERN Stack como se define en la figura X, la capa de presentación se desplegará en un servidor Node js en combinación con la librería react. La página web permitirá a médicos y pacientes interactuar con las funciones con las que dispone cada uno respectivamente, como son subir las resonancias magnéticas, obtener resultados del modelo clasificador y consultar el historial de un paciente. Se usa python para la construcción, entrenamiento y ejecución del modelo clasificador y el segmentador. Cabe resaltar, que el usuario que ya se encuentre registrado puede realizar una consulta de los resultados obtenidos debido a que también se cuenta con una conexión a base de datos MongoDB para cumplir con esa actividad.




Figura X. Diagrama de arquitectura tecnológica

Fuente: Elaboración propia

7.4. Arquitectura física

La arquitectura se materializa mediante un servidor local vinculado a un dominio web público como se grafica en la figura X. Dentro de este servidor, se encuentra la página web que opera node js y Mongodb. En este servidor, se almacenan los datos de los usuarios, las imágenes cargadas y generadas, junto con las bibliotecas de Python y los archivos en formato JSON adquiridos durante la fase de entrenamiento de los modelos de clasificación y segmentación. Los usuarios acceden al sistema desde sus propias computadoras personales utilizando un navegador y accediendo al dominio correspondiente.





Figura X. Diagrama de arquitectura física

Fuente: Elaboración propia

7.5. Vistas de Casos de Uso más Significativos



En el gráfico, los casos de uso de mayor relevancia están representados por el color azul, como se evidencia en la figura.

7.5.1. Especificación de los Casos de Uso más significativos

CASO DE USO	DESCRIPCIÓN
Registro de Resonancia Magnética	Mediante este caso de uso el doctor registrará la resonancia magnética del paciente a evaluar para su diagnóstico.
Visualizar Resultados	Mediante este caso de uso tanto el doctor como el paciente podrán visualizar los resultados de su evaluación una vez finalizada el proceso de diagnóstico

7.6. Modelo de despliegue

Referencias:

- Al Shehri, W. (2022). Alzheimer's disease diagnosis and classification using deep learning techniques. *PeerJ Computer Science*, 8. <https://doi.org/10.7717/PEERJ-CS.1177>
- Asgharzadeh-Bonab, A., Kalbkhani, H., & Azarfardian, S. (2023). An Alzheimer's disease classification method using fusion of features from brain Magnetic Resonance Image transforms and deep convolutional networks. *Healthcare Analytics*, 100223. <https://doi.org/10.1016/j.health.2023.100223>
- Balasundaram, A., Srinivasan, S., Prasad, A., Malik, J., & Kumar, A. (2023). Hippocampus Segmentation-Based Alzheimer's Disease Diagnosis and Classification of MRI Images. *Arabian Journal for Science and Engineering*. <https://doi.org/10.1007/s13369-022-07538-2>
- Bamber, S. S., & Vishvakarma, T. (2023). Medical image classification for Alzheimer's using a deep learning approach. *Journal of Engineering and Applied Science*, 70(1). <https://doi.org/10.1186/s44147-023-00211-x>
- Deep Arya, A., Singh Verma, S., Chakarabarti, P., Chakrabarti, T., Elngar, A. A., Nami, M., & Kamali, A.-M. (2022). A Systematic Review on Machine Learning and Deep Learning Techniques in the Effective Diagnosis of Alzheimer's Disease. <https://doi.org/10.21203/rs.3.rs-2028945/v1>
- Dipietro, L., Gonzalez-Mego, P., Ramos-Estebanez, C., Zukowski, L. H., Mikkilineni, R., Rushmore, R. J., & Wagner, T. (2023). The evolution of Big Data in neuroscience and neurology. *Journal of Big Data*, 10(1). <https://doi.org/10.1186/s40537-023-00751-2>
- EL-Geneedy, M., Moustafa, H. E. D., Khalifa, F., Khater, H., & Abdelhalim, E. (2023). An MRI-based deep learning approach for accurate detection of Alzheimer's disease. *Alexandria Engineering Journal*, 63, 211–221. <https://doi.org/10.1016/j.aej.2022.07.062>
- Hajamohideen, F., Shaffi, N., Mahmud, M., Subramanian, K., Al Sariri, A., Vimbi, V., & Abdesselam, A. (2023). Four-way classification of Alzheimer's disease using deep Siamese convolutional neural network with triplet-loss function. *Brain Informatics*, 10(1). <https://doi.org/10.1186/s40708-023-00184-w>
- Helaly, H. A., Badawy, M., & Haikal, A. Y. (2022). Deep Learning Approach for Early Detection of Alzheimer's Disease. *Cognitive Computation*, 14(5), 1711–1727. <https://doi.org/10.1007/s12559-021-09946-2>
- Huang, G., Li, R., Bai, Q., & Alty, J. (2023). Multimodal learning of clinically accessible tests to aid diagnosis of neurodegenerative disorders: a scoping review. In *Health Information Science and Systems* (Vol. 11, Issue 1). Springer. <https://doi.org/10.1007/s13755-023-00231-0>
- Jaiswal, A., & Sadana, A. (2022). Early Detection of Alzheimer's Disease Using Bottleneck Transformers. *International Journal of Intelligent Information Technologies*, 18(2). <https://doi.org/10.4018/IJIT.296268>
- Liang, L., Zhou, P., Ye, C., Yang, Q., & Ma, T. (2023). Spatial–temporal patterns of brain disconnectome in Alzheimer's disease. *Human Brain Mapping*. <https://doi.org/10.1002/hbm.26344>
- Ma, P., Wang, J., Zhou, Z., Chen, C. L. P., & Duan, J. (2023). Development and validation of a deep-broad ensemble model for early detection of Alzheimer's disease. *Frontiers in Neuroscience*, 17. <https://doi.org/10.3389/fnins.2023.1137557>

- Mehmood, A., yang, S., feng, Z., wang, M., Ahmad, A. S., khan, R., Maqsood, M., & Yaqub, M. (2021). A Transfer Learning Approach for Early Diagnosis of Alzheimer's Disease on MRI Images. *Neuroscience*, 460, 43–52. <https://doi.org/10.1016/j.neuroscience.2021.01.002>
- Pan, D., Zeng, A., Jia, L., Huang, Y., Frizzell, T., & Song, X. (2020). Early Detection of Alzheimer's Disease Using Magnetic Resonance Imaging: A Novel Approach Combining Convolutional Neural Networks and Ensemble Learning. *Frontiers in Neuroscience*, 14. <https://doi.org/10.3389/fnins.2020.00259>
- Park, C., Jung, W., & Suk, H. Il. (2023). Deep joint learning of pathological region localization and Alzheimer's disease diagnosis. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-38240-4>
- Park, S. W., Yeo, N. Y., Kim, Y., Byeon, G., & Jang, J. W. (2023). Deep learning application for the classification of Alzheimer's disease using 18F-flortaucipir (AV-1451) tau positron emission tomography. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-35389-w>
- Park, S. W., Yeo, N. Y., Lee, J., Lee, S. H., Byun, J., Park, D. Y., Yum, S., Kim, J. K., Byeon, G., Kim, Y., & Jang, J. W. (2023). Machine learning application for classification of Alzheimer's disease stages using 18F-flortaucipir positron emission tomography. *BioMedical Engineering Online*, 22(1). <https://doi.org/10.1186/s12938-023-01107-w>
- Rita, L., Neumann, N. R., Laponogov, I., Gonzalez, G., Veselkov, D., Pratico, D., Aalizadeh, R., Thomaidis, N. S., Thompson, D. C., Vasiliou, V., & Veselkov, K. (2023). Alzheimer's disease: using gene/protein network machine learning for molecule discovery in olive oil. *Human Genomics*, 17(1), 57. <https://doi.org/10.1186/s40246-023-00503-6>
- Shanmugam, J. V., Duraisamy, B., Simon, B. C., & Bhaskaran, P. (2022). Alzheimer's disease classification using pre-trained deep networks. *Biomedical Signal Processing and Control*, 71. <https://doi.org/10.1016/j.bspc.2021.103217>
- Venugopalan, J., Tong, L., Hassanzadeh, H. R., & Wang, M. D. (2021). Multimodal deep learning models for early detection of Alzheimer's disease stage. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-020-74399-w>
- Yiğit, A., & Işık, Z. (2020). Applying deep learning models to structural MRI for stage prediction of Alzheimer's disease. *Turkish Journal of Electrical Engineering and Computer Sciences*, 28(1), 196–210. <https://doi.org/10.3906/elk-1904-172>