

Aprendizaje profundo para el diagnóstico de la enfermedad de Alzheimer mediante el análisis de IRM

Elena Acevedo¹ ; Dinora Orantes² ; Antonio Acevedo³ 

^{1,3}Instituto Politécnico Nacional, ESIME Zacatenco, México, {eacevedo, macevedo}@ipn.mx

²Instituto Politécnico Nacional, CIC, México, sorantesj@ipn.mx

Resumen— La enfermedad de Alzheimer es un trastorno cerebral progresivo que afecta la memoria, la capacidad de razonamiento y, con el tiempo, la capacidad de realizar tareas cotidianas simples. Las personas diagnosticadas con esta demencia tienen una esperanza de vida de hasta veinte años desde el diagnóstico. Se presenta una propuesta basada en aprendizaje profundo para la clasificación y el diagnóstico de la enfermedad de Alzheimer mediante el análisis de resonancias magnéticas. El conjunto de datos se obtuvo de la plataforma de Kaggle y se aplicaron las métricas de precisión, recall y F1-score, cada una de ellas mostró un porcentaje cercano al 100%, obteniéndose una precisión promedio de 99.52%.

Palabras clave— Inteligencia Artificial, Aprendizaje supervisado, aprendizaje profundo, diagnóstico, Alzheimer.

I. INTRODUCCIÓN

Considerada un problema de salud pública, la enfermedad de Alzheimer es la demencia neurodegenerativa más frecuente en el mundo. A medida que la enfermedad avanza, se presentan discapacidades que derivan en un aumento a los cuidados personales. Este padecimiento también puede iniciar en la edad adulta, por factores como la herencia genética, diabetes, obesidad, hipertensión arterial, depresión, aislamiento social, sedentarismo, problemas para dormir, consumo de alcohol y tabaco.

La enfermedad de Alzheimer y demencia vascular representan el 90% de los casos de demencia en general. Este tipo de enfermedades generan un gasto económico muy alto en la población que lo padece, ya que el 85% de estos costos recaen totalmente en los familiares de pacientes con Alzheimer [1].

En México, 7.8 por ciento de las personas mayores de 60 años vive con Alzheimer [2], un padecimiento caracterizado por pérdida de la memoria que podría prevenirse o retardar su aparición con estilo de vida saludable, señaló el especialista adscrito a la Subdirección de Psiquiatría del Instituto Nacional de Neurología y Neurocirugía “Manuel Velasco Suárez” (INNNMVS), Francisco Martínez Carillo.

La imagen por resonancia magnética (IRM) es la técnica más utilizada en el diagnóstico de enfermedades neurodegenerativas debido a su carácter no invasivo y su bajo

riesgo, lo que permite a los profesionales médicos realizar diagnósticos más precisos y eficaces.

Con ayuda de herramientas de Inteligencia Artificial es posible realizar un diagnóstico automático del Alzheimer a partir del análisis de imágenes de resonancia magnética. En particular, el aprendizaje profundo permite que los sistemas aprendan funciones complejas a partir de grandes cantidades de datos mediante un entrenamiento previo sin supervisión constante. Por esta razón, es recomendable utilizar una red neuronal convolucional (CNN) cuando se dispone de una gran cantidad de datos complejos, como las imágenes de resonancia magnética.

En este trabajo se describe un modelo de aprendizaje profundo para el diagnóstico de la enfermedad de Alzheimer mediante el análisis de imágenes de resonancias magnéticas.

A continuación, se presentan los trabajos relacionados con el diagnóstico y la clasificación de la enfermedad de Alzheimer aplicando distintos algoritmos de Inteligencia Artificial.

A. Trabajos relacionados

Raza *et al.* [3] utilizaron un modelo de aprendizaje profundo pre-entrenado como base, Densenet-169, junto con transferencia de aprendizaje para clasificar la enfermedad de Alzheimer analizando resonancias magnéticas, específicamente usaron las imágenes Gray Matter del cerebro segmentadas. El conjunto de datos que utilizaron fue descargado del sitio Alzheimer’s Disease Neuroimaging Initiative (ADNI). El conjunto de datos tiene cuatro clases. Enfermedad de Alzheimer, No cognitiva, Deterioro cognitivo leve tardío y Deterioro cognitivo leve. El modelo fue probado con 10, 25 y 50 épocas y la precisión general fue de 97.84%.

En el 2023 [4], Archana y Kalirajan propusieron el uso de una red neuronal convolucional para la clasificación de la enfermedad de Alzheimer, utilizaron un conjunto de datos obtenido de ADNI, del cual analizan las clases: Deterioro cognitivo leve, Enfermedad de Alzheimer, Cognitivamente Normal y Persona sana. El pre-procesamiento de las resonancias magnéticas consistió en aplicar el algoritmo CLAHE para mejorar el contraste de las imágenes para

después remover el ruido. Utilizaron cien épocas para obtener una precisión del 95.82%.

Se aplicó una red neuronal convolucional tridimensional para el diagnóstico de Alzheimer utilizando resonancias magnéticas 3D [5]. El conjunto de datos fue obtenido del sitio ADNI. La arquitectura consta de cuatro capas de convolución 3D, seguidas de cuatro capas de Max Pool 3D y una capa de agrupación promedio global 3D. A ésta le siguen dos capas densas, con una función de Dropout aplicada después de la primera capa densa. El resultado final se genera mediante una activación de softmax. El modelo obtiene una precisión de entrenamiento del 99% y una precisión de validación del 73%.

Alarjani y Faisal [6] utilizaron una red convolucional tridimensional para obtener las características principales de las resonancias magnéticas y realizar el diagnóstico, también, esas características se usaron para alimentar un algoritmo de máquinas de soporte vectorial y así poder distinguir entre imágenes de personas sanas y personas con Alzheimer. Estos algoritmos fueron aplicados a resonancias magnéticas funcionales. El preprocesamiento de las imágenes incluye algunos pasos como la remoción del ruido, corrección del tiempo de corte, realineación, normalización espacial y suavizado espacial. La tasa de reconocimiento para la red convolucional fue de 98.92% en el entrenamiento y del 98.3% en la prueba, mientras que para la máquina de soporte vectorial se obtuvo el 97.14% de reconocimiento en el entrenamiento y 97.5% en la prueba.

En el 2024 [7], se aplica un modelo híbrido que incluye aprendizaje de máquina y aprendizaje profundo para la clasificación de la enfermedad de Alzheimer. Se utiliza una máquina de soporte vectorial para obtener las características principales de las imágenes. Una red convolucional también obtiene sus propias características principales y después se fusionan con las anteriores. Esta fusión es la entrada a una red totalmente conectada que realiza la clasificación. En este trabajo se tienen cuatro clases. El algoritmo logra un resultado final de 91.84% de precisión en los datos de prueba.

Assmi *et al.* [8], comparan el desempeño de seis redes pre-entrenadas: VGG-19, VGG-16, ResNet-50, InceptionV3, Xception, and DenseNet169, cuya precisión general fue 92.86%, 92.83%, 91.04%, 90.57%, 85.99%, y 88.64%, respectivamente. El conjunto de datos se obtuvo del repositorio de Kaggle. Las cuatro clases analizadas fueron No demencia, Demencia muy leve, Demencia leve y Demencia moderada.

Se aplicaron tres técnicas diferentes de Inteligencia Artificial para clasificar la enfermedad de Alzheimer [9]. Las técnicas son Redes neuronales Convolucionales (RNC), Lógica difusa (LD) y Perceptrón multicapa (PM) Del sitio de ADNI se procesaron imágenes de resonancias magnéticas 3D, PET Florbetaben y PET Flortaucipir. Se trabaja con tres clases: Controles Normales, Enfermedad de Alzheimer y Deterioro cognitivo leve. Los resultados de la precisión fueron: RNC = 90.67%, LD = 99.1% y PM = 94%.

En 2025 [10], se aplicó una combinación de dos técnicas para la detección y clasificación de la enfermedad de

Alzheimer. La primera técnica es Aprendizaje por refuerzo profundo y la segunda técnica es Red neuronal recurrente optimizada de Moth Flame. El algoritmo optimizado Moth Flame se utiliza para encontrar las características principales de las imágenes de resonancias magnéticas. Para el conjunto de datos se obtuvieron imágenes de resonancias magnéticas de dos repositorios: Kaggle y ADNI, se conjuntaron estas imágenes para considerar sólo dos clases que son personas sanas y personas afectadas por Alzheimer. Los resultados de las métricas fueron exactitud de 99.31 %, precisión de 99.24 %, recall de 99.43 % y f-measure de 99.35 %.

Mousavi *et al.* [11], aplicaron una red neuronal convolucional para obtener las características principales de imágenes de resonancias magnéticas para la clasificación y diagnóstico de la enfermedad de Alzheimer. Estas características fueron presentadas a cuatro modelos que fueron Xception, VGG19, VGG16 y InceptionResNetV2. El conjunto de datos se creó con muestras de varios repositorios obteniendo 6735 imágenes de resonancia magnéticas. Estas imágenes se clasifican en demencia leve, demencia moderada, demencia muy leve y normal. Se pre-procesaron y se aplicó el algoritmo de aumento de datos. Para la evaluación de los algoritmos de clasificación, se aplicaron las métricas de precisión, exactitud y F-score. El algoritmo de InceptionResnetV2 mostró los mejores resultados con 0.99 en todas las métricas.

Este documento está organizado de la siguiente manera. En la Sección II, se presentan los algoritmos y herramientas que se aplicaron para lograr el objetivo de nuestro trabajo. En la Sección III, se describe el modelo propuesto para realizar el diagnóstico de la enfermedad de Alzheimer. La Sección IV presenta los resultados obtenidos. Finalmente, se presentan las conclusiones.

II. MARCO TEÓRICO

En este apartado se presentará la descripción del conjunto de datos utilizado, de los conceptos básicos de una red neuronal convolucional y de las métricas aplicadas para la evaluación del modelo propuesto.

A. Conjunto de Datos

El conjunto de datos utilizado en este trabajo fue Alzheimer MRI Preprocessed Dataset que se obtuvo del repositorio de Kaggle. Este conjunto de datos cuenta con 10400 imágenes de resonancias magnéticas divididas en cuatro clases: demencia leve, demencia moderada, no demencia y demencia muy leve. Cada una de estas clases cuenta con 2600 imágenes, es decir, el conjunto de datos está balanceado.

Para este conjunto de imágenes se tomaron en cuenta los siguientes porcentajes:

- 80% imágenes de entrenamiento que corresponden a 8320 resonancias magnéticas.
- 10% imágenes de validación que corresponden a 1040 resonancias magnéticas.

- 10% imágenes de prueba que corresponden a 1040 resonancias magnéticas.

B. Redes Neuronales Convolucionales

Una Red Neuronal Convolutiva (CNN) [12] es un tipo de red neuronal artificial que procesa sus capas imitando la corteza visual del cerebro humano para identificar diferentes características en las entradas. Por ello, la CNN contiene varias capas ocultas especializadas con una jerarquía. Esto significa que las primeras capas detectan algunas singularidades o formas básicas y, a medida que avanza la propagación de la información, se especializan hasta alcanzar capas más profundas capaces de reconocer formas complejas, como tipos de ropa o diferenciar entre animales.

Las imágenes que procesa la red neuronal se presentan como una matriz de píxeles; la intensidad de cada color se representa mediante un número que va de 0 (sin color) a 255 (color máximo). Sin embargo, para que la red neuronal funcione eficazmente, estos valores se normalizan; esto significa que cambian de 0 a 1 para que la red gestione los datos con mayor eficacia y permita cálculos más estables.

La arquitectura general de una CNN se muestra en la Figura 1.




Fig. 1 Arquitectura general de una red neuronal convolutiva.

La convolución [13] se utiliza para extraer información de localidad. Utiliza una matriz denominada kernel que recorre cada píxel de la imagen original y genera un único valor, utilizando tanto el valor del propio píxel como el de los píxeles vecinos. De esta manera, se genera una nueva matriz denominada matriz convolucionada, que contiene la información del píxel y sus vecinos.

La agrupación (Pooling) es una operación que reduce la resolución espacial de una imagen al reducir su tamaño. Esta operación se realiza en ventanas o regiones de la imagen y toma el valor máximo (Agrupación Máxima) o promedio (Agrupación Promedio) de cada región. La agrupación ayuda a reducir el número de parámetros y cálculos en la red, lo que puede prevenir el sobreajuste y aumentar la eficiencia de la red. También ayuda a resaltar características importantes en la imagen, lo que puede facilitar la detección de patrones y objetos en capas posteriores.

En la última parte de las redes neuronales convolucionales se encuentra la capa totalmente conectada la cual funge como un clasificador encargado de asignar la imagen de entrada a una categoría determinada. Este algoritmo, también conocido como retropropagación del error o algoritmo de

retropropagación, es un método utilizado en redes neuronales de aprendizaje supervisado.

Pretende ajustar los pesos de la red neuronal, minimizando la función de pérdida en el entrenamiento, implica que el error se propaga desde la capa de salida hasta las capas ocultas de la red y con esto se ajustan los pesos de la mejor manera posible.

Este proceso empieza dando entradas a la red neuronal, a cada neurona se le asigna una entrada con un peso que se expondrá a una función de activación. Es ahora donde entran los cálculos de las capas, estos se basan siempre en las salidas de capas anteriores. La última salida del proceso se compara con la salida deseada y calcula el error.

Después el backpropagation utiliza este error para ajustar los pesos de cada una de las capas por donde pasará nuevamente la entrada. Una forma más sencilla de ver es propagar el error hacia atrás y actualizar los pesos de las capas de la red neuronal en las épocas del algoritmo. Para actualizar dichos pesos se utiliza otro método conocido como Gradiente descendente que tiene por objetivo dar pesos tales que minimicen el error de la red neuronal, para esto se requiere el cálculo de la derivada parcial del error con respecto a cada peso y esto se va a repetir en cada época.

C. Métricas

Enumere las ecuaciones consecutivamente con los números de ecuación entre paréntesis al mismo nivel que el margen derecho, como en (1). Para hacer sus ecuaciones más compactas, puede usar el solidus (/) y la función exp, etc.

III. MODELO PROPUESTO

La arquitectura completa de la red neuronal convolutiva consta de 9 capas, entre estas se encuentran las capas de convolución bidimensionales, las de agrupación, de aplanamiento y las de salida en donde se encuentran las densas.

Capa 1. Conv2D

- ✓ 32: Número de filtros (o kernels) a aplicar.
- ✓ Kernel_size = (3, 3): Tamaño de los filtros de 3x3 píxeles.
- ✓ Strides=2: Desplazamiento de los filtros de 2 píxeles tanto horizontal como verticalmente.
- ✓ Padding= 'same': Añade píxeles vacíos en los bordes para que las dimensiones de salida sean las mismas que las de entrada.
- ✓ Activation='relu': Función de activación ReLU, que introduce no linealidad.
- ✓ Input_shape = (128, 128, 1): Una imagen de 128x128 píxeles con 1 canal (blanco y negro).

Capa 2. MaxPool2D

- ✓ MaxPool2D: Capa de pooling máximo bidimensional.

- ✓ Pool_size = (2, 2): Tamaño del filtro de pooling, en este caso de 2x2 píxeles.
- ✓ Strides=2: Desplazamiento del filtro de pooling, en este caso de 2 píxeles.
- ✓ Padding='same': Añade píxeles vacíos en los bordes para mantener las dimensiones de salida.
- ✓ Dropout: Regularizador que apaga aleatoriamente el 15% de las neuronas para prevenir el sobreajuste.

Capa 3. Conv2D

- ✓ 64: Número de filtros.
- ✓ Kernel_size=(3, 3): Tamaño del filtro de 3x3 píxeles.
- ✓ Strides=2: Desplazamiento de 2 píxeles.
- ✓ Activation='relu': Función de activación ReLU.
- ✓ Padding='same': Mantiene las dimensiones de salida.

Capa 4. MaxPool2D

- ✓ (2, 2): Tamaño del filtro de pooling.
- ✓ Strides=2: Desplazamiento del filtro.
- ✓ Padding= 'same': Mantiene las dimensiones de salida.

Capa 5. Conv2D

- ✓ 128: Número de filtros.
- ✓ Kernel_size=(3, 3): Tamaño del filtro de 3x3 píxeles.
- ✓ Strides=2: Desplazamiento de 2 píxeles.
- ✓ Activation='relu': Función de activación ReLU.
- ✓ Padding='same': Mantiene las dimensiones de salida.

Capa 6. MaxPool2D

- ✓ (2, 2): Tamaño del filtro de pooling.
- ✓ strides=2: Desplazamiento del kernel.
- ✓ padding='same': Mantiene las dimensiones de salida.
- ✓ Dropout: Apaga aleatoriamente el 25% de las neuronas para prevenir el sobreajuste.

Capa 7. Flatten o capa de aplanamiento

Aplana la salida bidimensional en un vector unidimensional para su posterior procesamiento en las capas densas.

Capa 8. Dense

- ✓ 64 neuronas.
- ✓ activation='relu': Función de activación ReLU.

Capa 9. Dense

- ✓ 4 neuronas correspondientes a las 4 clases.

- ✓ Activation = 'softmax': Función de activación Softmax que convierte las salidas en probabilidades para cada clase.

Los parámetros utilizados en la red de retropropagación constan de 100 épocas, la función de pérdida es *categorical_crossentropy*, el optimizador es Adam y, durante el entrenamiento, se opta por monitorizar y evaluar el modelo con la precisión.

IV. PRUEBAS Y RESULTADOS

Los resultados obtenidos para el entrenamiento se realizaron probando con diferentes números de capas de convolución obteniendo las métricas de Recall y Precisión para cada prueba realizada individualmente utilizando siempre el mismo conjunto de datos, además se usa un 80% para el entrenamiento, 10% para validación y finalmente 10% para pruebas. Lo anterior se muestra en la Tabla I.

TABLA I
RESULTADOS DE LAS PRUEBAS REALIZADAS CON DIFERENTE NÚMERO DE CAPAS CONVOLUCIONALES

Capa	Recall	Precisión
1	0.991346	0.991374
2	0.989423	0.985944
3	0.995192	0.995188
4	0.985576	0.985727

Las pruebas se realizaron modificando el porcentaje del conjunto de imágenes total para entrenamiento y pruebas, conservando el 10% siempre para las validaciones, además ocupando 100 épocas para cada una de las modificaciones, a continuación, se muestran las gráficas de la magnitud de pérdida, precisión de entrenamiento y pruebas, pérdida de entrenamiento y pruebas, matriz de confusión, reporte f1-score y la curva ROC para cada una de las modificaciones. Las gráficas de entrenamiento y prueba, tanto de pérdida (Figura 2) como de precisión (Figura 3) reflejan el rápido aprendizaje de esta configuración y su alta precisión, lo que resulta en una disminución rápida de la pérdida.

Otra de las métricas que se utilizaron para el análisis del rendimiento de nuestra propuesta fue la matriz de confusión que se muestra en la Figura 4. En esta figura se puede observar que, de los 1040 registros de prueba, el sistema sólo se equivoca en 5 ocasiones. Uno de los registros que pertenece a la clase de demencia muy leve lo confunde con la clase de demencia leve y dos registros de la clase demencia muy leve los clasifica mal indicando que son de la clase de no demencia.




Fig. 2 Magnitud de la pérdida por época en la fase entrenamiento y en la fase de pruebas.




Fig. 3 Precisión obtenida por época en la fase entrenamiento y en la fase de pruebas.




Fig. 4 Matriz de confusión.

El reporte F1-score muestra un rendimiento casi perfecto en todas las clases, con métricas cercanas a 1.0, como se muestra en la Figura 5.

	precision	recall	f1-score	support
0	1.00	1.00	1.00	260
1	1.00	1.00	1.00	260
2	0.99	0.99	0.99	260
3	0.99	0.99	0.99	260
accuracy			1.00	1040
macro avg	1.00	1.00	1.00	1040
weighted avg	1.00	1.00	1.00	1040

Fig. 5 Reporte de métricas.

Estos resultados empatan con los valores de la matriz de confusión ya que se observa que para cada una de las clases (de la 0 a la 3) las métricas muestran resultados cercanos a 1.0.

El Área Bajo la Curva ROC (AUC) proporciona una medida agregada del rendimiento del modelo en todas las posibles configuraciones de umbral. Un AUC de 1 indica un clasificador perfecto, mientras que un AUC de 0.5 indica un clasificador sin habilidad.

La curva ROC mostrada en la Figura 6, se demuestra que tiene un alto desempeño al clasificar cada una de las cuatro clases.




Fig. 6 Curva ROC.

En la Tabla II se muestra el resumen de las pruebas realizadas a la propuesta con diferentes porcentajes del conjunto de entrenamiento. En las primeras tres filas se muestran los porcentajes de la división del conjunto de datos entre entrenamiento, pruebas y validación. Las dos últimas dos filas muestran los resultados de eficiencia obtenidos durante el entrenamiento y la validación, respectivamente.

En este trabajo se utilizó el 80% para entrenamiento y el 10% de los registros para la validación.

De la Tabla II se puede observar que la eficiencia para una un 80-10-10 es de 99.52%.

Finalmente, en la Tabla III se muestra la comparación de los resultados obtenidos por los trabajos relacionados y la propuesta de este trabajo.

TABLA II

TABLA COMPARATIVA DE RESULTADOS OBTENIDOS UTILIZANDO
DIFERENTES PORCENTAJES DE ENTRENAMIENTO DEL CONJUNTO DE DATOS

División del repositorio de imágenes			Resultados	
Validación (%)	Pruebas (%)	Entrenamiento (%)	Entrenamiento (%)	Eficiencia (%)
10	10	80	99.5	99.52
10	20	70	98.90	99.42
10	30	60	98.27	98.94
10	40	50	97.76	97.28
10	50	40	95.94	95.19
10	60	30	92.63	92.40
10	70	20	90.00	89.90
10	80	10	81.73	80.77

TABLA III

TABLA COMPARATIVA DE RESULTADOS OBTENIDOS POR LOS DIFERENTES
TRABAJOS RELACIONADOS

Trabajo	Validación (%)
Nuestra propuesta	99.52
2023 [3] Alzheimer Disease Classification through Transfer Learning Approach	97.84
2023[4] Alzheimer's Disease Classification using Convolutional Neural Networks	98.52
2023 [5] Deep 3D-CNN using Resonance Imaging for Diagnosing Alzheimer's	73
2023 [6] Detect Alzheimer's Disease from Neuroimaging Using Artificial Intelligence Techniques	RNC= 98.3 SVM= 97.5
2024 [7] A proficient approach for the classification of Alzheimer's disease using a hybridization of machine learning and deep learning	91.84
2024 [8] Alzheimer's disease classification: a comprehensive study	VGG-19= 92.86
2025 [9] Alzheimer's disease classification by supervised and intelligent techniques	RNC = 90.67%, LD = 99.1% y PM = 94%
2025 [10] Alzheimer's Disease detection and classification using optimized neural network	Exactitud= 99.31, precisión= 99.24, recall= 99.43 y f-measure= 99.35
2025 [11] Classifying and diagnosing Alzheimer's disease with deep learning using 6735 brain MRI images	99

En esta tabla se puede observar que nuestra propuesta presenta resultados comparables con algunos de los trabajos relacionados.

El trabajo presentado en [8] utiliza el mismo conjunto de datos que nuestra propuesta. El porcentaje reportado de eficiencia es de 92.86% utilizando un modelo pre-entrenado mientras que nuestro modelo supera ese resultado con un 99.52 de eficiencia con una arquitectura propia. Algunos de los otros trabajos sólo diagnostican dos clases. También se puede observar que los trabajos más recientes son los que alcanzan los valores de 99% de eficiencia.

CONCLUSIONES

La aplicación de herramientas de inteligencia artificial, en particular el aprendizaje profundo, es una opción viable para el diagnóstico de la enfermedad de Alzheimer. Cada una de las métricas se respalda entre sí y muestran el adecuado desempeño de nuestra propuesta. En la matriz de confusión se observa que el algoritmo comete sólo 5 errores. La precisión, recall y F1-score muestran que los resultados son muy cercanos a 1 para cada una de las clases diagnosticadas. De la misma forma, la curva ROC muestra un desempeño óptimo de la arquitectura propuesta. También se puede mencionar que con tres capas convolucionales es suficiente para extraer las características principales de las resonancias magnéticas. En general, se demostró que nuestra propuesta es una opción óptima para la clasificación y el diagnóstico de la enfermedad de Alzheimer al presentar una precisión promedio de todas las clases del 99.52%.

AGRADECIMIENTO/RECONOCIMIENTO

Los autores de este trabajo queremos agradecer al Instituto Politécnico Nacional (COFAA, EDI y SIP), SECIHTI (SNII) por el apoyo para el desarrollo de esta propuesta.

REFERENCES

- [1] Consultor salud [en línea] <https://consultorsalud.com.mx/alzheimer-mexico-pronam-prevencion-demencias/#:~:text=Una%20epidemia%20silenciosa%20con%20alto,cr%C3%B3nicas%20vinculadas%20al%20deterioro%20cognitivo.> 25 de septiembre de 2025.
- [2] Secretaría de Salud, [en línea] <https://www.gob.mx/salud/prensa/391-en-mexico-padece-alzheimer-7-8-de-las-personas-mayores-de-60-anos#:~:text=En%20M%C3%A9xico%2C%207.8%20por%20ciento,Insti tuto%20Nacional%20de%20Neurolog%C3%ADa%20y,> 21 de septiembre de 2024
- [3] N. Raza, A. Naseer, M. Tamoor and K. Zafar. "Alzheimer Disease Classification through Transfer Learning Approach", *Diagnostics* 2023, 13, 801. DOI: <https://doi.org/10.3390/diagnostics13040801>
- [4] B. Archana and K. Kalirajan. "Alzheimer's Disease Classification using Convolutional Neural Networks", *International Conference on Innovative Data Communication Technologies and Application (ICIDCA-2023)*, pp. 1044-1048, 2023
- [5] N. Ayub, S. Z. A. Shah, A. Assad and N. M. Din. "Deep 3D-CNN using Resonance Imaging for Diagnosing Alzheimer's", *CSI International Symposium on Artificial Intelligence and Signal Processing*, 2023, DOI: 10.1109/AISP57993.2023.10135044.
- [6] M. Alarjani and K. Faisal. "Detect Alzheimer's Disease from Neuroimaging Using Artificial Intelligence Techniques", *3rd International Conference on Computing and Information Technology (ICCIT)*, pp. 192-200, 2023, DOI: 10.1109/ICCIT58132.2023.10273977.
- [7] H. A. Raza, S. U. Ansari, K. Javed, M. Hanif et al. "A proficient approach for the classification of Alzheimer's disease using a hybridization of machine learning and deep learning", *Scientific Reports*, vol. 14, no. 30925, 2024 DOI: 10.1038/s41598-024-81563-z.
- [8] A. Assmi, K. Elhabyb, A. Benba and A. Jilbab. "Alzheimer's disease classification: a comprehensive study", *Multimedia Tools and Applications*, no. 83, pp. 70193–70216, 2024, DOI: 10.1007/s11042-024-18306-9.
- [9] J. M. Amine and M. Mourad. "Alzheimer's disease classification by supervised and intelligent techniques", *Journal of Alzheimer's Disease Reports*, Vol. 9, pp. 1–14, 2025.

- [10]N. B. Balakrishnan, A. S. Pillai, J. J, Panackal and P.S. Sreeja. "Alzheimer's Disease detection and classification using optimized neural network", Computers in Biology and Medicine, Vol. 187, 2025.
- [11]S. M. Mousavi, K. Moulaei and L. Ahmadian. "Classifying and diagnosing Alzheimer's disease with deep learning using 6735 brain MRI images", Scientific Reports, Vol. 15, No. 22721, 2025.
- [12]Á. Artola. "Clasificación de imágenes usando redes neuronales convolucionales en Python". (Trabajo Fin de Grado Inédito). Universidad de Sevilla, Sevilla, 2019.
- [13]R. Castilla. Reconocimiento de logotipos de marcas mediante Redes Neuronales de Convolución (CNN). Master tesis, 2021.