

# Convolutional Neural Network for glaucoma detection in fundus images

Villegas-Cubas, Juan Elias, Dr<sup>1</sup>, Capuñay-Uceda, Oscar Efraín, Mg<sup>2</sup>, and Celi Arévalo, Ernesto Karlo, Dr<sup>3</sup>

<sup>1,2,3</sup>Grupo de Investigación en Ciencia de Datos, Inteligencia Artificial y Ciberseguridad, Universidad Nacional Pedro Ruiz Gallo, Lambayeque, Perú, jvillegasc@unprg.edu.pe, ocapunayu@unprg.edu.pe, eceli@unprg.edu.pe

**Abstract**– Glaucoma is a silent disease and is the most common cause of irreversible blindness; early detection can prevent cases of blindness and improve the patient's quality of life. This research implements a convolutional neural network (CNN) for glaucoma detection in fundus images. The architecture of the proposed convolutional neural network consists of an input layer that receives an image, seven convolutional layers, five pooling layers, one flattened layer, two fully connected layers, and a two-class output layer. The proposed CNN was trained and tuned with 85 epochs using 3864 fundus images from the LAG dataset. The performance of the proposed CNN was evaluated with 990 images and 96.57% accuracy, 95.73% sensitivity and a specificity of 98.83% were obtained, which represent better performance compared to previous studies.

**Keywords**-- Glaucoma detection, fundus imaging, convolutional neural network

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).  
**ISSN, ISBN:** (to be inserted by LACCEI).  
**DO NOT REMOVE**

# Red Neuronal Convolutacional para la detección de glaucoma en imágenes de fondo de ojo

Villegas-Cubas, Juan Elias, Dr<sup>1</sup>, Capuñay-Uceda, Oscar Efraín, Mg<sup>2</sup>, and Celi Arévalo, Ernesto Karlo, Dr<sup>3</sup>

<sup>1,2,3</sup>Grupo de Investigación en Ciencia de Datos, Inteligencia Artificial y Ciberseguridad, Universidad Nacional Pedro Ruiz Gallo, Lambayeque, Perú, jvillegasc@unprg.edu.pe, ocapunayu@unprg.edu.pe, eceli@unprg.edu.pe

**Resumen-** El glaucoma es una enfermedad silenciosa y es la causa más común de ceguera irreversible, la detección temprana puede prevenir casos de ceguera y mejorar la calidad de vida del paciente. Esta investigación implementa una red neuronal convolutacional (CNN) para la detección de glaucoma en imágenes de fondo de ojo. La arquitectura de la red neuronal convolutacional propuesta consta de una capa de entrada que recibe una imagen, siete capas convolutacionales, cinco capas de agrupación, una capa aplanada, dos capas completamente conectadas y una capa de salida de dos clases. La CNN propuesta se entrenó y afinó con 85 épocas utilizando 3864 imágenes de fondo de ojo del conjunto de datos LAG. Se evaluó el rendimiento de la CNN propuesta con 990 imágenes y se obtuvo 96.57% de exactitud, 95.73% de sensibilidad y una especificidad de 98.83%, que representan un mejor desempeño en comparación con estudios previos.

**Palabras clave-** Detección de glaucoma, imágenes de fondo de ojo, red neuronal convolutacional

## I. INTRODUCCIÓN

El glaucoma es una enfermedad silenciosa que daña el nervio óptico y es la causa más común de ceguera irreversible. Un aproximado de 80 millones de personas en el mundo tenían glaucoma en el año 2020, y se estima que este número aumente a 112 millones de personas al año 2040 [1]. Las personas que viven con deficiencia visual a causa del glaucoma son principalmente porque no recibieron tratamiento oportuno. La detección temprana del glaucoma evitaría en un 95% de los casos de ceguera total de los pacientes [2].

Las herramientas de aprendizaje automático y aprendizaje profundo permiten desarrollar modelos y sistemas que aprenden de un conjunto de datos o imágenes y para luego predecir enfermedades de forma temprana. Se han desarrollado modelos basados en diversos algoritmos como Support Vector Machine (SVM) que logran rendimientos de 92.3% [3], 93.0% [4] y de 89.45% [5] de exactitud; Random Forest que obtiene una exactitud de 90.5% [6]; un sistema EyeDr basado en el algoritmo YOLO logrando una exactitud de 91.2% [7]; otro modelo utilizado es el ResNet50 obteniendo una exactitud de 90.0% [8]; el modelo ResNET-152 que logra un 86.9 % de exactitud [9]; un modelo Deep learning 3D que logró una exactitud de 93,8 % [10]; un modelo de extracción de características de textura multidireccional (MTFE) que obtiene con 90.44% de exactitud [11]; y marcos fusionados de técnicas de machine learning y Deep learning usando Major Voting y Weighted Decision Fusion que logran una exactitud de 95.0% [12].

También se han desarrollado y evaluado una variedad de modelos basados en aprendizaje profundo y específicamente redes neuronales convolutacionales (CNN por sus siglas en inglés) para la detección temprana del glaucoma usando imágenes de fondo de ojo, como el modelo CNN que consiguió una exactitud de 85.0% [13]; el modelo G-EyeNet que obtiene una exactitud de 92.3% [14]; el modelo DCGAN obtiene una exactitud de 90.17% [15]; el modelo ConvNet que logra una exactitud de 88.0% [16]; la llamada CoG-NET [17] con una exactitud de 93.5% y la AG-CNN que obtiene una exactitud de 96.2% [18].

Los estudios previos mencionados en los párrafos anteriores muestran que han sido desarrollados varios modelos de aprendizaje automático y aprendizaje profundo para la detección temprana del glaucoma utilizando imágenes de fondo de ojo; sin embargo, hay limitaciones en el rendimiento de la correcta detección y no han sido lo suficientemente explorados las redes neuronales convolutacionales y las técnicas de procesamiento de imágenes en conjunto, para la detección de glaucoma en imágenes de fondo de ojo con alto rendimiento; por lo que en esta investigación se propone construir una red neuronal convolutacional con técnicas de preprocesamiento de imágenes para la detección de glaucoma en imágenes de fondo de ojo con un alta tasa de exactitud y precisión.

La formulación del problema planteado es ¿Una red neuronal convolutacional con técnicas de procesamiento de imágenes, ayudará a detectar glaucoma en imágenes de fondo de ojo? Por lo que planteamos como objetivo general desarrollar un sistema inteligente basado en una red neuronal convolutacional para la detección temprana de glaucoma en imágenes de fondo de ojo; y para poder cumplir con el objetivo general, se plantean los siguientes objetivos específicos:

- 1) Obtener un conjunto de imágenes de fondo de ojo, etiquetadas con Glaucoma Positivo y Glaucoma Negativo
- 2) Procesar el conjunto de imágenes de fondo de ojo, convirtiendo a una matriz de 150x150 en RGB.
- 3) Construir un modelo CNN para la detección de glaucoma en imágenes de fondo de ojo.
- 4) Evaluar el rendimiento del modelo en la detección temprana de glaucoma en imágenes de fondo de ojo.
- 5) Desarrollar la interfaz de un sistema inteligente que haga uso del modelo CNN para la detección temprana de glaucoma.

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).

**ISSN, ISBN:** (to be inserted by LACCEI).

**DO NOT REMOVE**

## II. BASES TEÓRICAS

El aprendizaje automático o machine learning se define como un tipo de inteligencia artificial que proporciona a un sistema la capacidad de aprender, sin ser explícitamente programado [19]. Son dos los enfoques para los problemas de aprendizaje [20]; el aprendizaje supervisado y el aprendizaje no supervisado; Algunos autores consideran al aprendizaje por refuerzo y al aprendizaje profundo como enfoques adicionales del aprendizaje automático [21].

El aprendizaje supervisado inicia con un conjunto de datos de características y una etiqueta que brinda un significado de los datos [21]. El aprendizaje supervisado tiene como objetivo buscar y reconocer patrones en los datos analizados. Los modelos de aprendizaje supervisado se aplican en una amplia variedad de problemas comerciales, como la detección de fraudes, detección de enfermedades, sistemas de recomendación o reconocimiento de voz.

El aprendizaje profundo o deep learning, es un tipo de aprendizaje que se basa en redes neuronales y se utiliza para problemas más complejos como en los problemas de aprendizaje con imágenes.

Las redes neuronales son un tipo de algoritmos de deep learning o aprendizaje profundo, las arquitecturas más básicas son los perceptrones multicapa (MLP) que sirven tanto para problemas de clasificación y de regresión [20]. En el tratamiento de imágenes las redes neuronales analizan todos los píxeles de la imagen en cambio las redes neuronales convolucionales identifican patrones y son las más eficientes en el trabajo con imágenes. Las redes neuronales convolucionales son un modelo más avanzado de redes neuronales que incluyen en su arquitectura en la parte inicial de la red las denominadas capas de convolución para la detección de ciertos patrones y capas de agrupamiento o pooling que disminuye la dimensionalidad de los parámetros de entrenamiento.

Para medir el rendimiento de los modelos de aprendizaje automático y de una red neuronal convolucional se utilizan diferentes métricas de evaluación [22]. La base informativa para las métricas es la matriz de confusión y a partir de esta matriz se obtienen las métricas de exactitud, precisión, sensibilidad y especificidad [23], se describen a continuación:

1) *Matriz de confusión*: En la Tabla I se muestra la matriz de confusión que es una tabla de frecuencias con las cantidades de aciertos y errores de las predicciones realizadas por el modelo, en comparación con los resultados reales.

TABLA I

MATRIZ DE CONFUSIÓN

	Clase	Predicción del modelo	
		Positivo	Negativo
Resultado Real	Positivo	Verdadero Positivo (VP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadero Negativo (VN)

Los verdaderos positivos (VP), se refiere a la cantidad de pruebas positivas clasificadas correctamente. (una imagen de glaucoma positivo, clasificada correctamente). Los verdaderos negativos (VN), se refiere a la cantidad de pruebas negativas clasificadas correctamente (una imagen de glaucoma negativo clasificada correctamente). Los falsos positivos (FP), se refiere a la cantidad de pruebas positivas clasificadas erróneamente (una imagen de glaucoma negativo, clasificada como imagen de glaucoma positivo); y los falsos negativos (FN) se refiere a la cantidad de pruebas positivas clasificadas erróneamente (imagen de glaucoma positivo, clasificada como imagen de glaucoma negativo)

2) *Exactitud*: Es la métrica más utilizada para medir el rendimiento global de un modelo; es la relación entre la cantidad de elementos clasificados correctamente por el modelo y el número total de pruebas realizadas, se calcula por la fórmula (1).

$$Exactitud = \frac{VP + VN}{VP + FP + FN + VN} \quad (1)$$

2) *Precisión*: El valor de la precisión se define como la proporción de verdaderos positivos contra todos los resultados positivos, es definida por la fórmula (2).

$$Precisión = \frac{VP}{VP + FP} \quad (2)$$

3) *Sensibilidad*: Es la métrica que mide la capacidad del modelo en clasificar como positivo a aquél que efectivamente lo es; El modelo clasifica como clase “Glaucoma Positivo” a las imágenes que verdaderamente son “Glaucoma Positivo”, se calcula por la fórmula (3).

$$Sensibilidad = \frac{VP}{VP + FN} \quad (3)$$

4) *Especificidad*: Es la métrica que mide la capacidad del modelo en clasificar como negativo a aquél que efectivamente lo es, el modelo clasifica como clase “Glaucoma Negativo” a las imágenes que verdaderamente son “Glaucoma Negativo”, se calcula por la fórmula (4).

$$Especificidad = \frac{VN}{VN + FP} \quad (4)$$

## III. MÉTODO

Se utilizaron imágenes de fondo de ojo etiquetadas con las clases: “Glaucoma Positivo” y “Glaucoma Negativo”. Las etapas seguidas en esta investigación inician con la adquisición de las imágenes de fondo de ojo etiquetadas por clases, luego las imágenes son preprocesadas; con las imágenes preprocesadas se entrena y optimiza un modelo de red neuronal convolucional; luego se evalúa el rendimiento en la clasificación de las imágenes y la detección de glaucoma y finalmente se desarrolla una interfaz para la predicción de glaucoma en imágenes de fondo de ojo. En la Fig.1, se resume las etapas seguidas en este trabajo.

## IV. RESULTADOS

### A. Adquisición de imágenes

Se adquiere el conjunto de imágenes de fondo de ojo denominado LAG (Large-scale Attention based Glaucoma) utilizadas por otras investigaciones previas [9] [18] y publicado originalmente por Li y otros [24]. El conjunto de imágenes LAG se encuentran divididas en carpetas, con imágenes para las etapas de entrenamiento y evaluación respectivamente; y están clasificadas de acuerdo con las clases. Como se muestra en la Tabla II, el conjunto de imágenes de fondo de ojo consta en total de 4854 imágenes, de las cuales 3864 (80%) son para entrenamiento y 990 (20%) imágenes son para la evaluación de la red neuronal convolucional. Además, 3143 imágenes corresponden a la clase “Glaucoma Negativo”, y 1711 imágenes corresponden a la clase “Glaucoma Positivo”.

TABLA II

CONJUNTO DE IMÁGENES DE FONDO DE OJO

Imágenes	Total	Porcentaje	Clases	
			Glaucoma Negativo	Glaucoma Positivo
Entrenamiento	3864	80%	2387	1477
Evaluación	990	20%	756	234
Total	4854	100%	3143	1711

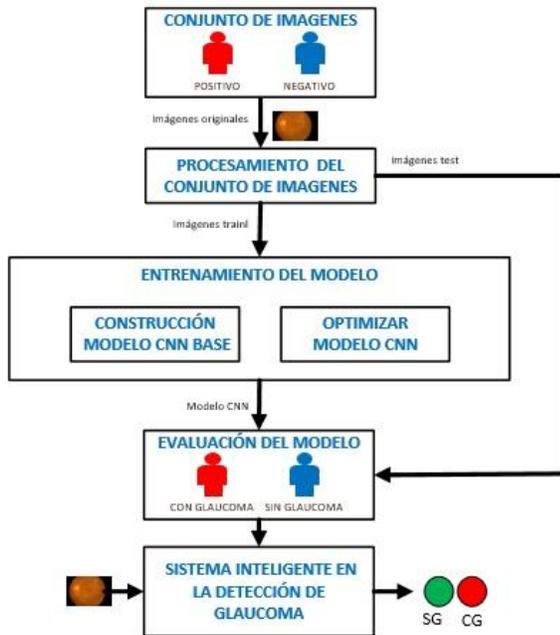


Fig. 1 Etapas de la investigación

A continuación, se describe brevemente cada uno de los pasos seguidos:

1) *Adquisición de imágenes*: Se adquieren las imágenes de fondo de ojo, y se separan en dos carpetas, una con imágenes que estén etiquetadas como imágenes de fondo de ojo de Glaucoma Positivo y otra carpeta con imágenes de Glaucoma Negativo. El etiquetado se realiza por expertos y en esta investigación se toman las imágenes ya etiquetadas.

2) *Procesamiento de imágenes*: Luego de adquirir las imágenes, éstas son procesadas utilizando diferentes técnicas como pasar a escala de grises, normalización, segmentación, etc. Y finalmente son separadas en dos conjuntos de imágenes, una para realizar el entrenamiento del modelo CNN, y otro conjunto de datos para la evaluación del rendimiento. Además, éstas imágenes son pasadas a arreglos para la siguiente etapa.

3) *Entrenamiento del modelo*: Con las imágenes de entrenamiento procesadas se entrena una red neuronal convolucional base, para luego optimizarla probando con diferentes parámetros y validar su curva de aprendizaje, eligiendo una red neuronal convolucional final que obtiene el mejor resultado.

4) *Evaluación del modelo*: La red neuronal convolucional óptima (CNN), es evaluada con el conjunto de imágenes de evaluación (que son imágenes nuevas para el modelo); se utilizaron las diferentes métricas de evaluación como la exactitud, la sensibilidad y la especificidad en la detección de glaucoma.

4) *Interfaz de predicción de glaucoma*: Finalmente se desarrolla una interfaz que cargue el modelo CNN, y que, al ingresar una imagen nueva, el sistema inteligente nos indique si la imagen pertenece a un paciente con Glaucoma Positivo o Glaucoma Negativo.

Se utiliza Jupyter Notebook con Python versión 3.8 como lenguaje de programación para la carga y el preprocesamiento de las imágenes de fondo de ojo, así mismo para el entrenamiento y la evaluación de la red neuronal convolucional. Todos los experimentos se realizan en un mismo ordenador con procesador Intel Core i7 de 2.30GHz, con 16GB de RAM y disco sólido de 1TB.

### B. Procesamiento de imágenes

Se cargan algunas imágenes de fondo de ojo con etiquetas Positivo y otras imágenes con etiquetas negativo; donde se observa que las imágenes son a color en RGB y en formato jpg; y tienen un tamaño de 500x500 píxeles, como se muestra en la Fig. 2.

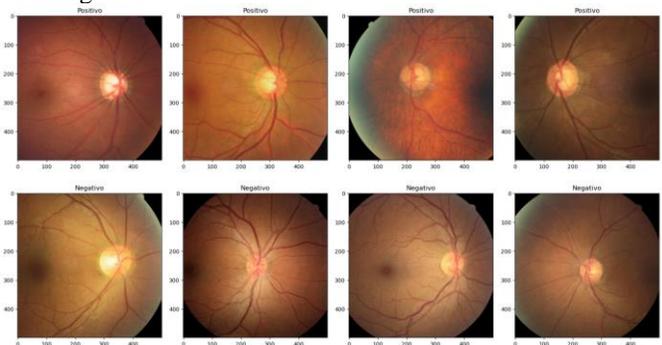


Fig. 2 Visualización de Imágenes de fondo de ojo

Para optimizar el uso de recursos de procesamiento y almacenamiento; reducimos el tamaño de las imágenes a 150x150x3; utilizamos keras y tensorflow para cargar y preprocesar las imágenes en un tensor. El conjunto de imágenes es preprocesado en dos subconjuntos uno para la fase de entrenamiento y optimización de la red neuronal convolucional y otra para la fase de evaluación y pruebas de predicción de la CNN.

### C. Entrenamiento del modelo

La red neuronal convolucional propuesta tiene como propósito recibir como ingreso una imagen de fondo de ojo y brinda como salida la clase a la que corresponde la imagen ingresada (Glaucoma Positivo o Glaucoma Negativo).

Para la construcción de la red neuronal convolucional se utilizó como base la red neuronal convolucional para la detección de diabetes propuesta por Villegas y otros [25] que consiste en una capa de entrada en dimensiones de 150x150x3, con tres capas convolucionales, tres capas de agrupamiento, una capa de aplanamiento, dos capas directamente conectadas y con la salida para dos clases. A esta red neuronal convolucional de referencia se adicionaron capas convolucionales y de agrupamiento y mediante experimentos de prueba y error se obtiene la red neuronal convolucional particular construida en esta investigación.

En la Fig. 3, se muestra la arquitectura de la red neuronal convolucional particular construida en esta investigación, consta de una capa de entrada de 150x150x3 dimensiones que corresponde al tamaño de la imagen en RGB, que recibe como ingreso a las imágenes de fondo de ojo previamente procesadas. Luego pasa por siete capas convoluciones para la extracción de las características de las imágenes, cinco capas de agrupación (pooling), una capa de aplanamiento (flatten) para la conversión en una sola dimensión, con dos capas completamente conectadas y una capa de salida de dos neuronas (una para la clase glaucoma positivo y otra clase para glaucoma negativo).

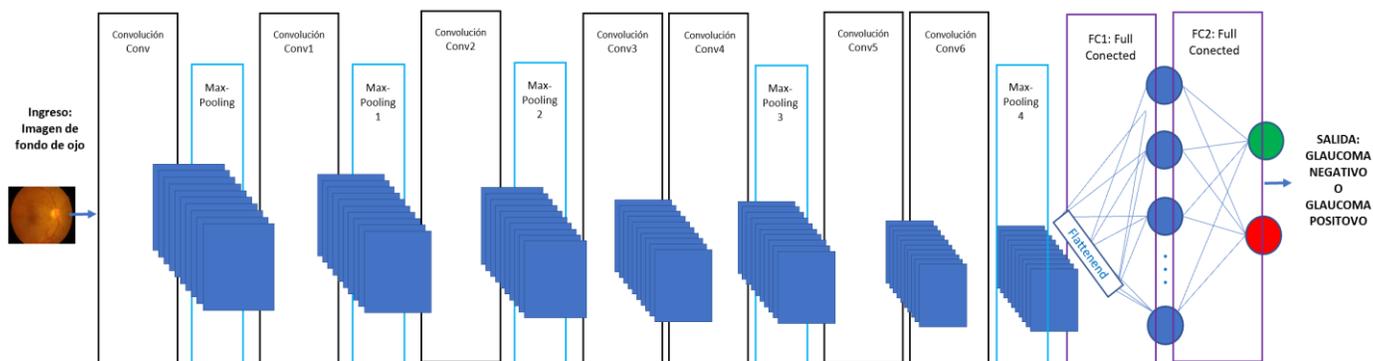


Fig. 3 Arquitectura de la Red Neuronal Convolucional (CNN) propuesta

La red neuronal convolucional particular se implementa en el entorno de programación Jupyter Notebook con el lenguaje Python y la librería de tensorflow, donde se construye cada una de las capas y se obtiene el modelo secuencial que se muestra en la Fig. 4.

```

Model: "sequential"
Layer (type)                Output Shape                Param #
-----
rescaling (Rescaling)       (None, 150, 150, 3)        0
conv2d (Conv2D)              (None, 150, 150, 16)       448
max_pooling2d (MaxPooling2D) (None, 75, 75, 16)         0
conv2d_1 (Conv2D)            (None, 75, 75, 32)         4640
max_pooling2d_1 (MaxPooling2 (None, 37, 37, 32)         0
conv2d_2 (Conv2D)            (None, 37, 37, 64)         18496
max_pooling2d_2 (MaxPooling2 (None, 18, 18, 64)         0
conv2d_3 (Conv2D)            (None, 18, 18, 128)        73856
conv2d_4 (Conv2D)            (None, 18, 18, 128)        147584
max_pooling2d_3 (MaxPooling2 (None, 9, 9, 128)         0
conv2d_5 (Conv2D)            (None, 9, 9, 256)          295168
conv2d_6 (Conv2D)            (None, 9, 9, 256)          590080
max_pooling2d_4 (MaxPooling2 (None, 4, 4, 256)         0
flatten (Flatten)            (None, 4096)                0
dense (Dense)                (None, 256)                 1048832
dropout (Dropout)           (None, 256)                 0
dense_1 (Dense)              (None, 2)                   514
-----
Total params: 2,179,618
Trainable params: 2,179,618
Non-trainable params: 0

```

Fig. 4 Arquitectura de la CNN desarrollada.

La red neuronal convolucional particular construida se entrena con 3063 imágenes de fondo de ojo y se valida el aprendizaje con 801 imágenes, utilizando en total para la etapa de entrenamiento 3864 imágenes de fondo de ojo. El modelo se optimizó buscando el mejor aprendizaje y se afina con 85 épocas para obtener el mejor rendimiento.

En la Fig. 5 se muestra la curva de aprendizaje de la CNN con las imágenes de entrenamiento y con 85 épocas. Se observa que a partir de la época 70 se consigue un resultado de aprendizaje estable y óptimo, logrando un 95.0% de exactitud en la validación del aprendizaje.

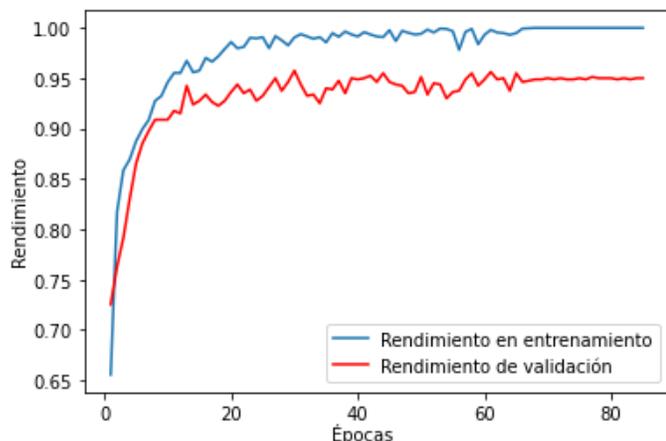


Fig. 5 Curva de aprendizaje de la CNN propuesta

La CNN desarrollada se almacena y queda apta para realizar la evaluación y las predicciones; la CNN recibe de entradas una imagen de fondo de ojo, y como salida predice la clase a la que corresponde la imagen de fondo de ojo, según el aprendizaje obtenido.

#### D. Evaluación del modelo

Para la evaluación del rendimiento de la CNN se utilizan 990 imágenes de fondo de ojo reservadas para la evaluación, de las cuales 234 son de la clase Glaucoma Positivo y 756 de la clase Glaucoma Negativo. En la tabla III se muestra la matriz de confusión de la CNN propuesta para la detección de glaucoma, donde se obtienen 224 Verdaderos Positivos, 10 Falsos Negativos, 24 Falsos Positivos y 732 Verdaderos Negativos.

TABLA III

MATRIZ DE CONFUSIÓN DE LA CNN PROPUESTA

	Clase	Predicción de la CNN		Total
		Glaucoma Positivo	Glaucoma Negativo	
Resultado Real	Glaucoma Positivo	224 (0.96)	10 (0.04)	234
	Glaucoma Negativo	24 (0.03)	732 (0.97)	756

La red neuronal convolucional construida en esta investigación clasifica correctamente a 224 de las 234 de imágenes de glaucoma positivo, que representa el 96% de aciertos en imágenes con glaucoma positivo. Además, la red neuronal convolucional desarrollada clasifica correctamente a 732 de las 756 de imágenes de glaucoma negativo, que representa el 97% de aciertos en imágenes de glaucoma positivo.

Utilizando las fórmulas (1), (2), (3) y (4) calculamos las métricas de exactitud, precisión, sensibilidad y especificidad de la CNN desarrollada en la detección de glaucoma en imágenes de fondo de ojo. En la tabla 4 se muestra los resultados obtenidos.

TABLA IV

MÉTRICAS DE RENDIMIENTO DE LA CNN PROPUESTA

Métrica Evaluada	Resultado
Exactitud	96.57%
Precisión	90.32%
Sensibilidad	95.73%
Especificidad	96.83%

La red neuronal convolucional construida en esta investigación obtiene una exactitud de 96.57% (956/990) en la detección de glaucoma en imágenes de fondo de ojo en forma global. Mostrando una alta tasa de aciertos en la detección de glaucoma con imágenes de fondo de ojo en forma global. Además, se obtiene una precisión de 90.32%; una sensibilidad de 95.73% que corresponde a la tasa de aciertos de la CNN en la detección correcta con imágenes de fondo de ojo de glaucoma positivo; y una especificidad de 96.83%, que corresponde a la tasa de aciertos de la CNN en la detección correcta de imágenes de fondo de ojo de glaucoma negativo.

Finalmente se desarrolla una interfaz donde se hace uso del modelo CNN desarrollado para la detección de glaucoma. En esta interfaz se carga una imagen de fondo de ojo y el sistema utilizando la CNN da como resultado la predicción si la imagen corresponde a una imagen con glaucoma positivo o a una imagen con glaucoma negativo. En la Fig.6, se muestra un ejemplo de una predicción; luego que el usuario carga la imagen de fondo de ojo, en la parte inferior se muestra el resultado de la predicción, en el ejemplo “Glaucoma Positivo”.

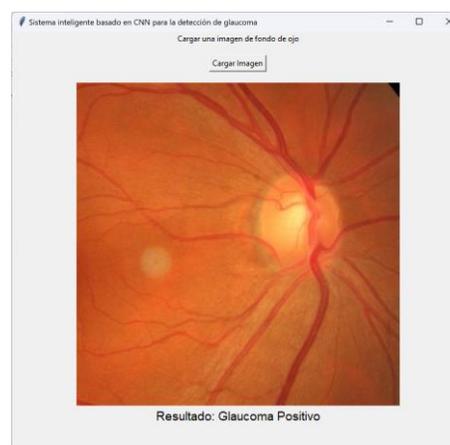


Fig. 6 Interfaz de predicciones de la CNN en la detección de glaucoma

### E. Discusión de resultados

Los resultados de rendimiento obtenidos por la CNN particular construida en esta investigación supera al rendimiento logrado por la investigación de Li y otros [24] que propone inicialmente el conjunto de imágenes LAG y una red neuronal convolucional que obtiene una precisión de 95.3%, sensibilidad de 95.4%, y especificidad de 95.2%.

La CNN propuesta también obtiene mejores resultados que otras investigaciones que usan el mismo conjunto de imágenes LAG, como el trabajo de Sallam y otros [9] que evalúa redes neuronales pre entrenados obteniendo una precisión del 86,9%, sensibilidad del 86,9% y especificidad del 86,9% con el modelo ResNET-152; y con el trabajo realizado por Li y otros [18] que propone una red neuronal convolucional mejorada (AG-CNN) que logra una precisión de 96.2%, sensibilidad de 95.4% y especificidad de 96.7%.

Además, la red neuronal desarrollada en esta investigación obtiene mejor rendimiento que los modelos de aprendizaje automático y de redes neuronales convolucionales de todos los estudios previos mencionados en esta investigación.

La red neuronal convolucional desarrollada en este trabajo ha logrado obtener un muy buen rendimiento en lo global superando a los resultados obtenidos en los estudios previos.

### V. CONCLUSIONES

Se utilizó el conjunto de imágenes de fondo de ojo LAG con un total de 4854 imágenes, de las cuales 3864 son para entrenamiento y 990 imágenes son para la evaluación de la red neuronal convolucional; las imágenes están etiquetadas como glaucoma positivo (1711 imágenes) y glaucoma negativo (3143 imágenes).

Las imágenes originales se preprocesaron, se cambiaron de tamaño y fueron convertidas a un tensor de 150x150x3.

Se desarrolló una red neuronal convolucional (CNN) para la detección temprana de glaucoma en imágenes de fondo de ojo, que está compuesta por una capa de entrada, siete capas convoluciones, cinco capas de agrupación, una de aplanamiento, dos capas completamente conectadas y una capa de salida de dos clases para determinar si la imagen corresponde a una de las clases: glaucoma positivo o glaucoma negativo. Se entrenó y se afinó la red neuronal convolucional con 85 épocas.

Se evaluó el rendimiento de la red neuronal convolucional propuesta, y obtiene una precisión de 96.57% en la detección de glaucoma en imágenes de fondo de ojo de forma global; una sensibilidad de 95.73% en la clasificación correcta de imágenes de la clase glaucoma positivo; y una especificidad de 98.83% en la clasificación correcta de imágenes de la clase glaucoma negativo.

Los resultados obtenidos representan un mejor rendimiento comparado con otras redes neuronales convolucionales y otros modelos desarrollados e indicados en estudios previos.

### REFERENCES

- [1] World Glaucoma Association. (2022). *Información de glaucoma Estadísticas - Información de glaucoma*. <https://www.glaucopatients.org/es/basica/estadisticas/>
- [2] Sociedad Española de Geriátría y Gerontología. (2019). *El 95% de los casos de ceguera por glaucoma se pueden evitar mediante una detección precoz*. <https://www.segg.es/actualidad-segg/2019/03/12/glaucoma-ojos-salud-mayores>
- [3] Lee, S. D., Lee, J. H., Choi, Y. G., You, H. C., Kang, J. H., & Jun, C. H. (2019). Machine learning models based on the dimensionality reduction of standard automated perimetry data for glaucoma diagnosis. *Artificial Intelligence in Medicine*, 94, 110–116. <https://doi.org/10.1016/J.ARTMED.2019.02.006>
- [4] Thangaraj, V., & Natarajan, V. (2017). Glaucoma diagnosis using support vector machine. *Proceedings of the 2017 International Conference on Intelligent Computing and Control Systems, ICCC 2017, 2018-January*, 394–399. <https://doi.org/10.1109/ICCONS.2017.8250750>
- [5] Parashar, D. R., & Agarwal, D. K. (2021). SVM based Supervised Machine Learning Framework for Glaucoma Classification using Retinal Fundus Images. *Proceedings - 2021 IEEE 10th International Conference on Communication Systems and Network Technologies, CSNT 2021*, 660–663. <https://doi.org/10.1109/CSNT51715.2021.9509708>
- [6] Zhao, R., Chen, X., Liu, X., Chen, Z., Guo, F., & Li, S. (2020). Direct Cup-to-Disc Ratio Estimation for Glaucoma Screening via Semi-Supervised Learning. *IEEE Journal of Biomedical and Health Informatics*, 24(4), 1104–1113. <https://doi.org/10.1109/JBHI.2019.2934477>
- [7] Thanh, T. H. P., Thuy, T. P. T., Hieu, T. N., & Nguyen, M. S. (2020). A Real-Time Classification of Glaucoma from Retinal Fundus Images Using AI Technology. *Proceedings - 2020 International Conference on Advanced Computing and Applications, ACOMP 2020*, 114–121. <https://doi.org/10.1109/ACOMP50827.2020.00024>
- [8] Civit-Masot, J., Dominguez-Morales, M. J., Vicente-Diaz, S., & Civit, A. (2020). Dual Machine-Learning System to Aid Glaucoma Diagnosis Using Disc and Cup Feature Extraction. *IEEE Access*, 8, 127519–127529. <https://doi.org/10.1109/ACCESS.2020.3008539>
- [9] Sallam, A., Gaid, A. S. A., Saif, W. Q. A., Kaid, H. A. S., Abdulkareem, R. A., Ahmed, K. J. A., Saeed, A. Y. A., & Radman, A. (2021). Early Detection of Glaucoma using Transfer Learning from Pre-trained CNN Models. *2021 International Conference of Technology, Science and Administration, ICTSA 2021*. <https://doi.org/10.1109/ICTSA52017.2021.9406522>
- [10] George, Y., Antony, B. J., Ishikawa, H., Wollstein, G., Schuman, J. S., & Garnavi, R. (2020). Attention-Guided 3D-CNN Framework for Glaucoma Detection and Structural-Functional Association Using Volumetric Images. *IEEE Journal of Biomedical and Health Informatics*, 24(12), 3421–3430. <https://doi.org/10.1109/JBHI.2020.3001019>
- [11] Suttapakti, U., Srikamdee, S., & Onpans, J. (2022). Multi-directional Texture Feature Extraction for Glaucoma Classification from Color Retinal Images. *2022 19th International Joint Conference on Computer Science and Software Engineering (JCSSE)*, 1–5. <https://doi.org/10.1109/JCSSE54890.2022.9836277>
- [12] Juneja, M., Minhas, J. S., Singla, N., Thakur, S., Thakur, N., & Jindal, P. (2022). Fused framework for glaucoma diagnosis using Optical Coherence Tomography (OCT) images. *Expert Systems with Applications*, 201. <https://doi.org/10.1016/J.ESWA.2022.117202>
- [13] Al-Bander, B., Al-Nuaimy, W., Al-Tae, M. A., & Zheng, Y. (2017). Automated glaucoma diagnosis using deep learning approach. *2017 14th International Multi-Conference on Systems, Signals and Devices, SSD 2017, 2017-January*, 207–210. <https://doi.org/10.1109/SSD.2017.8166974>
- [14] Pal, A., Moorthy, M. R., & Shahina, A. (2018). G-Eyenet: A Convolutional Autoencoding Classifier Framework for the Detection of Glaucoma from Retinal Fundus Images. *Proceedings - International Conference on Image Processing, ICIP*, 2775–2779. <https://doi.org/10.1109/ICIP.2018.8451029>
- [15] Diaz-Pinto, A., Colomer, A., Naranjo, V., Morales, S., Xu, Y., & Frangi, A. F. (2019). Retinal Image Synthesis and Semi-Supervised Learning for

- Glaucoma Assessment. *IEEE Transactions on Medical Imaging*, 38(9), 2211–2218. <https://doi.org/10.1109/TMI.2019.2903434>
- [16] Liao, W., Zou, B., Zhao, R., Chen, Y., He, Z., & Zhou, M. (2020). Clinical Interpretable Deep Learning Model for Glaucoma Diagnosis. *IEEE Journal of Biomedical and Health Informatics*, 24(5), 1405–1412. <https://doi.org/10.1109/JBHI.2019.2949075>
- [17] Juneja, M., Thakur, S., Uniyal, A., Wani, A., Thakur, N., & Jindal, P. (2022). Deep learning-based classification network for glaucoma in retinal images. *Computers and Electrical Engineering*, 101. <https://doi.org/10.1016/J.COMPELECENG.2022.108009>
- [18] Li, L., Xu, M., Liu, H., Li, Y., Wang, X., Jiang, L., Wang, Z., Fan, X., & Wang, N. (2020). A Large-Scale Database and a CNN Model for Attention-Based Glaucoma Detection. *IEEE Transactions on Medical Imaging*, 39(2), 413–424. <https://doi.org/10.1109/TMI.2019.2927226>
- [19] Gori, M. (2017). Machine learning : a constraint-based approach. *Morgan Kaufmann*. <https://doi.org/doi.org/10.1016/C2015-0-00237-4>
- [20] Müller, A., & Guido, S. (2018). Introduction to Machine Learning with Python: A Guide for Data Scientists 1st Edition. O'Reilly Media. *Journal of Chemical Information and Modeling*, 53(9), 378.
- [21] Hurwitz, J., & Kirsch, D. (2018). *Machine Learning IBM Limited Edition*. <http://www.wiley.com/go/permissions>.
- [22] Vakili, M., Ghamsari, M., & Rezaei, M. (2020). Performance Analysis and Comparison of Machine and Deep Learning Algorithms for IoT Data Classification. <https://arxiv.org/abs/2001.09636v1>
- [23] Cubas, J. V., & Niño, G. M. (2022). Machine learning model in the detection of phishing websites. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, 2022(E52), 161–173.
- [24] Li, L., Xu, M., Wang, X., Jiang, L., & Liu, H. (2019). Attention Based Glaucoma Detection: A Large-scale Database and CNN Model. *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 10571–10580.
- [25] J. Villegas-Cubas, O. Capuñay-Uceda, A. F. Coronado-Navarro, A. H. Delgado-Chavarri, and O. E. Osoro-Granda, “Sistemas de información para la Red Neuronal Convolutiva en la detección de diabetes usando imágenes de fondo de ojo,” *Revista Ibérica de Sistemas e Tecnologias de Informação Iberian Journal of Information Systems and Technologies*, vol. E51, pp. 34–45, Mar. 2022.