

Modelo basado en Rust en la detección eficiente de Alzheimer en imágenes de resonancia magnética cerebral

A Rust-based Model for the Efficient Detection of Alzheimer's in Brain MRI Scans

Joel García Arteaga

Jorge Parraga-Alava



Investigación

Tecnología e Innovación



Modelo basado en Rust en la detección eficiente de Alzheimer en imágenes de resonancia magnética cerebral

A Rust-based Model for the Efficient Detection of Alzheimer's in Brain MRI Scans

Joel García Arteaga¹, Jorge Parraga-Alava²

How to cite: García Arteaga, J., Parraga-Alava, J. (2026). *Modelo basado en Rust en la detección eficiente de Alzheimer en imágenes de resonancia magnética cerebral. Investigación. Tecnología e Innovación.* 18(25), 23-34. DOI: <https://doi.org/10.53591/iti.v18i25.3232>

RESUMEN

Contexto: la detección temprana de Alzheimer mediante imágenes de resonancia magnética requiere modelos con alta precisión diagnóstica y, al mismo tiempo, implementaciones eficientes para su despliegue. **Objetivo:** comparar tres estrategias de clasificación de MRI cerebral y analizar la viabilidad de migrar el mejor modelo a un pipeline de inferencia en Rust. **Método:** se trabajó con 6400 imágenes distribuidas en cuatro clases diagnósticas. Se evaluó un modelo híbrido CNN + mRMR + KNN, ADD-Net y un ensamble Master-Slave basado en VGG-16. **Resultados:** el modelo híbrido obtuvo la mejor exactitud en prueba (99,27%) y el mejor F1 ponderado (0,995), seguido por ADD-Net (91,98%; F1 = 0,932) y el ensamble Master-Slave (75,94%; F1 = 0,699). En la comparación de despliegue, Rust redujo el tiempo de inferencia de 12,36 s a 3,14 s para 128 imágenes y elevó el rendimiento de 10.36 a 40.70 imágenes por segundo. **Conclusiones:** el enfoque híbrido fue el más sólido para la clasificación multiclase, mientras que Rust mostró alto potencial para inferencia eficiente, sujeto a una mejor alineación del preprocesamiento para preservar la fidelidad predictiva.

Palabras clave: MRI, Alzheimer, Aprendizaje Profundo, Green AI.

ABSTRACT

Context: early Alzheimer detection from magnetic resonance imaging requires both diagnostic accuracy and computational efficiency for deployment. **Objective:** to compare three multiclass MRI classification strategies and assess whether the best-performing model can be migrated to a Rust inference pipeline. **Method:** a public dataset of 6400 brain MRI images across four diagnostic classes was partitioned into training, validation and testing subsets. Safe data augmentation, mutual-information feature selection and SMOTETomek were applied depending on the model. Three approaches were evaluated: a hybrid CNN + mRMR + KNN model, ADD-Net and a VGG-16-based Master-Slave ensemble. **Results:** the hybrid model achieved the best test accuracy (99.27%) and weighted F1-score (0.995), followed by ADD-Net (91.98%; F1 = 0.932) and the Master-Slave ensemble (75.94%; F1 = 0.699). In deployment benchmarking, Rust reduced inference time from 12.36 s to 3.14 s for 128 images and increased throughput from 10.36 to 40.70 images per second, although accuracy dropped by 1.56 percentage points relative to Python. **Conclusions:** the hybrid approach was the most robust option for multiclass classification, while Rust demonstrated strong potential for efficient inference if preprocessing parity with the original Python pipeline is improved

Keywords: MRI, Alzheimer's Disease Diagnosis, Deep Learning, Green AI.

¹ Maestría en Ciencia de Datos y Máquinas de Aprendizaje, Universidad Técnica de Manabí, Ecuador. Correo electrónico: jgarcia5169@utm.edu.ec

² Facultad de Ciencias Informáticas, Universidad Técnica de Manabí, Ecuador. Correo electrónico: jorge.parraga@utm.edu.ec



Fecha de recepción: Marzo 31, 2026.

Fecha de aceptación: Mayo 29, 2026.

INTRODUCCIÓN

La enfermedad de Alzheimer (AD) representa uno de los desafíos sanitarios y económicos más apremiantes del siglo XXI, caracterizada por un deterioro cognitivo irreversible y una creciente prevalencia global (Khan et al., 2022) (Afzal et al., 2021). El diagnóstico temprano resulta crítico para la intervención terapéutica; en este ámbito, el análisis de imágenes de resonancia magnética (MRI) mediante algoritmos de Deep Learning se ha consolidado como una herramienta indispensable (George & Menon, 2024)(Khan et al., 2022).

Arquitecturas de redes neuronales convolucionales (CNN) como ResNet y EfficientNet han permitido la clasificación efectiva entre controles normales, deterioro cognitivo leve y Alzheimer, superando a los métodos tradicionales (Liquan Zhao, 2022)(Mahasin & Dewi, 2022). No obstante, la tendencia predominante en la investigación actual se alinea con la denominada "Red AI", enfocada en la búsqueda de precisión sin priorizar la eficiencia energética (Barbierato & Gatti, 2024), lo cual plantea preocupaciones ambientales debido al elevado consumo de energía.

A pesar de la existencia de redes ligeras y modelos optimizados (Liquan Zhao, 2022) (Ngo et al., 2025) (Ali et al., 2025), persiste un cuello de botella en la infraestructura de software. La mayoría de los flujos de trabajo en IA médica se implementan en ecosistemas basados en Python, el cual introduce sobrecargas significativas en tiempo de ejecución a pesar de su flexibilidad para el prototipado (Franzén et al., 2022).

Ante este escenario, surge la oportunidad de investigar lenguajes de sistemas modernos como Rust. Investigaciones en computación de alto rendimiento (HPC) sugieren que Rust puede reducir el consumo de energía al eliminar comprobaciones de memoria innecesarias y ofrecer abstracciones de costo cero. Sin embargo, su uso para orquestar pipelines de Deep Learning en el dominio médico permanece subexplorado, existiendo una falta de evidencia empírica que cuantifique si la migración a Rust contribuye significativamente a los objetivos de la Green AI (Ngo et al., 2025).

En respuesta a necesidades clínicas y ambientales, esta investigación tiene como objetivo principal desarrollar y evaluar un modelo de alto rendimiento basado en Rust para el procesamiento masivo de MRI, manteniendo la precisión y rendimiento de los modelos de Deep Learning para la detección de Alzheimer. El presente trabajo se estructura de la siguiente manera: la sección de materiales y métodos detalla la implementación de la metodología CRISP-ML(Q), abarcando desde la adquisición y el tratamiento de los datos hasta el modelado; la sección de resultados presenta el rendimiento de los modelos considerados, así como la mejora obtenida mediante el uso de Rust; finalmente, las secciones de discusión y conclusiones interpretan los resultados y analizan las ventajas de Rust en comparación con la literatura existente.

El presente proyecto se plantea las siguientes preguntas de investigación:

RQ1: ¿Qué arquitectura de clasificación de imágenes MRI ofrece el mejor desempeño para la detección multiclasa de la enfermedad de Alzheimer entre un modelo híbrido CNN + mRMR + KNN, una CNN ligera personalizada y un ensamble basado en VGG-16?

RQ2: ¿La combinación de extracción profunda de características, selección de atributos mediante un enfoque tipo mRMR y clasificación con KNN mejora la capacidad discriminativa frente a



arquitecturas convolucionales entrenadas de extremo a extremo y métodos de ensamble clásicos?

RQ3: ¿Es posible trasladar el modelo de mejor desempeño a un entorno de inferencia de alto rendimiento en Rust manteniendo resultados comparables en exactitud, tiempo de ejecución y uso de recursos respecto a la implementación original en Python?

Materiales y métodos

El presente trabajo hace uso de la metodología CRISP-ML(Q) (Cross-Industry Standard Process for the development of Machine Learning applications with Quality assurance methodology), que es un modelo de proceso diseñado para gestionar el ciclo de vida de proyectos de Machine Learning (Studer et al., 2021). Tradicionalmente, la industria y la academia han utilizado el modelo CRISP-DM (Studer et al., 2021), sin embargo, este se centra en la extracción de conocimiento y no contempla el uso de modelos de Machine Learning que deben inferir decisiones en entornos de producción en tiempo real. CRISP-ML(Q) contempla las siguientes etapas (Ver Figura 1): Comprensión del negocio y datos, preparación de datos, modelado, evaluación, despliegue, monitoreo y mantenimiento.




Figura 1. CRISP-ML(Q)

Fuente: Linda Wehrstein (CRISP-DM ready for Machine Learning Projects)

3.1. Detalles de Reproducibilidad

El conjunto de datos se obtuvo del dataset de Kaggle "Alzheimer's Disease MRI Classification". El conjunto total de 6400 imágenes se dividió en entrenamiento (70%), validación (15%) y prueba (15%). Las imágenes de entrada se redimensionaron de 208 x 176 a 128 x 128 x 3 para su uso en los modelos CNN. Para contrarrestar el desbalance de clases, se implementó una política de aumento de datos que incluyó $rotation_range=10$, $zoom_range=0,05$, $horizontal_flip=True$, y $brightness_range=(0,9; 1,1)$. En la fase de entrenamiento de ADD-Net, se aplicó SMOTETomek únicamente a los datos de entrenamiento para generar muestras sintéticas. El modelo híbrido utilizó



Esta obra está bajo una licencia internacional Creative Commons Atribución-NoComercial-SinDerivadas 4.0. Los autores mantienen los derechos sobre los artículos y por tanto son libres de compartir, copiar, distribuir, ejecutar y comunicar públicamente la obra.

los backbones InceptionV3, ResNet101 y DenseNet121. La configuración óptima para el clasificador KNN fue $metric=manhattan$, $n_neighbors=3$, $selector_k=768$ para la selección de características, y $weights=distance$. ADD-Net fue entrenado con el optimizador Adam (tasa de aprendizaje 10^{-4}), 40 épocas, y tamaño de lote de 32, con *EarlyStopping* (paciencia 8) y *ReduceLROnPlateau* (paciencia 4). El ensamble Master-Slave se basó en *XGBClassifier* ($n_estimators=200$, $learning_rate=0,05$, $max_depth=4$), *DecisionTreeClassifier* ($max_depth=12$, $criterion='entropy'$) y *SVC* ($kernel='poly'$, $degree=3$, $C=1,0$, $probability=True$). Los detalles del entorno (hardware, OS, Python/Rust toolchains) están documentados para la replicación exacta de los benchmarks de despliegue.

Comprensión del negocio y datos

El diagnóstico temprano de la enfermedad de Alzheimer es fundamental, ya que permite intervenciones oportunas para ralentizar la progresión de los síntomas y mejorar la planificación futura de los pacientes (Hasan Saif et al., 2024). Actualmente, las imágenes de resonancia magnética (MRI) se utilizan para detectar atrofia en el hipocampo y otros cambios estructurales que marcan las etapas de la enfermedad (Eroglu et al., 2022). Es por esta razón que los modelos de IA que se entrenen no solo deben ser precisos, sino también confiables, rápidos, y sostenibles ambientalmente.

Para el desarrollo del modelo, se utilizó un conjunto de datos públicos, el cual puede ser obtenido desde la plataforma Kaggle. El dataset consta de 6400 imágenes, distribuidas en 4 categorías (ver Figura 2). También se evidencia un desbalance en las clases, indicando que la mayoría de registros se concentra en los pacientes sin demencia, en contraste con la etapa más avanzada que apenas corresponde al 1% de los registros.

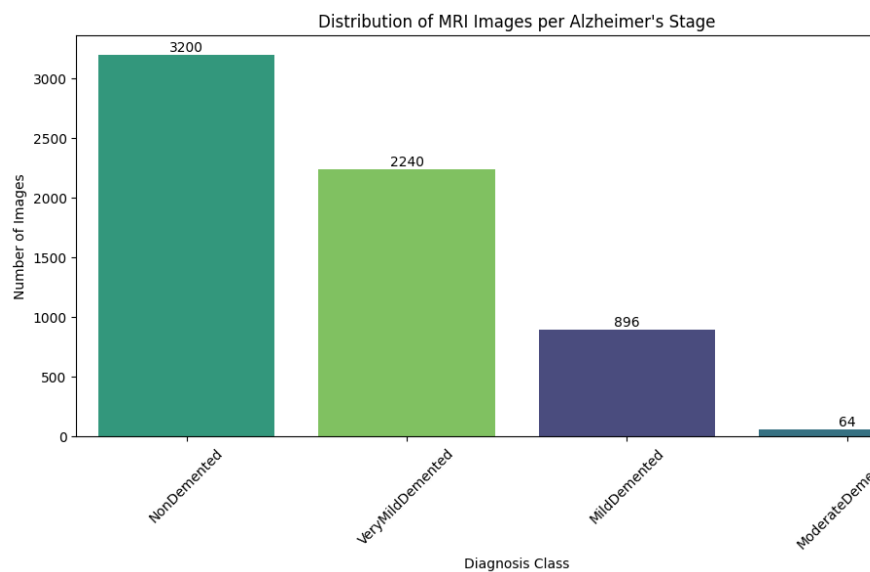


Figura 2. Distribución de clases

Fuente: Los autores

El desbalance de clases es un problema bastante común, ya que casi siempre el número de pacientes sanos supera al número de pacientes con la condición médica a analizar (Fareed et al., 2022).



Esta obra está bajo una licencia internacional Creative Commons Atribución-NoComercial-SinDerivadas 4.0. Los autores mantienen los derechos sobre los artículos y por tanto son libres de compartir, copiar, distribuir, ejecutar y comunicar públicamente la obra.

Todas las imágenes presentes en el dataset constan de las mismas dimensiones, 208 x 176 (ver Figura 3), para todas las clases disponibles.




Figura 3. MRI por categoría

Fuente: Los autores

Preparación de datos

Para el aumento de datos se utilizó el paquete *ImageDataGenerator* (Ali et al., 2025), de la librería Keras, alterando parámetros como el brillo y zoom. Otra de las estrategias fue SMOTETomek, que es una combinación entre SMOTE (Synthetic Minority Over-sampling Technique) (Fareed et al., 2022) que es un algoritmo de sobremuestreo que interpola nuevas muestras sintéticas basándose en los vecinos más cercanos de una misma clase; y TOMK (Tomek Links), que es un algoritmo de submuestreo el cual toma las muestras que están demasiado cerca a la clase minoritaria y las descarta (Swana et al., 2022). La Figura 4 muestra una de las imágenes aumentadas mediante *ImageDataGenerator* de Keras, en donde se puede apreciar las transformaciones en cuanto a ángulo de rotación, contraste y brillo.




Figura 4. Imagen aumentada mediante Keras

Fuente: Los autores

Modelado

En esta etapa se entrenaron 3 modelos de Deep Learning, los mismos que fueron seleccionados



Esta obra está bajo una licencia internacional Creative Commons Atribución-NoComercial-SinDerivadas 4.0. Los autores mantienen los derechos sobre los artículos y por tanto son libres de compartir, copiar, distribuir, ejecutar y comunicar públicamente la obra.

después de un análisis sistemático de la literatura. Los modelos implementados fueron: híbrido entre CNN + mRMR + KNN (Eroglu et al., 2022); ADD-Net (Alzheimer's Disease Detection Network) (Fareed et al., 2022); Master-Slave Ensemble (XGB + DT + SVM) (Khan et al., 2022).

El primer modelo combina extracción de características, selección de variables y aprendizaje basado en vecinos más cercanos. En una primera etapa, cada imagen es preprocesada y redimensionada a 128 x 128 x 3, para luego ser analizada mediante tres arquitecturas convolucionales preentrenadas sobre ImageNet: InceptionV3 (Shah et al., 2023), ResNet101 (Zhang, 2022) y DenseNet121 (Arulananth et al., 2024). A partir de cada red se obtienen descriptores de alto nivel mediante global average pooling, los cuales se concatenan en un único vector de características híbrido con el objetivo de capturar información espacial complementaria. Posteriormente, dado el alto número de atributos generados, se aplica una fase de escalado y una selección de características basada en información mutua, utilizada como aproximación al criterio mRMR, a fin de conservar las variables más relevantes y reducir la redundancia entre ellas. Finalmente, el subconjunto optimizado de características es utilizado como entrada de un clasificador K-Nearest Neighbors (KNN) con $k = 5$ y ponderación por distancia, permitiendo asignar la clase diagnóstica en función de la similitud entre muestras. Este diseño busca aprovechar la capacidad representacional de múltiples CNN profundas y, al mismo tiempo, mantener una etapa de clasificación simple, interpretable y eficiente. La Figura 5 muestra la arquitectura empleada.

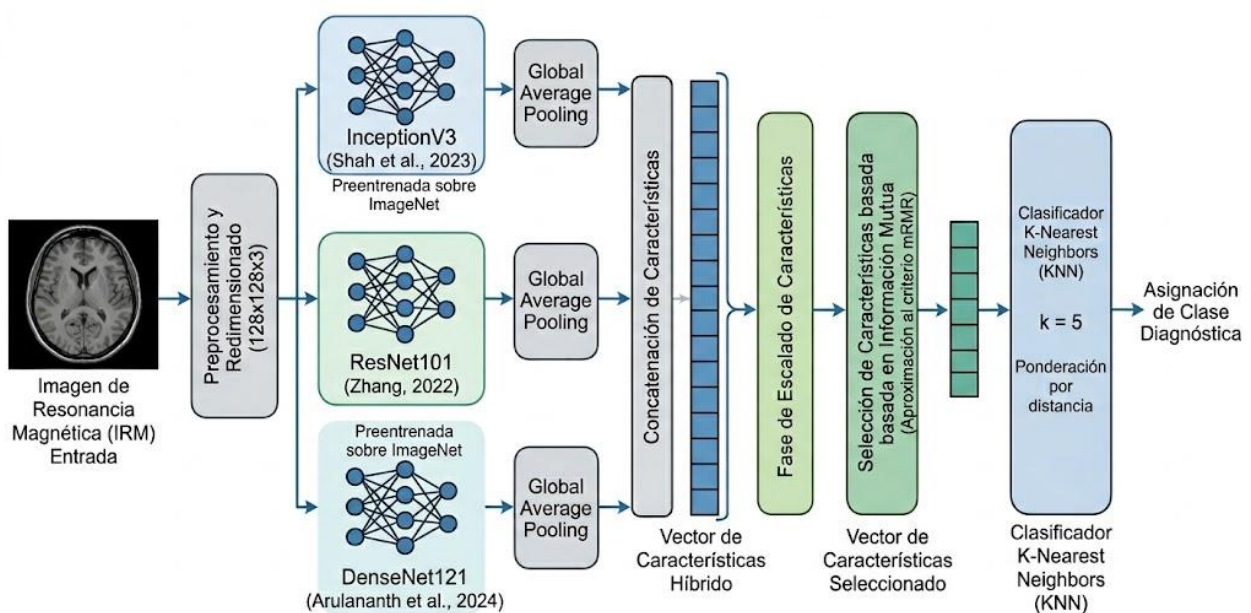


Figura 5. Arquitectura de modelo híbrido de clasificación de imágenes médicas

Fuente: Los autores

El segundo modelo corresponde a ADD-Net (Alzheimer's Disease Detection Network), una red convolucional ligera diseñada específicamente para la clasificación temprana de Alzheimer a partir de imágenes de resonancia magnética (ver Figura 6). A diferencia del primer enfoque híbrido, este modelo realiza un aprendizaje de extremo a extremo mediante una arquitectura propia de cuatro



Esta obra está bajo una licencia internacional Creative Commons Atribución-NoComercial-SinDerivadas 4.0. Los autores mantienen los derechos sobre los artículos y por tanto son libres de compartir, copiar, distribuir, ejecutar y comunicar públicamente la obra.

bloques convolucionales construida con la Keras Funcional API, lo que permite tanto el entrenamiento supervisado como la posterior aplicación de técnicas de interpretabilidad. Previamente, para mitigar el desbalance de clases, las imágenes originales en escala de grises se redimensionan a 128 x 128, se transforman en vectores y se equilibran mediante SMOTETomek. La arquitectura de ADD-Net está compuesta por capas Conv2D con 32, 64, 128 y 256 filtros, acompañadas de BatchNormalization y MaxPooling2D (Ali et al., 2025) en los tres primeros bloques, mientras que el último bloque preserva mayor información espacial para favorecer la interpretabilidad. Luego, se emplea GlobalAveragePooling2D, seguido de una capa densa de 256 neuronas con regularización L2, una capa Dropout de 0,5 y una capa de salida softmax para la clasificación multiclase. Finalmente, el modelo incorpora Grad-CAM (Wang & Zhang, 2023) sobre la última capa convolucional para visualizar las regiones cerebrales que influyen en la predicción, aportando un componente de explicabilidad clínica al sistema.

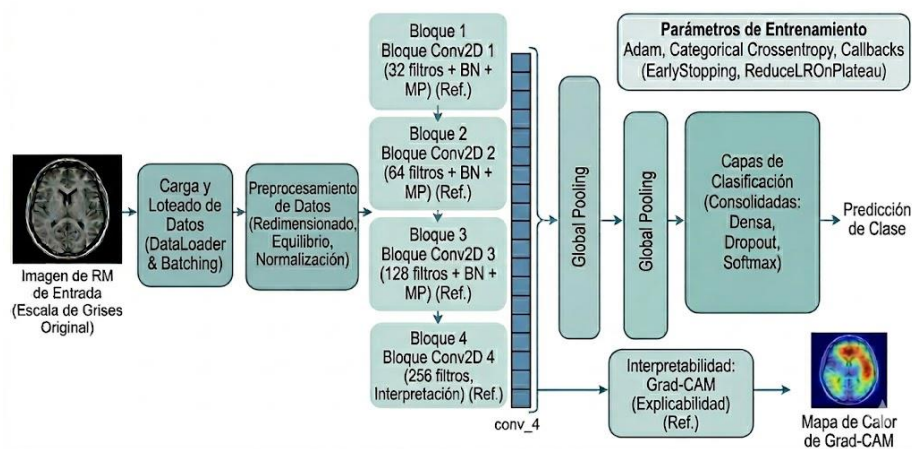


Figura 6. Arquitectura ADD-Net (Alzheimer's Disease Detection Network) para clasificación temprana de Alzheimer

Fuente: Los autores

La Figura 7 muestra el tercer modelo entrenado, el cual corresponde a un ensamble Master-Slave (Khan et al., 2022) basado en extracción profunda de características y clasificación clásica supervisada. Para cada imagen del conjunto balanceado se aplica el preprocesamiento propio de VGG-16 y se obtiene un vector profundo de 512 características, el cual resume la información espacial más relevante. Posteriormente, las etiquetas se codifican con LabelEncoder y las características se normalizan mediante StandardScaler. Sobre estas representaciones se entrena un VotingClassifier con votación suave (soft voting). La lógica del modelo consiste en fusionar las probabilidades predichas por tres clasificadores para producir la decisión final, buscando aprovechar simultáneamente la capacidad de representación de VGG-16, la robustez de los árboles de decisión, la potencia del boosting y la separación no lineal del SVM.



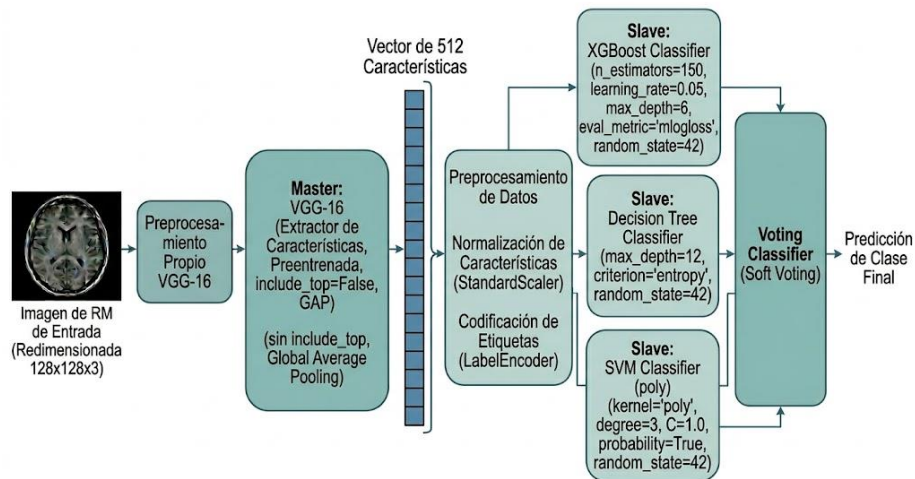


Figura 7. Arquitectura de modelo master-slave

Fuente: Los autores

Resultados

La evaluación de los tres modelos de clasificación se estructura en tres ejes principales para responder a las preguntas de investigación: desempeño predictivo, interpretabilidad clínica y eficiencia computacional.

4.1 Desempeño de clasificación en prueba

Los tres modelos evaluados presentan comportamientos diferenciados en capacidad predictiva. El Modelo Híbrido (CNN + mRMR + KNN) obtuvo el mejor desempeño global, logrando una exactitud de 99,27% y un F1-score ponderado de 0,995 (ver Tabla 1), lo que valida la efectividad de combinar la extracción profunda de características con una etapa de selección de atributos, resolviendo la *RQ1*. Este modelo es robusto, manteniendo un *recall* perfecto incluso en la clase minoritaria *ModerateDemented*. Sin embargo, dado que el subconjunto de prueba para esta clase solo contiene 9 muestras, la solidez estadística de este resultado es frágil, lo cual debe considerarse. El Modelo ADD-Net alcanzó una exactitud de 91,98% y un F1 de 0,932, quedando en segundo lugar. Por su parte, el Ensamble Master-Slave registró la menor exactitud (75,94%; $F1 = 0,699$), evidenciando limitaciones en su capacidad de discriminación frente a las demás alternativas. Estos hallazgos responden la *RQ2* al demostrar la superioridad del enfoque híbrido.



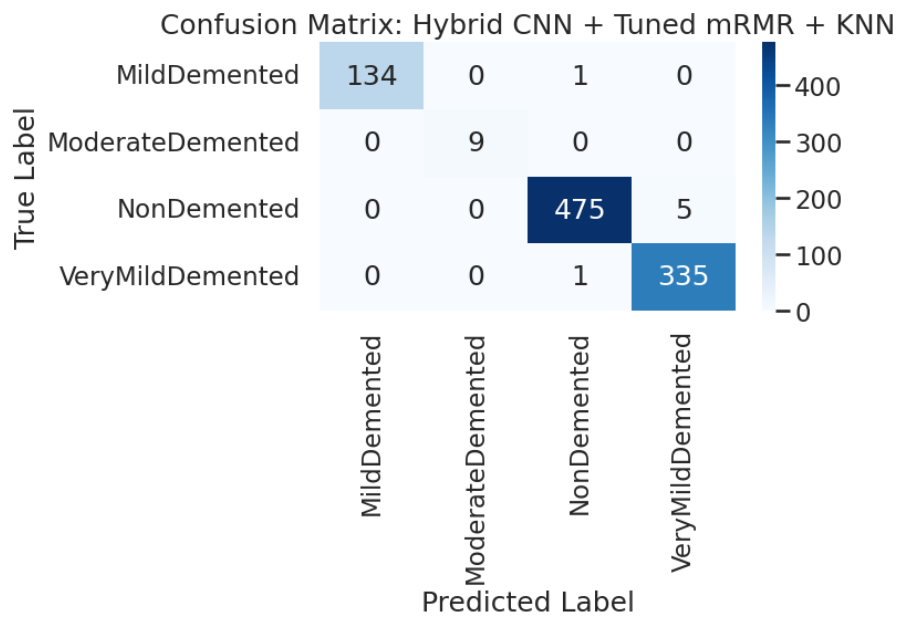


Figura 8. Matriz de confusión modelo híbrido

Fuente: Los autores

El Modelo ADD-Net, pese a su menor desempeño en exactitud bruta, contribuye significativamente al componente de interpretabilidad del estudio. Mediante la aplicación de Grad-CAM sobre la última capa convolucional (ver Figura 9), se visualizan las regiones cerebrales que más influyen en la decisión diagnóstica. Estos mapas de calor (Heatmaps) aportan un valor importante en explicabilidad clínica al sistema, permitiendo justificar las predicciones.




Figura 9. ADD-Net Heatmap

Fuente: Los autores



Tabla 1. Rendimiento promedio de modelos entrenados

Modelo	Exactitud	F1-Score
CNN + mRMR + KNN	0,9927	0,995
Rest	0,9198	0,932
Ejection	0,7594	0,699

Fuente: Los autores

4.2 Interpretabilidad clínica

Como se puede apreciar, el modelo híbrido de *CNN + mRMR + KNN* ofrece un desempeño consistente sobre todas las clases disponibles en el dataset (ver Tabla 2). Estos resultados demuestran la elevada capacidad discriminativa del modelo para identificar correctamente tanto paciente sanos como diferentes niveles de deterioro cognitivo. Además, la uniformidad de las métricas sugiere que el enfoque híbrido presenta estabilidad y equilibrio en la clasificación multiclase, minimizando errores entre categorías clínicas.

Tabla 2. Rendimiento CNN + mRMR + KNN por clase

Clase	Exactitud	Recall	F1-Score
MildDemented	0,99	0,99	0,99
ModerateDemented	1,00	1,00	1,00
NonDemented	0,99	0,99	0,99
VeryMildDemented	0,99	0,99	0,99

Fuente: Los autores

4.3 Despliegue y eficiencia computacional

La implementación de inferencia en Rust demostró una superioridad significativa en términos de eficiencia, resolviendo la *RQ3*. En el *benchmark* de despliegue, Rust redujo el tiempo de inferencia de *12,36 s* (Python ONNX) a *3,14 s* y elevó el rendimiento de *10,36 a 40,70 imágenes por segundo*. Este incremento representa una mejora de rendimiento de más del 300% respecto a la implementación optimizada en Python, lo que valida su potencial como solución de *Green AI* para el procesamiento masivo de imágenes. La única desventaja fue una pérdida de exactitud de *1,56 puntos porcentuales* al migrar, lo cual se atribuye a discrepancias en el preprocesamiento antes de la inferencia con ONNX. La Tabla 3 resume la comparativa.

Tabla 3. Comparativa de Rendimiento de Despliegue

Entorno	Tiempo (s)	Rendimiento (img/s)	Exactitud
Python (ONNX)	12,36	10,36	0,9766
Rust (ONNX)	3,14	40,7	0,9609

Fuente: Los autores

DISCUSIÓN

Los resultados obtenidos en el presente trabajo se alinean con la investigación llevada a cabo por Eroglu (Eroglu et al., 2022). En su trabajo, el modelo híbrido de red neuronal convolucional y KNN obtuvo un rendimiento superior a otros modelos individuales, alcanzando un pico de precisión de *99,1%*. El uso del modelo ADD-Net si bien en los resultados obtenidos alcanza una precisión *89,6%*, en su publicación original este llega hasta *98,63%* (Fareed et al., 2022). Esta diferencia en



rendimiento puede deberse a múltiples factores, entre ellos el preprocesamiento que se le dio a los datos o la misma naturaleza de los mismos, ya que la publicación original hacía un uso exhaustivo del algoritmo SMOTETOMEK. El modelo en donde existe la mayor brecha de rendimiento en cuanto a su publicación original es el *Master-Slave Ensemble*, dado que en el presente trabajo obtuvo una precisión promedio de 71,77% mientras que en los resultados obtenidos por el autor original este llega hasta 95,75% (Khan et al., 2022). Cabe mencionar que el autor original hace un uso bastante agresivo del algoritmo *Grid Search* para encontrar los hiperparámetros más óptimos para el modelo, lo cuál si bien podría mejorar la precisión en el dataset actual, no se alinea con el objetivo de *Green AI* de la presente investigación.

CONCLUSIONES

El presente estudio ha demostrado que el enfoque híbrido basado en CNN + mRMR + KNN constituye una alternativa sólida para la detección de deterioro cognitivo, ofreciendo una capacidad de discriminación elevada y un desempeño global superior en clasificaciones multiclase. La comparación entre las implementaciones de inferencia en Python y Rust ha evidenciado que ambas plataformas son viables para el procesamiento de imágenes de resonancia magnética cerebral con fines diagnósticos. Sin embargo, se destaca la importancia de preservar la fidelidad al flujo original del modelo para evitar degradaciones en la calidad predictiva. En este sentido, Python resultó ser más idóneo debido a su mayor capacidad para alcanzar niveles de exactitud altos sin sacrificar rendimiento computacional. En última instancia, el trabajo presentado no solo valida la eficacia del modelo híbrido propuesto para el apoyo al diagnóstico temprano de Alzheimer, sino que también contribuye al desarrollo de tecnologías de inteligencia artificial más robustas y precisas en la detección de enfermedades neurológicas. La investigación aquí presentada ofrece una plataforma sólida para futuras investigaciones enfocadas en mejorar las herramientas de diagnóstico temprano y personalizado del Alzheimer a través de imágenes de resonancia magnética cerebral.

REFERENCIAS BIBLIOGRÁFICAS

- Afzal, S., Maqsood, M., Khan, U., Mehmood, I., Nawaz, H., Aadil, F., Young Song, O., & Nam, Y. (2021). Alzheimer Disease Detection Techniques and Methods: A Review. *International Journal of Interactive Multimedia and Artificial Intelligence*, 6(7), 26–38. <https://doi.org/10.9781/ijimai.2021.04.005>
- Ali, H., Shifa, N., Benlamri, R., Farooque, A. A., & Yaqub, R. (2025). A fine tuned EfficientNet-B0 convolutional neural network for accurate and efficient classification of apple leaf diseases. *Scientific Reports*, 15(1), 25732. <https://doi.org/10.1038/s41598-025-04479-2>
- Arulananth, T. S., Prakash, S. W., Ayyasamy, R. K., Kavitha, V. P., Kuppusamy, P. G., & Chinnasamy, P. (2024). Classification of Paediatric Pneumonia Using Modified DenseNet-121 Deep-Learning Model. *IEEE Access*, 12, 35716–35727. <https://doi.org/10.1109/ACCESS.2024.3371151>
- Barbierato, E., & Gatti, A. (2024). Toward Green AI: A Methodological Survey of the Scientific Literature. *IEEE Access*, 12, 23989–24013. <https://doi.org/10.1109/ACCESS.2024.3360705>
- Battineni, G., Chintalapudi, N., & Amenta, F. (2024). Machine Learning Driven by Magnetic Resonance Imaging for the Classification of Alzheimer Disease Progression: Systematic Review and Meta-Analysis. *JMIR Aging*, 7, e59370. <https://doi.org/10.2196/59370>



- Eroglu, Y., Yildirim, M., & Cinar, A. (2022). mRMR -based hybrid convolutional neural network model for classification of Alzheimer's disease on brain magnetic resonance images. *International Journal of Imaging Systems and Technology*, 32(2), 517–527. <https://doi.org/10.1002/ima.22632>
- Fareed, M. M. S., Zikria, S., Ahmed, G., Mui-Zzud-Din, Mahmood, S., Aslam, M., Jillani, S. F., Moustafa, A., & Asad, M. (2022). ADD-Net: An Effective Deep Learning Model for Early Detection of Alzheimer Disease in MRI Scans. *IEEE Access*, 10, 96930–96951. <https://doi.org/10.1109/ACCESS.2022.3204395>
- Franzén, V., Viktor Franzén, & Carl Östling. (2022). A performance comparison between native C++-CUDA kernels and Rust-CUDA kernels on NVIDIA hardware.
- George, C. M., & Menon, S. (2024). MACHINE LEARNING FOR ALZHEIMER DETECTION: A COMPREHENSIVE APPROACH. (4).
- Hasan Saif, F., Al-Andoli, M. N., & Bejuri, W. M. Y. W. (2024). Explainable AI for Alzheimer Detection: A Review of Current Methods and Applications. *Applied Sciences*, 14(22), 10121. <https://doi.org/10.3390/app142210121>
- Khan, Y. F., Kaushik, B., Chowdhary, C. L., & Srivastava, G. (2022). Ensemble Model for Diagnostic Classification of Alzheimer's Disease Based on Brain Anatomical Magnetic Resonance Imaging. *Diagnostics*, 12(12), 3193. <https://doi.org/10.3390/diagnostics12123193>
- Liquan Zhao, L. W. (2022). A new lightweight network based on MobileNetV3. *KSII Transactions on Internet and Information Systems*, 16(1). <https://doi.org/10.3837/tiis.2022.01.001>
- Mahasin, M., & Dewi, I. A. (2022). Comparison of CSPDarkNet53, CSPResNeXt-50, and EfficientNet-B0 Backbones on YOLO V4 as Object Detector. *International Journal of Engineering, Science and Information Technology*, 2(3), 64–72. <https://doi.org/10.52088/ijesty.v2i3.291>
- Ngo, D., Park, H.-C., & Kang, B. (2025). Edge Intelligence: A Review of Deep Neural Network Inference in Resource-Limited Environments. *Electronics*, 14(12), 2495. <https://doi.org/10.3390/electronics14122495>
- Shah, S. R., Qadri, S., Bibi, H., Shah, S. M. W., Sharif, M. I., & Marinello, F. (2023). Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50: A Case Study on Early Detection of a Rice Disease. *Agronomy*, 13(6), 1633. <https://doi.org/10.3390/agronomy13061633>
- Studer, S., Bui, T. B., Drescher, C., Hanuschkin, A., Winkler, L., Peters, S., & Müller, K.-R. (2021). Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology. *Machine Learning and Knowledge Extraction*, 3(2), 392–413. <https://doi.org/10.3390/make3020020>
- Swana, E. F., Doorsamy, W., & Bokoro, P. (2022). Tomek Link and SMOTE Approaches for Machine Fault Classification with an Imbalanced Dataset. *Sensors*, 22(9), 3246. <https://doi.org/10.3390/s22093246>
- Wang, S., & Zhang, Y. (2023). Grad-CAM: Understanding AI Models. *Computers, Materials & Continua*, 76(2), 1321–1324. <https://doi.org/10.32604/cmc.2023.041419>
- Zhang, Q. (2022). A novel ResNet101 model based on dense dilated convolution for image classification. *SN Applied Sciences*, 4(1), 9. <https://doi.org/10.1007/s42452-021-04897-7>

