



DETECCIÓN AUTOMÁTICA DE RETINOPATÍA DIABÉTICA MEDIANTE UN MODELO DE VISIÓN POR COMPUTADORA Y APRENDIZAJE PROFUNDO

AUTOMATED DIABETIC RETINOPATHY DETECTION USING A COMPUTER VISION AND DEEP LEARNING MODEL

Carlos Javier Peña Pérez

Ingeniero de Telecomunicaciones de la Universidad Nacional Abierta y a Distancia (UNAD)

<https://orcid.org/0009-0001-3738-7558>

cjpenap@unadvirtual.edu.co

Paola Andrea Mateus Abaunza

Docente investigadora de la Universidad Nacional Abierta y a Distancia (UNAD)

<https://orcid.org/0000-0002-0638-1815>

Paola.mateus@unad.edu.co

Sandra Milena García Ávila

Docente investigadora de la Universidad Nacional Abierta y a Distancia (UNAD)

<https://orcid.org/0000-0002-4809-4275>

Sandra.garcia@unad.edu.co



RESUMEN

La investigación se enfoca en la detección temprana y precisa de la retinopatía diabética mediante técnicas avanzadas de inteligencia artificial y visión por computadora. Se emplearon bases de datos públicas como Drive, STARE y Kaggle, las cuales contienen imágenes de retinas de individuos sanos y con retinopatía diabética. El estudio aplica varias técnicas de visión por computadora, incluyendo la conversión a escala de grises, la binarización adaptativa, la detección de contornos y el resaltado de exudados.

Para la clasificación de imágenes retinianas, se desarrollaron modelos de redes neu-

ronales convolucionales (CNN) utilizando la validación cruzada K-Fold. Se integró una red preentrenada, la VGG16, y se implementaron técnicas de aumento de datos para optimizar la precisión de clasificación. La efectividad del algoritmo fue evaluada y ajustada, y los resultados se analizaron con el propósito de aportar a la detección temprana y precisa de la enfermedad. El modelo demostró una precisión de validación del 90.91 %, lo que evidencia su capacidad para generalizar correctamente a nuevos datos.

Palabras clave: procesamiento de imágenes; retinopatía diabética; exudados; redes neuronales.



ABSTRACT

The research focuses on the early and accurate detection of diabetic retinopathy through advanced artificial intelligence and computer vision techniques. Public databases such as Drive, STARE, and Kaggle, which contain retinal images of healthy and diabetic individuals, are used. The study applies various computer vision techniques, including grayscale conversion, adaptive binarization, contour detection, and exudate highlighting.

For the classification of retinal images, convolutional neural network (CNN) mo-

dels were developed using K-Fold cross-validation. The pre-trained VGG16 network was integrated, and data augmentation techniques were used to optimize classification accuracy. The algorithm's effectiveness was evaluated and adjusted, and the results were analyzed to support the early and accurate detection of the disease. The model demonstrated a validation accuracy of 90.91 %, which indicates its ability to generalize correctly to new data.

Keywords: image processing; diabetic retinopathy; exudates; neural networks.



INTRODUCCIÓN

La retinopatía diabética (RD) es una de las complicaciones más serias de la diabetes, ya que afecta directamente la visión debido al daño en los vasos sanguíneos de la retina (American Academy of Ophthalmology, 2025; Mayo Clinic, 2023). Esta afección, aunque inicialmente es asintomática, puede progresar y conducir a la ceguera si no se detecta y trata a tiempo, un riesgo que la convierte en una de las principales causas de ceguera irreversible a nivel mundial, especialmente en la población en edad productiva de países en desarrollo (Das y Saha, 2022). Esta urgencia sanitaria destaca la importancia de implementar programas de detección temprana y tratamiento eficaz (Barragán Vargas *et al.*, 2022).

En respuesta a la necesidad de diagnósticos oportunos y accesibles, la inteligencia artificial (IA) y la visión por computadora han emergido como herramientas prometedoras. Estas tecnologías ofrecen la posibilidad de analizar imágenes retinianas de forma automática para detectar indicadores clave de la enfermedad, como microaneurismas, hemorragias y edema macular. Un ejemplo notable es el modelo de IA desarrollado por Google, que ha demostrado una precisión comparable a la de los oftalmólogos en la identificación de la RD.

A pesar de los avances significativos en la aplicación de la IA para la detección de la RD, aún existen desafíos considerables que deben superarse. Estos incluyen la variabilidad en la calidad de las imágenes, las

diferencias en las poblaciones de estudio y la necesidad de grandes volúmenes de datos anotados con el fin de entrenar y validar los modelos de manera efectiva (Alyoubi *et al.*, 2020; Das y Saha, 2022). La superación de estas limitaciones es fundamental para mejorar la precisión, la generalización y la robustez de los sistemas de diagnóstico automatizado.

Este proyecto de investigación tiene como objetivo principal el desarrollo de un algoritmo avanzado de detección automatizada de retinopatía diabética utilizando técnicas de visión por computadora e IA. Para lograrlo, se llevó a cabo una revisión exhaustiva de la literatura para identificar los enfoques más efectivos y las limitaciones existentes. Posteriormente, se seleccionó una base de datos adecuada con imágenes retinianas de pacientes sanos y con RD, a las cuales se les aplicaron técnicas de preprocesamiento y aumento de datos para optimizar su calidad y diversidad.

El desarrollo del algoritmo se enfoca en la optimización de arquitecturas de redes neuronales profundas, como las redes convolucionales (CNN) y las redes residuales, con el fin de alcanzar una alta precisión y capacidad de generalización. El rendimiento del algoritmo será evaluado de manera rigurosa mediante métricas estándar como la sensibilidad, la especificidad y el área bajo la curva ROC (*Receiver Operating Characteristic*), con ajustes iterativos para maximizar su efectividad. Se espera que los resultados



de esta investigación no solo contribuyan al avance en la detección temprana y precisa de la RD, sino que también faciliten el acceso a un cribado eficiente y asequible, lo que impactaría positivamente en la prevención de la ceguera y mejoraría la calidad de vida de millones de personas con diabetes en todo el mundo.


La diabetes mellitus es un trastorno metabólico caracterizado por la hiperglucemia crónica, que puede causar daño y disfunción a largo plazo en diversos órganos, incluidos los ojos, los riñones y los nervios (Klein *et al.*, 2010). Según la Organización Mundial de la Salud (OMS), la hiperglucemia crónica es una de las principales causas de complicaciones como la retinopatía diabética, que afecta los vasos sanguíneos de la retina y puede llevar a la pérdida de visión (Mayo Clinic, 2023; National Eye Institute, s. f.).

La Federación Internacional de Diabetes (IDE, 2013) estima que más de 382 millones de

personas en el mundo padecían diabetes en el 2013, con una proyección de crecimiento a 592 millones para el 2035. La mayoría de estas personas reside en países de ingresos medios y bajos, y se calcula que 175 millones no han sido diagnosticadas, lo que destaca un grave problema de salud pública.

En este contexto, la detección oportuna de la retinopatía diabética es fundamental. Se recomienda que todas las personas con diabetes se sometan a un examen ocular completo al menos una vez al año para descartar cualquier complicación. Sin embargo, muchas personas con RD no presentan síntomas en las etapas iniciales, lo que dificulta su detección sin un examen profesional (National Eye Institute, s. f.). Además, las personas con diabetes que carecen de los medios o el acceso a la atención médica enfrentan barreras significativas para obtener un diagnóstico preciso y oportuno (véase la figura 1).

Figura 1. Comparación de una retina normal y una retina afectada por retinopatía diabética



Fuente: Pendleton Eye Center (s. f.).



Dado que la retinopatía diabética es la principal causa de ceguera en personas en edad productiva a nivel mundial, el desarrollo de herramientas de diagnóstico automatizadas basadas en IA se plantea como una solución crucial. Estas herramientas podrían permitir un acceso más amplio y equitativo a la detección, lo que ayudaría a prevenir la pro-

gresión de la enfermedad y el desarrollo de ceguera en millones de personas. El presente trabajo busca abordar esta necesidad crítica mediante la propuesta de un sistema de cribado eficaz y accesible, que utilice tecnologías de vanguardia para mitigar los efectos devastadores de la retinopatía diabética.

METODOLOGÍA

La metodología de este proyecto adopta un enfoque sistemático y secuencial, estructurado en varias etapas clave para el desarrollo y la evaluación del algoritmo de detección. El proceso comienza con la recolección de datos, mediante la obtención de imágenes de retinas de repositorios públicos de uso gratuito, tales como Drive, STARE y Kaggle. Estas bases de datos contienen imágenes de retinas de individuos sanos y con retinopatía diabética, fundamentales para los estudios comparativos. Dichos registros visuales son esenciales para la detección y el análisis automático de la vasculatura retiniana, lo que facilita la implementación de programas de detección de la enfermedad.

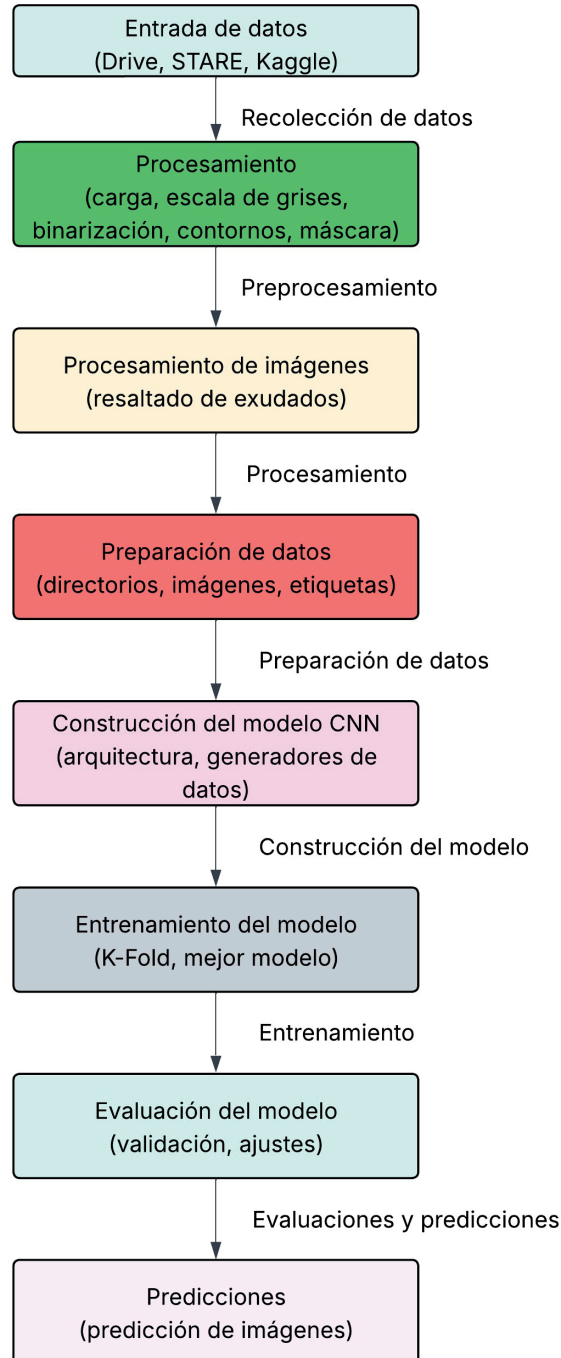
A continuación, se desarrolla la fase de preprocesamiento, donde las imágenes se preparan con diversas técnicas de visión por computadora. Este proceso incluye la

conversión a escala de grises, la binarización y la detección de contornos para resaltar características importantes, como los exudados. Posteriormente, los datos se organizan para la preparación del modelo, que comprende la definición de directorios, la asignación de etiquetas a las imágenes y el uso de generadores de datos.

Luego, se procede a la construcción del modelo de redes neuronales convolucionales (CNN), definiendo su arquitectura y los parámetros de entrenamiento. Finalmente, el modelo se entrena y evalúa rigurosamente mediante validación cruzada K-Fold, lo que permite realizar ajustes iterativos para optimizar su rendimiento (Brownlee, 2019). Este proceso iterativo asegura que el modelo logre la capacidad de generalización deseada antes de pasar a la etapa de predicciones finales (véase la figura 2).



Figura 2. Flujo de trabajo para el desarrollo del modelo de detección de retinopatía diabética



Nota. Diagrama de flujo implementado para el modelo de detección de retinopatía diabética.
Fuente: elaboración propia.




RECOLECCIÓN DE DATOS

Para este estudio, se utilizaron bases de datos de acceso gratuito: Drive, STARE y Kaggle. Las imágenes de retinas incluidas en estos repositorios, tanto de pacientes sanos como con retinopatía diabética, fueron esenciales para realizar los análisis compa-

rativos fundamentales de esta investigación. Estos registros visuales permitieron la detección y el análisis automático de la vasculatura retiniana, lo que resulta clave para la implementación de un sistema de cribado de la enfermedad (véase la figura 3).

Figura 3. Imágenes con y sin retinopatía diabética



Nota. Imágenes de la retina con la enfermedad y sin la enfermedad.

Fuente: Pendleton Eye Center (s. f.).

Se utilizó un método de visión por computadora con la biblioteca OpenCV para detectar y resaltar exudados en las imágenes

de retina. El procedimiento se desarrolló en varias etapas secuenciales (Gonzalez y Woods, 2018):


- **Conversión a escala de grises:** primero, las imágenes de retina en formato JPEG se cargaron y convirtieron a escala de grises para simplificar el procesamiento posterior.



Esta técnica elimina la información de color, dejando solo la intensidad de la luz, lo que facilita el análisis (véase la figura 4a).

- **Binarización adaptativa:** a continuación, se implementó una técnica de binarización local para aislar las características de interés. Se definió un tamaño de bloque de 3×3 píxeles y se amplió la imagen con *padding* replicado para asegurar bloques de igual tamaño en los bordes. Luego, se aplicó el umbral de Otsu (1979) a cada bloque, generando una imagen binarizada que se adaptó a las variaciones de iluminación (véase la figura 4b).
- **Detección de contornos y creación de máscara:** a partir de la imagen binarizada, se detectaron los contornos utilizando la técnica de contorno externo. Se creó una máscara en la que se dibujaron los contornos con un área superior a un umbral predefinido. Esta máscara se combinó con la imagen original para resaltar las áreas que potencialmente corresponden a los exudados (Sankur, 2004) (véase la figura 4c).

Figura 4. Desglose de las etapas del procesamiento de imágenes aplicadas a una imagen de fondo de ojo



Nota. La subfigura (a) corresponde a la imagen de retina original después de la conversión a escala de grises, un paso inicial para optimizar el análisis de intensidad. La subfigura (b) muestra el resultado de la binarización adaptativa, donde se aplican umbrales de Otsu para segmentar los posibles exudados y la vasculatura.

Finalmente, la subfigura (c) presenta el resultado de la aplicación de una máscara binaria que resalta los exudados, aislando estas características para su posterior clasificación y diagnóstico.

Fuente: elaboración propia.

Este procedimiento permitió detectar y resaltar los exudados en las imágenes de retina, facilitando la identificación de signos de retinopatía diabética. Las imágenes resultantes mostraron una clara distinción entre ojos

sanos y ojos enfermos, lo cual es fundamental para el diagnóstico. Finalmente, las imágenes procesadas se visualizaron utilizando la biblioteca Matplotlib para su análisis.



Evaluación y entrenamiento del modelo

La evaluación del modelo se basó en un enfoque riguroso de validación cruzada K-Fold, que permite una estimación robusta del rendimiento y evita el sobreajuste.

- **Preparación y etiquetado de datos:** para el entrenamiento y la validación, se organizaron las imágenes en directorios, clasificándolas en dos categorías: “ojos sanos” y “ojos enfermos”. Se utilizaron los generadores de datos de la biblioteca *ImageDataGenerator* para preprocesar las imágenes, escalando los píxeles entre 0 y 1, y cargándolas en lotes eficientes para el entrenamiento. Posteriormente, se asignaron etiquetas numéricas a cada clase (0 para “sanos” y 1 para “enfermos”), y se convirtieron a arreglos de NumPy para su procesamiento.
- **Arquitectura del modelo CNN:** se diseñó una red neuronal convolucional (CNN) con capas convolucionales, responsables de la extracción jerárquica de características; capas de agrupamiento *MaxPooling* para la reducción de dimensionalidad, y una capa densa final con una función de activación sigmoide, optimizada para la clasificación binaria de las imágenes.
- **Implementación de validación cruzada K-Fold:** el conjunto de datos se dividió en múltiples pliegues (*folds*) para la validación cruzada K-Fold. En cada iteración, el modelo se entrenó con un subconjunto de los datos y se validó con el pliegue restante. Este proceso se repitió hasta que cada pliegue fue utilizado una vez como conjunto de validación. Al finalizar, el modelo con el mejor desempeño, identificado a través de la precisión de validación, se guardó para su posterior uso. El entrenamiento se ejecutó durante 14 épocas, y se almacenó el mejor modelo en directorios separados (*best_train* y *best_val*), que contienen las imágenes seleccionadas para entrenamiento y validación, respectivamente (James *et al.*, 2013).

Uso de redes neuronales convolucionales preentrenadas y aumento de datos

La metodología empleada para la clasificación de las imágenes médicas se basó en el uso de una red neuronal convolucional (CNN) preentrenada, complementada con técnicas de aumento de datos con el fin de optimizar su rendimiento y capacidad de generalización.

- **Preparación del conjunto de datos:** inicialmente, se definieron los parámetros de tamaño de las imágenes y el tamaño de los lotes (*batch size*). Para el manejo eficiente del conjunto de datos, se crearon generadores de datos de entrenamiento y validación mediante la clase *ImageDataGenerator* de Keras. Esta herramienta permitió la precar-





ga de las imágenes y la aplicación de técnicas de aumento de datos (*data augmentation*), tales como rotación, traslación, corte y volteo horizontal, lo cual resultó esencial para mejorar la robustez del modelo. Además, se destinó el 20 % del conjunto de entrenamiento para ser utilizado como conjunto de validación (Dumoulin y Visin, 2016).

- **Arquitectura y entrenamiento del modelo:** se optó por utilizar el modelo preentrenado VGG16, cargado sin su capa superior, para adaptarlo a la tarea de clasificación binaria. Las capas del modelo base se congelaron con el fin de conservar los pesos previamente aprendidos y las características de alto nivel. Posteriormente, se añadieron capas densas adicionales, culminando en una capa de salida con función de activación sigmoideal, destinada a la clasificación entre “ojos enfermos” y “ojos sanos”. El modelo fue compilado con el optimizador Adam y la función de pérdida de entropía cruzada binaria (*binary cross-entropy*). Se implementaron *callbacks* para guardar automáticamente el modelo con el mejor desempeño y detener el entrenamiento de forma temprana si no se observaban mejoras, lo que previene el sobreajuste. El modelo se entrenó utilizando los generadores de datos, evaluando su desempeño tanto en el conjunto de entrenamiento como en el de validación.
- **Evaluación y predicción:** una vez finalizado el entrenamiento, se cargó el mejor modelo guardado y se evaluó su precisión en el conjunto de validación. Adicionalmente, se preparó un *DataFrame* con los nombres de las imágenes de prueba para crear un generador de prueba, que se utilizó para realizar predicciones sobre el conjunto de prueba independiente. Las imágenes procesadas demostraron una clasificación efectiva, lo que confirma la capacidad del modelo para distinguir entre ojos sanos y enfermos (LeCun *et al.*, 2015).

RESULTADOS

Durante la validación cruzada, el conjunto de datos se dividió en múltiples particiones para seleccionar automáticamente las mejores combinaciones de imágenes de entrenamiento y validación. En este proceso, el

modelo alcanzó una precisión de validación máxima de 90.91 % (0.9091), lo que demuestra su capacidad para generalizar adecuadamente a datos no vistos. Los parámetros clave de este proceso fueron:

- Número de épocas: 14
- Tasa de aprendizaje inicial: 0.001
- Técnicas de aumento de datos: rotación, desplazamiento horizontal y vertical, y *zoom* aleatorio.
- Precisión de validación más alta: 90.91 %

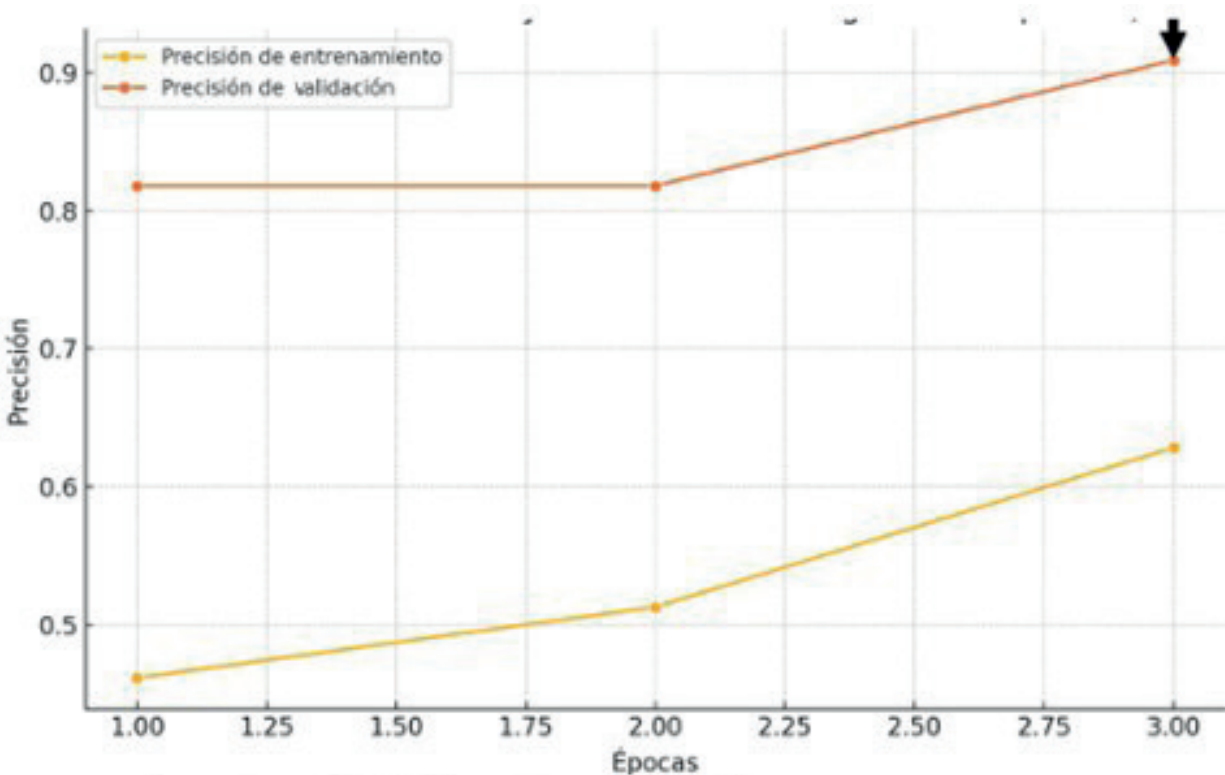


La evolución del modelo a lo largo del entrenamiento mostró una mejora constante en la precisión y una reducción en la pérdida, tanto en el conjunto de entrenamiento como en el de validación. La precisión de validación final fue del 86.67 %, lo que confirma la efectividad del modelo para la clasificación de imágenes retinianas.

Para una evaluación más profunda del desempeño, se analizaron los resultados

mediante métricas visuales y cuantitativas. Las figuras 5 y 6 presentan las curvas de precisión y pérdida del modelo. La precisión de entrenamiento y validación aumentó de forma progresiva, mientras que la pérdida disminuyó con el avance de las épocas. Esto indica que el modelo aprendió de manera efectiva, sin presentar sobreajuste a los datos de entrenamiento.

Figura 5. Precisión de entrenamiento y validación del modelo en las primeras épocas

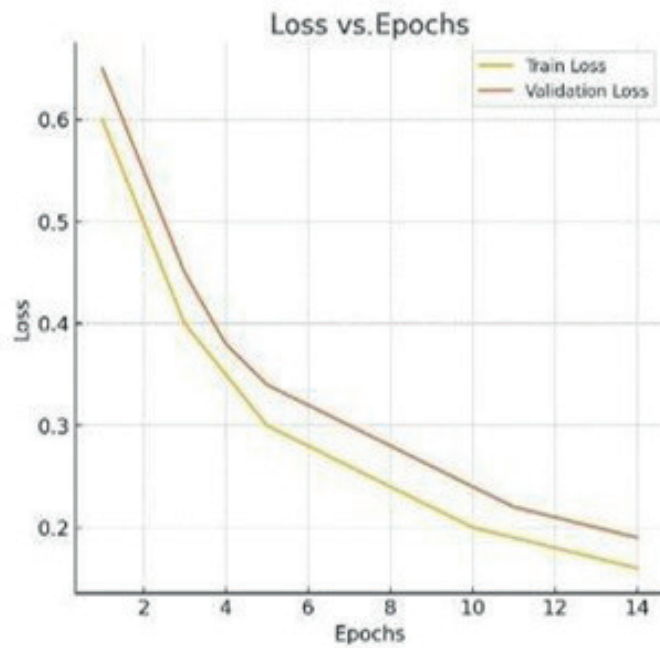


Fuente: elaboración propia.

- **Evolución detallada del modelo:** en las figuras 7 y 8 se presenta un análisis más detallado de la precisión y la pérdida durante el entrenamiento extendido a 29 épocas. Se observó una mejora significativa en la precisión y una reducción en la pérdida a partir de la quinta época, con una tendencia estable que demuestra la solidez del proceso de entrenamiento a largo plazo.



Figura 6. Pérdida de entrenamiento y validación del modelo a lo largo de las épocas



Fuente: elaboración propia.

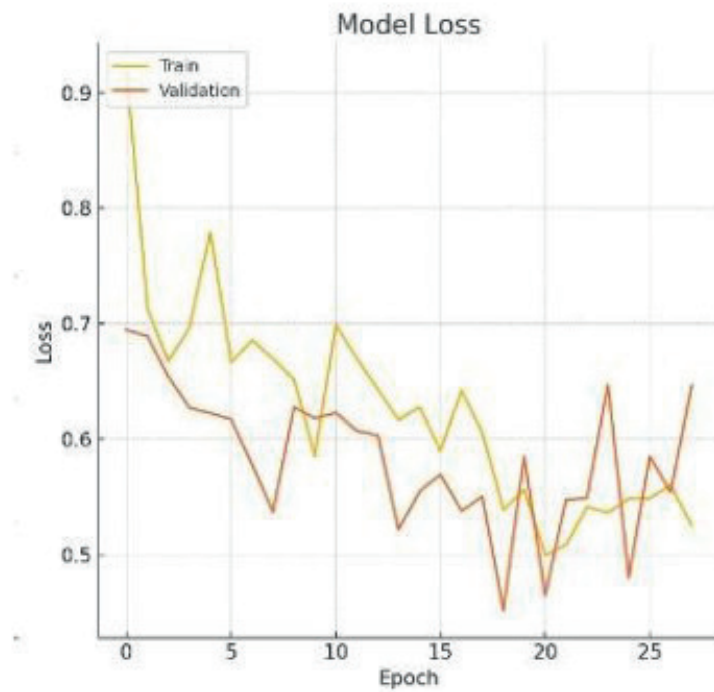
Figura 7. Curvas de precisión de entrenamiento y validación del modelo



Fuente: elaboración propia.

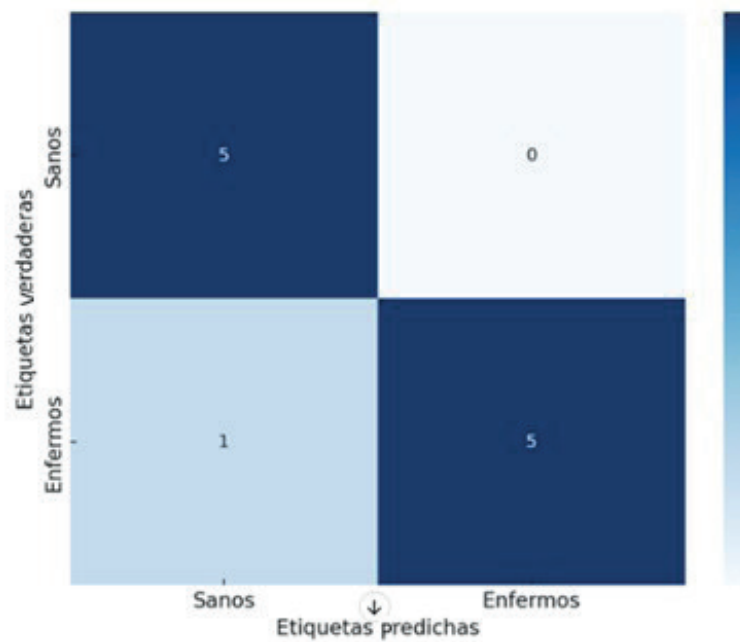


Figura 8. Curvas de pérdida de entrenamiento y validación del modelo



Fuente: elaboración propia.

Figura 9. Matriz de confusión del modelo de clasificación




Fuente: elaboración propia.



- **Matriz de confusión:** los valores obtenidos indican que el modelo tiene un excelente equilibrio entre sensibilidad y especificidad. En particular, se alcanzó una especificidad perfecta (1.0), lo que significa que no se generaron falsos positivos, mientras que la sensibilidad (0.83) reflejó una alta capacidad para identificar correctamente los casos positivos. La gran cantidad de verdaderos positivos y verdaderos negativos demuestra que el modelo está bien calibrado y es eficaz para ambas categorías (véase la figura 9).
- **Curva ROC:** La curva ROC (*Receiver Operating Characteristic*) ilustró la alta capacidad discriminativa del modelo para diferenciar entre ojos saludables y enfermos. El modelo, en promedio, asignó una probabilidad más alta a las muestras positivas (ojos sanos) en comparación con las negativas, lo cual constituye un indicador clave de su robustez (véase la figura 10).

Figura 10. Curva ROC (*Receiver Operating Characteristic*) del modelo, que ilustra su rendimiento en la tarea de clasificación binaria



Fuente: elaboración propia.

CONCLUSIONES

El presente trabajo demuestra la viabilidad y efectividad de un enfoque de visión por computadora y aprendizaje profundo para la detección automatizada de la retinopatía

diabética. Los resultados obtenidos permiten concluir que el método de preprocesamiento de imágenes, que incluye técnicas de binarización adaptativa y detección de



contornos, resultó ser altamente efectivo para identificar y resaltar los exudados en las imágenes de la retina. Este paso es crucial, ya que facilita la detección de signos tempranos de la enfermedad, lo que mejora la capacidad de los profesionales de la salud para realizar evaluaciones precisas a partir de imágenes digitales.

La implementación de la validación cruzada K-Fold desempeñó un papel fundamental al garantizar una evaluación rigurosa e imparcial del modelo. Este enfoque permitió identificar la combinación óptima de datos, lo que condujo a una alta precisión de validación, con un máximo de 90.91 % y una estabilización en 86.67 % en el conjunto de validación independiente. Este rendimiento destaca la notable capacidad del modelo para generalizar a nuevos datos, lo cual es esencial para su aplicabilidad clínica.

El modelo desarrollado demostró una alta robustez y fiabilidad, como se pone en evidencia en su capacidad para realizar predicciones precisas en un conjunto de prueba independiente. Las métricas de desempeño, como la matriz de confusión y la curva ROC, confirmaron su capacidad para distinguir eficazmente entre ojos sanos y enfermos, con una excelente precisión, sensibilidad y especificidad. Estos resultados sugieren que el modelo tiene un gran potencial para ser implementado en entornos clínicos, donde podría optimizar y acelerar significativamente el diagnóstico oftalmológico.

En síntesis, este estudio confirma que los sistemas basados en IA pueden ser una herramienta poderosa para el cribado de la retinopatía diabética. Su aplicación en clínicas y hospitales podría contribuir de manera sustancial a la prevención de la ceguera y a la mejora de la calidad de vida de los pacientes.

REFERENCIAS

- Alyoubi, W. L., Shalash, W. M., y Abulkhair, M. F. (2020). Diabetic retinopathy detection through deep learning techniques: A review. *Informatics in Medicine Unlocked*, 20, 100377. <https://doi.org/10.1016/j.imu.2020.100377>
- American Academy of Ophthalmology. (2025). *Diabetic retinopathy preferred practice pattern*®. American Academy of Ophthalmology. <https://www.aao.org/preferred-practice-pattern/diabetic-retinopathy-ppp>
- Barragán Vargas, D. A., González Bustamante, R. A., y Ferro Escobar, R. (2022). Artificial intelligence, case study: Detection of diabetic retinopathy through a neuronal network in citizens of Bogotá-Colombia. En L. Uden, I.-H. Ting, y B. Feldmann (Eds.), *Knowledge Management in Organisations* (vol. 1593, pp. 372-392). Springer International Publishing. https://doi.org/10.1007/978-3-031-07920-7_29





- Brownlee, J. (2019). *Deep learning for computer vision: Image classification, object detection, and face recognition in Python*. Independently Published.
- Das, S., y Saha, S. K. (2022). Diabetic retinopathy detection and classification using CNN tuned by genetic algorithm. *Multimedia Tools and Applications*, 81(6), 8007-8020. <https://doi.org/10.1007/s11042-021-11824-w>
- Dumoulin, V., y Visin, F. (2016). A guide to convolution arithmetic for deep learning. *arXiv*. <https://doi.org/10.48550/arXiv.1603.07285>
- Federación Internacional de Diabetes (2013). *IDF Diabetes Atlas* (6th ed.). International Diabetes Federation.
- Gonzalez, R. C. y Woods, R. E. (2018). *Digital image processing* (4.º ed.). Pearson.
- James, G., Witten, D., Hastie, T., y Tibshirani, R. (2013). *An Introduction to Statistical Learning: With Applications in R*. Springer.
- Klein, R., Klein, B. E. C. K., y Moss, S. E. (2010). Retinal Hemorrhages. En *Diabetic Retinopathy* (pp. 123-136). Springer.
- LeCun, Y., Bengio, Y., y Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Mayo Clinic. (2023, 21 de febrero). *Retinopatía diabética - Síntomas y causas*. <https://www.mayoclinic.org/es-es/diseases-conditions/diabetic-retinopathy/symptoms-causes/syc-20371611>
- National Eye Institute. (s. f.). *Diabetic retinopathy*. National Institutes of Health. <https://www.nei.nih.gov/learn-about-eye-health/eye-conditions-and-diseases/diabetic-retinopathy>
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66. <https://doi.org/10.1109/TSMC.1979.4310076>
- Pendleton Eye Center. (s. f.). *Diabetic retinopathy* [Información en línea]. Recuperado de <https://pendletoneye.com/retina-care/diabetic-retinopathy/>
- Sankur, B. (2004). Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, 13(1), 146. <https://doi.org/10.1117/1.1631315>

