

DETECCIÓN DE GLAUCOMA UTILIZANDO IMÁGENES DEL FONDO DEL OJO  
MEDIANTE EL USO DE REDES NEURONALES CONVOLUCIONALES

JUAN SEBASTIÁN CARRILLO RODRÍGUEZ

UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS  
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA  
PROGRAMA DE MAESTRÍA EN INGENIERÍA DE SISTEMAS E INFORMÁTICA  
BUCARAMANGA  
2024

DETECCIÓN DE GLAUCOMA UTILIZANDO IMÁGENES DEL FONDO DEL OJO  
MEDIANTE EL USO DE REDES NEURONALES CONVOLUCIONALES

JUAN SEBASTIÁN CARRILLO RODRÍGUEZ

Trabajo de Grado para optar al título de  
M.Sc. en Ingeniería de Sistemas e Informática

Directora

Lola Xiomara Bautista Rozo

Ph.D. en Automatización, Tratamiento de Señales e Imágenes

Co-Director

Jorge Villamizar Morales

Doctor en Ciencias Aplicadas

UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS  
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA  
PROGRAMA DE MAESTRÍA EN INGENIERÍA DE SISTEMAS E INFORMÁTICA  
BUCARAMANGA

2024

## **DEDICATORIA**

Este trabajo va dedicado principalmente a Dios, por haberme dado la vida y las oportunidades para llegar a este momento tan importante personal y profesional. A mis padres por ser pilares de confianza, cariño y apoyo incondicional. A mis tías, tíos y abuelos que aprecio por compartir muchos momentos significativos conmigo, por su predisposición a enseñarme y guiarme de la mejor manera siempre que tuvieron la oportunidad y también por brindarme apoyo y ayuda en cualquier situación de necesidad. A Juanda, porque te amo infinitamente hermano y a mis amigos, que están en las buenas y en las malas.

## **AGRADECIMIENTOS**

Agradezco a Dios por la bendición de la vida y las personas que me rodean. Gracias a mis padres: Raúl y Olga por ser los principales promotores de mis sueños, por confiar y creer en mis expectativas, por los consejos, valores y principios que me han enseñado. Agradezco a mis profesores de la Escuela de Ingeniería de Sistemas de la Universidad Industrial de Santander, por haber compartido sus conocimientos a lo largo de la preparación de mi profesión. De manera especial, a la profesora Lola Bautista, tutora de mi proyecto de investigación quien me ha guiado con su paciencia y su rectitud como docente; al profesor Jorge Villamizar, tutor que ha prestado toda su ayuda, empeño y buena actitud para la realización del trabajo, al profesor Giovanni Calderon, al profesor Julio Carrillo y a los médicos oftalmólogos Juan Carlos Rueda, Mary Sanchez, Margarita Parra y Francisco Arango por su valioso aporte para nuestra investigación.

## CONTENIDO

	<b>pág.</b>
<b>INTRODUCCIÓN</b>	<b>14</b>
<b>1. OBJETIVOS</b>	<b>22</b>
<b>2. CONTRIBUCIONES</b>	<b>23</b>
<b>3. FUNDAMENTOS Y TRABAJO PREVIO</b>	<b>25</b>
3.1. IMÁGENES DEL FONDO DEL OJO	25
3.2. PARTES DEL OJO	26
3.3. GLAUCOMA EN IMÁGENES DEL FONDO DEL OJO	31
3.4. ORIGEN Y CONSECUENCIAS DEL GLAUCOMA	32
3.5. TRANSFORMADA WAVELET	34
3.6. EXTRACCIÓN DE CARACTERÍSTICAS	36
3.7. INTELIGENCIA ARTIFICIAL	38
3.7.1. APRENDIZAJE AUTOMÁTICO	39
3.7.2. REDES NEURONALES CONVOLUCIONALES	40
3.8. TRABAJOS PREVIOS	42
<b>4. MÉTODOS Y DESARROLLO</b>	<b>49</b>
4.1. RECOLECCIÓN DE DATOS	49
4.1.1. PLATAFORMA WEB	50
4.2. ESTRATEGIA COMPUTACIONAL	53
4.2.1. EXTRACCIÓN DE CARACTERÍSTICAS	54
4.2.2. RED NEURONAL CONVOLUCIONAL	63

<b>5. RESULTADOS</b>	<b>66</b>
5.1. MÉTRICAS	68
5.1.1. SENSIBILIDAD (RECALL O TASA DE VERDADEROS POSITIVOS)	68
5.1.2. ESPECIFICIDAD (TASA DE VERDADEROS NEGATIVOS)	69
5.1.3. ERROR	70
5.2. TRANSFORMADA WAVELET TRADICIONAL	70
5.2.1. WAVELET MADRE HAAR	71
5.2.2. VARIACIÓN DE LA WAVELET MADRE	74
5.3. TRANSFORMADA WAVELET SCATTERING	75
5.3.1. PRUEBAS EN DATASET PÚBLICO	77
5.3.2. DEFORMACIONES Y DESPLAZAMIENTOS	79
5.4. DISCUSIÓN DE LOS RESULTADOS	81
<b>6. RECOMENDACIONES</b>	<b>89</b>
<b>7. TRABAJO FUTURO</b>	<b>91</b>
<b>8. CONCLUSIONES</b>	<b>94</b>
<b>BIBLIOGRAFÍA</b>	<b>98</b>

## LISTA DE FIGURAS

	<b>pág.</b>
Figura 1. Imagen de fondo de ojo	26
Figura 2. Cámara portatil para imágenes de fondo de ojo	27
Figura 3. Cámara para imágenes de fondo de ojo	28
Figura 4. Partes de la retina	29
Figura 5. Particularidades encontradas en la retina	30
Figura 6. Defecto de Capa de Fibras Nerviosas	32
Figura 7. Efecto del glaucoma en el globo ocular	34
Figura 8. Ejemplos de wavelet madre	36
Figura 9. Red neuronal	41
Figura 10. Red neuronal convolucional	41
Figura 11. Vista en la plataforma para lectura de imágenes	52
Figura 12. Valoración de glaucoma en la plataforma	53
Figura 13. Base de datos	53
Figura 14. Detalles y aproximación de la transformada wavelet tradicional	56
Figura 15. Modelo de transformada wavelet tradicional	57
Figura 16. Modelo propuesto de imagen con transformada wavelet tradicional	58
Figura 17. Proceso para encontrar la transformada wavelet tradicional de una imagen	59
Figura 18. Proceso para encontrar la transformada wavelet Scattering de una imagen	62
Figura 19. Imagen generada con coeficientes de la transformada wavelet Scattering	63
Figura 20. Arquitectura ResNet-18	65

Figura 21.	Sensibilidad máxima obtenida variando el tipo de entrada	83
Figura 22.	Convergencia obtenida variando el tipo de entrada	84
Figura 23.	Precisión maxima obtenida variando el tipo de entrada	87
Figura 24.	Comparación de precisión con trabajo previo	88
Figura 25.	Comparación de sensibilidad con trabajo previo	88

## LISTA DE TABLAS

	<b>pág.</b>
Tabla 1. Prevalencia de glaucoma en Colombia 2009-2014	16
Tabla 2. Estratificación de los datos	50
Tabla 3. Sensibilidad del modelo con la variación en canales	71
Tabla 4. Sensibilidad del modelo con la variación en canales y transformada wavelet tradicional	72
Tabla 5. Especificidad y error del modelo con la variación en canales	73
Tabla 6. Especificidad y error del modelo con la variación en canales y transformada wavelet tradicional	73
Tabla 7. Variación de la wavelet madre(Sensibilidad)	74
Tabla 8. Variación de la wavelet madre(Error y especificidad)	75
Tabla 9. Variación de la entrada con transformada wavelet Scattering (sensibilidad)	76
Tabla 10. Variación de la entrada con transformada wavelet Scattering(error y especificidad)	77
Tabla 11. Estratificación de los datos(ORIGA)	78
Tabla 12. Comparación de resultados entre datasets (entrenamiento únicamente con privado)	78
Tabla 13. Comparación de resultados entre datasets (entrenamiento con dataset privado y ORIGA)	79
Tabla 14. Variación de la sensibilidad por rotaciones o deformaciones	80
Tabla 15. Variación de la especificidad por rotaciones o deformaciones	80
Tabla 16. Variación del error por rotaciones o deformaciones	80

## GLOSARIO

**FONDO DEL OJO** Imagen capturada del interior del ojo que muestra la retina, el nervio óptico y otros elementos estructurales.

**GLAUCOMA** Enfermedad ocular crónica que daña el nervio óptico y puede llevar a la pérdida de la visión.

**REDES NEURONALES CONVOLUCIONALES** Tipo de red neuronal utilizado en el procesamiento de imágenes que utiliza la convolución para detectar características relevantes.

**TRANSFORMADA WAVELET** Técnica matemática utilizada para descomponer una señal en diferentes escalas y frecuencias, permitiendo el análisis de detalles específicos.

**EXTRACCIÓN DE CARACTERÍSTICAS** Proceso de identificar y seleccionar características significativas en los datos de entrada para su posterior análisis o clasificación.

**RED NEURONAL** Modelo computacional inspirado en el funcionamiento del cerebro que se utiliza para el procesamiento de información.

**CAPA DE CONVOLUCIÓN** Componente de una red neuronal convolucional que aplica filtros de convolución a los datos de entrada.

**APRENDIZAJE PROFUNDO** Enfoque de la inteligencia artificial que utiliza redes neuronales con múltiples capas para extraer características y aprender representaciones complejas de los datos.

**CLASIFICACIÓN** Tarea de asignar una etiqueta o categoría a un objeto o conjunto de datos, basada en características específicas.

**PREPROCESAMIENTO** Etapa de procesamiento de datos que incluye operaciones como limpieza, normalización y reducción de ruido para mejorar la calidad de los datos de entrada.

**ENTRENAMIENTO** Proceso de ajustar los parámetros de una red neuronal mediante el uso de datos de entrenamiento para que pueda realizar tareas específicas.

**CONJUNTO DE DATOS** Colección de datos utilizados para entrenar, validar y probar modelos de aprendizaje automático.

**SENSIBILIDAD** Medida que indica la capacidad de un modelo para identificar correctamente los casos positivos.

**ESPECIFICIDAD** Medida que indica la capacidad de un modelo para identificar correctamente los casos negativos.

**PRECISIÓN** Medida que indica la proporción de resultados verdaderamente positivos entre todos los resultados clasificados como positivos.

**DISCO ÓPTICO** Área en el cual se conecta el nervio óptico al ojo y es la entrada de las venas y arterias al mismo

**ENFERMEDAD ASINTOMÁTICA** No presenta síntomas visibles para el portador de la enfermedad.

**EXCAVACIÓN DEL DISCO** Irregularidad presentada dentro del disco óptico debido al aumento de presión del ojo.

**PROCESAMIENTO DE IMÁGENES** conjunto de técnicas para mejorar características de las imágenes o extraer la información requerida de las mismas.

## RESUMEN

**TÍTULO:** DETECCIÓN DE GLAUCOMA UTILIZANDO IMÁGENES DEL FONDO DEL OJO MEDIANTE EL USO DE REDES NEURONALES CONVOLUCIONALES \*

**AUTOR:** JUAN SEBASTIÁN CARRILLO RODRÍGUEZ \*\*

**PALABRAS CLAVE:** GLAUCOMA, PROCESAMIENTO DIGITAL DE IMÁGENES, DEEP LEARNING, REDES NEURONALES, DETECCIÓN DE GLAUCOMA, TRANSFORMADA WAVELET, INFORMÁTICA BIOMÉDICA.

### **DESCRIPCIÓN:**

Las deficiencias en el cuidado de la visión pueden tener consecuencias lamentables e irreversibles en la vida de las personas, ya que algunas enfermedades oculares, como el Glaucoma abordado en este proyecto, son afecciones sigilosas que afectan los ojos de manera asintomática. El Glaucoma se destaca como una de las principales causas de ceguera a nivel mundial, atribuido a la falta de síntomas claros que adviertan a quienes lo padecen y a la escasez de oftalmólogos especializados para diagnosticar y dar seguimiento adecuado a los casos identificados.

En la práctica, la detección de la enfermedad comienza con un análisis visual de imágenes del fondo del ojo para identificar la presencia de Glaucoma. Estas imágenes se adquieren de manera relativamente sencilla, sin requerir procedimientos invasivos ni dispositivos costosos, y las cámaras para su obtención pueden ser manejadas por personal con entrenamiento básico. Además, proporcionan información suficiente para el diagnóstico de la enfermedad.

En este proyecto, se aborda esta problemática de manera computarizada mediante la detección automatizada de Glaucoma. Se emplea una estrategia que combina redes de aprendizaje profundo y la transformada wavelet. Primero, las imágenes se procesan mediante el algoritmo de transformada wavelet para extraer características, y luego estas características se utilizan en el algoritmo de aprendizaje profundo para detectar la presencia de Glaucoma, respaldando así el diagnóstico oftalmológico. Esta estrategia ha demostrado una sensibilidad de hasta 96.72% y una mejora en la convergencia de la red neuronal convolucional.

---

\* Trabajo de grado

\*\* Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería de Sistemas e Informática.

## ABSTRACT

**TITLE:** GLAUCOMA DETECTION USING FUNDUS IMAGES OF THE EYE WITH CONVOLUTIONAL DEEP NEURAL NETWORKS \*

**AUTHOR:** JUAN SEBASTIAN CARRILLO RODRIGUEZ \*\*

**KEYWORDS:** GLAUCOMA, DIGITAL IMAGE PROCESING, DEEP LEARNING, CONVOLUTIONAL NEURAL NETWORKS, GLAUCOMA DETECTION, WAVELET TRANSFORM.

### **DESCRIPTION:**

Deficiencies in vision care can have unfortunate and irreversible consequences in people's lives, especially with ocular diseases that are often asymptomatic and progress silently. An example of such a condition is Glaucoma, a leading cause of blindness worldwide. Factors such as the lack of clear symptoms and a shortage of specialized ophthalmologists contribute to the challenges in diagnosing and monitoring Glaucoma cases.

In practice, the initial detection of Glaucoma involves a visual analysis of fundus images to identify its presence. These images are relatively easy to acquire, requiring non-intrusive procedures and can be captured using cameras operated by personnel with basic training. Furthermore, these images provide sufficient information for disease diagnosis.

This project addresses this issue computationally by automating Glaucoma detection. The approach combines deep learning networks and wavelet transformation. Initially, images undergo processing with the wavelet transformation algorithm to extract features. Subsequently, these features are utilized in the deep learning algorithm to detect Glaucoma, supporting ophthalmological diagnosis. This strategy has demonstrated a sensitivity of up to 96.72% and an improvement in the convergence of the convolutional neural network.

---

\* Master of science thesis

\*\* Faculty of Physical-Mechanical Engineering, School of Systems Engineering and Informatics.

## INTRODUCCIÓN

El cuidado adecuado de la salud ocular implica una alimentación equilibrada y la adopción de buenos hábitos visuales. Es esencial destacar la importancia de prestar atención a cualquier cambio en la vista, como parte de los hábitos visuales recomendados. Las revisiones periódicas se convierten en una constante necesaria para prevenir enfermedades o detectar problemas de manera temprana <sup>1</sup>. Lamentablemente, estudios realizados por la Organización Mundial de la Salud (OMS) y la Agencia Internacional para la Prevención de la Ceguera revelan que aproximadamente 36 millones de personas tienen ceguera y más de 215 millones sufren discapacidades visuales en todo el mundo. De este grupo, 195 millones se encuentran en países subdesarrollados y 119.35 millones son mujeres, con una prevalencia superior al 55 % en este grupo <sup>2</sup>.

Las principales causas de discapacidad visual incluyen la degeneración macular relacionada con la edad y las cataratas, siendo estas últimas la principal causa de ceguera a nivel mundial, seguidas por el glaucoma <sup>2</sup>. Ante el crecimiento de estas cifras, la Asamblea Mundial de la Salud emprendió acciones positivas, desarrollando un plan de acción en 2014 para superar las barreras de acceso a servicios de atención visual. Este plan buscó mejorar la salud visual mediante la integración de

---

<sup>1</sup> GRUPO DE GESTIÓN INTEGRADA DE LA SALUD CARDIOVASCULAR BUCAL DEL CÁNCER Y OTRAS. *Lineamiento para la implementación de actividades de promoción de la salud visual, control de alteraciones visuales y discapacidad visual evitable (Estrategia VISIÓN 2020)*. [En línea]. Bogotá: Ministerio de salud y protección social. 2020. (Recuperado en 03 agosto 2019) Disponible en <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/RIDE/VS/PP/ENT/lineamientos-salud-visual-2017.pdf>.

<sup>2</sup> THE INTERNATIONAL AGENCY FOR THE PREVENTION OF BLINDNESS. [Sitio web]. *Global Vision Impairment Facts*. [Consulta: 03 de agosto 2019]. Disponible en: <https://www.iapb.org/vision-2020/who-facts/>.

la atención oftalmológica con los proveedores de servicios de salud <sup>3</sup>.

A nivel nacional, se han implementado esfuerzos similares, como el plan de intervenciones de salud visual en 2017 del Ministerio de Salud de Colombia. Este plan tenía como objetivo fortalecer la salud visual del país a través de diversas estrategias, incluyendo políticas y programas innovadores. Se utilizaron datos estadísticos recopilados entre 2009 y 2014 para analizar el estado de la salud visual en Colombia durante ese período <sup>4</sup>. Entre estos datos, se realizaron análisis detallados por departamentos.

En el informe también presentan datos sobre glaucoma para diferentes departamentos Colombianos, ver Figura 1, mostrando también aumentos en las prevalencias a nivel departamental, donde departamentos como Tolima tuvieron un incremento del 0.11 % y Cundinamarca del 10 %.

Las estadísticas anteriormente mencionadas son una muestra del impacto y aumento que ha tenido la enfermedad en el país, siendo esta una situación que se presenta a nivel mundial, donde se esperaba alcanzar los 80 millones de personas con glaucoma para el 2020 <sup>5</sup>. Una de las causantes del incremento en la prevalencia de la misma es la dificultad para su detección debido a la carencia de síntomas que alarmen a la persona que la padece, a esto se le conoce como una enfermedad asintomática, por lo que permite el paso del tiempo, trayendo consigo daños irre-

---

<sup>3</sup> THE INTERNATIONAL AGENCY FOR THE PREVENTION OF BLINDNESS. [Sitio web]. *Universal Eye Health - a vital component of health coverage*. [Consulta: 03 de agosto 2019]. Disponible en: <http://atlas.iapb.org/global-action-plan/universal-eye-health/>.

<sup>4</sup> DELGADO José Elías et al. *Análisis de Situación de Salud Visual en Colombia 2016*. [En línea]. Bogotá: Ministerio de salud y protección social. 2016. (Recuperado en 03 agosto 2019) Disponible en <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/asis-salud-visual-colombia-2016.pdf>.

<sup>5</sup> THE INTERNATIONAL AGENCY FOR THE PREVENTION OF BLINDNESS. [Sitio web]. *Glaucoma*. [Consulta: 03 de agosto 2019]. Disponible en: <https://www.iapb.org/knowledge/what-is-avoidable-blindness/glaucoma/>.

Tabla 1. Prevalencia de glaucoma en Colombia 2009-2014

Departamento	2009	2010	2011	2012	2013	2014
Antioquia	0.13 %	0.13 %	0.10 %	0.14 %	0.18 %	0.20 %
Atlántico	0.09 %	0.10 %	0.09 %	0.10 %	0.11 %	0.15 %
Bogotá	0.12 %	0.12 %	0.14 %	0.15 %	0.13 %	0.15 %
Bucaramanga	0.06 %	0.08 %	0.11 %	0.09 %	0.07 %	0.10 %

Fuente: GRUPO DE GESTIÓN INTEGRADA DE LA SALUD CARDIOVASCULAR BUCAL DEL CÁNCER Y OTRAS. Lineamiento para la implementación de actividades de promoción de la salud visual, control de alteraciones visuales y discapacidad visual evitable (Estrategia VISIÓN 2020). [En línea].Bogotá: Ministerio de salud y protección social. 2020. (Recuperado en 10 Mayo 2023) Disponible en <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/RIDE/VS/PP/ENT/%lineamientos-salud-visual-2017.pdf>.

versibles a tejidos del ojo. Cuando se presentan síntomas detectables sin ayuda de estudios médicos, generalmente es asociado a un avanzado estado de glaucoma y grandes posibilidades de ceguera irreversible, debido a los daños causados al nervio óptico. Otra de las causas que empeoran la situación, es que si es bien sabido que la población mundial ha incrementado, esta proporción de crecimiento no ha sido seguida por la cantidad de oftalmólogos; por ejemplo, en 2011, en Colombia se contaban con tan solo 903 oftalmólogos y una población total de 46 millones de personas<sup>4</sup>, esto equivalía a que cada oftalmólogo debía darle seguimiento a cerca de 60 mil personas para dar cobertura a toda la población, siendo este un valor poco factible, dejando por fuera de una debida salud visual a muchas personas. Esto propicia el avance de enfermedades oculares asintomáticas como el glaucoma, ya que sin estudios y seguimiento de un especialista es difícil detectar la enfermedad de forma temprana.

La detección inicial de glaucoma se realiza mediante imágenes del fondo del ojo, donde un oftalmólogo evalúa diversas características para decidir si es necesario realizar estudios adicionales debido a la sospecha de glaucoma u otras enferme-

dades <sup>6</sup>. Estas imágenes proporcionan información valiosa sobre posibles enfermedades que afectan la retina, basándose en aspectos como el sistema irrigatorio, la estructura de la retina y la presencia de cuerpos extraños en su superficie. La accesibilidad a imágenes de la retina se vuelve fundamental, y diversas tecnologías permiten a los especialistas visualizarla. Destacando las tomografías (OCT) y las imágenes de fondo de ojo. Estas últimas son las más utilizadas por los oftalmólogos debido a sus ventajas. La captura de estas imágenes se realiza a través de cámaras de fondo de ojo, dispositivos que varían en tamaño y peso según su aplicación, desde cámaras de oficina hasta versiones portátiles ideales para entornos remotos. Estas cámaras facilitan la toma de imágenes sin procedimientos invasivos, lo que permite su operación por personal capacitado, incluso no oftalmólogos. Además, almacenan imágenes en formato digital y su portabilidad posibilita la captura en áreas remotas sin acceso frecuente a servicios oftalmológicos. En contraste, las imágenes de OCT ofrecen mayor precisión y detalle, utilizándose para confirmar diagnósticos, aunque su toma implica la presencia del paciente en lugares especializados y con equipos costosos. Por lo tanto, suelen emplearse en etapas posteriores para validar sospechas originadas en revisiones de imágenes de fondo de ojo.

Como se mencionó previamente, las imágenes de fondo del ojo presentan ventajas en comparación con otras tecnologías en términos de adquisición. Esto permite a los oftalmólogos disponer de amplios bancos de estas imágenes. Sin embargo, esta ventaja se ve contrarrestada por un nuevo desafío. Mientras un oftalmólogo no tiene dificultad en tamizar 10 imágenes, el costo en tiempo se vuelve significativamente alto cuando este número se incrementa a miles. Esto dificulta la gestión de grandes cantidades de imágenes y restringe el alcance poblacional de cada oftalmólogo. Un ejemplo ilustrativo de estos programas de recolección de imágenes fue la campa-

---

<sup>6</sup> ABRÀMOFF Michael D et al. *Retinal imaging and image analysis*. IEEE reviews in biomedical engineering. 2010, vol. 3, pp. 169-208.

ña de prevención de cataratas y glaucoma llevada a cabo en varios departamentos del territorio nacional<sup>7,8</sup>. La iniciativa logró recopilar una gran cantidad de imágenes médicas de diversos sectores. Sin embargo, cada imagen debe ser evaluada por un oftalmólogo, consumiendo tiempo y recursos escasos debido a la falta de oftalmólogos para satisfacer la demanda de tamizaje. Esta situación plantea la posibilidad de soluciones como el análisis computarizado de imágenes. Este enfoque, al procesar la información, podría realizar parte del tamizaje realizado por oftalmólogos, acelerando así el proceso de detección de enfermedades en imágenes del fondo del ojo. La capacidad de procesar un gran número de imágenes en un tiempo mucho menor que el empleado por los humanos destaca la utilidad de esta estrategia.

En la actualidad se han desarrollado diferentes trabajos que buscan apoyar a los oftalmólogos por medio de estrategias computarizadas, esto se ha llevado a cabo con diferentes enfoques, uno de estos es el procesamiento de imágenes con operaciones a nivel de píxeles en las imágenes como sería el caso de <sup>9</sup>, o enfoques de inteligencia artificial utilizando mayores cantidades de imágenes <sup>10</sup>, estos algoritmos permiten la detección de enfermedades en imágenes del fondo del ojo de forma computarizada. Cabe aclarar que no reemplazan por completo a un especia-

---

<sup>7</sup> CENTRO DE PREVENCIÓN Y CONSULTORÍA EN GLAUCOMA. [En línea]. Bucaramanga: Fundación oftalmológica de santander-FOSCAL.2019 (recuperando en 1 diciembre 2019). Disponible en: <http://www.glaucomarueda.com/programas-de-prevencion.html>.

<sup>8</sup> GOBERNACIÓN DE SANTANDER. *Secretaría de Salud Departamental lidera el programa 'Santander sin ceguera'*. [<http://www.santander.gov.co>]. Bucaramanga: gobernación de santander. [Consulta: 03 de agosto 2019]. Disponible en: <http://www.santander.gov.co/index.php/actualidad/item/3131-secretaria-de-salud-departamental-lidera-el-programa-santander-sin-ceguera>.

<sup>9</sup> CARRILLO Juan Sebastian et al. *Glaucoma Detection Using Fundus Images of The Eye*. 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA). 2019, pp. 1-4.

<sup>10</sup> GARGEYA Rishab y LENG Theodore. *Automated identification of diabetic retinopathy using deep learning*. Elsevier. 2017, vol.124, nro.7, pp. 962-969.

lista, pues estos resultados entregan sospechas de presencia de la enfermedad que luego deben ser confirmadas por el especialista con diferentes análisis posteriores. Aun así el aporte que pueden realizar es la posibilidad de servir como herramientas de ayuda a oftalmólogos Junior y también de dar lectura a grandes cantidades de imágenes, detectando así pacientes que deban ser remitidos a exámenes con especialista.

Considerando las complicaciones mencionadas en la detección de enfermedades oculares, se determina como necesario el desarrollo de estrategias que faciliten el análisis computarizado de las imágenes. Se ha conformado un equipo integral, compuesto por oftalmólogos especializados en glaucoma encargados de recolectar y etiquetar los datos de manera adecuada. Este equipo se complementa con profesionales del área de ingeniería y matemáticas, quienes aportan valiosos conocimientos al desarrollo de los algoritmos. En este contexto, se ha diseñado una estrategia computacional basada en redes neuronales convolucionales para detectar glaucoma en imágenes del fondo del ojo. Estas imágenes fueron previamente evaluadas por el equipo médico especializado, contribuyendo al proceso de formación y validación del algoritmo implementado. Cabe destacar que esta valoración se llevó a cabo mediante una plataforma web, que permitió al oftalmólogo realizar el tamizaje de las imágenes utilizadas tanto en el entrenamiento como en la validación del algoritmo<sup>11</sup>.

El desempeño de los algoritmos de procesamiento de imágenes suele estar directamente relacionado a los datos utilizados para su desarrollo, entrenamiento y validación, por lo que se ha visto que realizar un procesamiento previo o extracción de características puede mejorar los resultados de tareas como la clasificación de

---

<sup>11</sup> Juan CARRILLO. *CLASIFICACIÓN COMPUTARIZADA DE ENFERMEDADES OFTALMOLÓGICAS UTILIZANDO IMÁGENES DEL FONDO DEL OJO*. Tesis de grado para optar por el título de ingeniero de sistemas, Bucaramanga, Universidad Industrial de Santander 2019.

imágenes, detección de objetos y otras tareas que pueden llevarse a cabo con redes neuronales convolucionales, ya sea para eliminar ruido, amplificar rasgos de los mismos o extraer alguna parte más relevante; estos pueden marcar la diferencia y mejorar los resultados obtenidos por algoritmos de clasificación, puesto que en trabajos anteriores se evidencian resultados prometedores con su aplicación como sería el caso de la detección de tumores cerebrales en imágenes médicas con redes neuronales y transformada wavelet <sup>12</sup>. Por esto en este proyecto se busca aportar a la detección de glaucoma por medio de una extracción de características con transformada wavelet, sumando este algoritmo a la estrategia computacional para detección de glaucoma a desarrollar en este proyecto.

La elección de la transformada wavelet como parte fundamental de la estrategia computacional para la detección de glaucoma se justifica por varias razones. Aunque las redes neuronales convolucionales (CNN) han demostrado su eficacia en tareas de clasificación de imágenes, como la detección de enfermedades, existe la posibilidad de que la red no capture eficientemente ciertos patrones y detalles críticos presentes en las imágenes de fondo de ojo.

La transformada wavelet ofrece una ventaja significativa al permitir una descomposición multiresolución de la imagen, lo que significa que la información se divide en diferentes frecuencias y escalas. Esto facilita la identificación de patrones tanto a nivel global como local en la imagen. Además, la transformada wavelet puede destacar características específicas, como bordes y texturas, que podrían ser fundamentales para la detección precisa de anomalías asociadas al glaucoma.

Aunque las CNN son capaces de aprender patrones complejos, la inclusión de la transformada wavelet como paso previo de procesamiento brinda una oportunidad

---

<sup>12</sup> CHEN Dar-Ren et al. *Diagnosis of breast tumors with sonographic texture analysis using wavelet transform and neural networks*. *Ultrasound in medicine & biology*. 2002, vol. 28, nro. 10, pp. 1301-1310.

adicional para resaltar y acentuar características relevantes antes de que la red las analice. Este enfoque no solo potencia la capacidad de la red para aprender información crucial, sino que también puede mejorar la robustez del modelo frente a imágenes de baja calidad o fuera de distribución.

En resumen, la aplicación de la transformada wavelet en este proyecto no solo busca mejorar la capacidad de detección de la red neuronal, sino que también proporciona una estrategia para abordar desafíos específicos asociados con la variabilidad y calidad de las imágenes, elevando así la eficacia global del sistema para la detección temprana de glaucoma.

Este documento está organizado de la siguiente manera: la introducción establece el contexto y los objetivos de la investigación. A continuación, se abordan los fundamentos teóricos relacionados con las imágenes del fondo del ojo, las partes del ojo y el glaucoma. También se exploran conceptos como la transformada wavelet y la inteligencia artificial, incluyendo el aprendizaje automático y las redes neuronales convolucionales. Se revisan trabajos previos relevantes. En la sección de métodos y desarrollo se detalla la recolección de datos, utilizando una plataforma web, y se describe la estrategia computacional, incluyendo la extracción de características y el uso de redes neuronales convolucionales. Los resultados se presentan en varias subsecciones, incluyendo una variante de la transformada wavelet, análisis de deformaciones y desplazamientos. Se discuten los resultados y las contribuciones de la investigación, y se ofrecen recomendaciones y propuestas para trabajos futuros. Las métricas utilizadas en el análisis incluyen sensibilidad, especificidad, precisión, enfocadas a la detección de glaucoma y técnicas de análisis de imágenes donde la sensibilidad desempeña un papel crucial al indicar la capacidad del algoritmo para detectar casos reales de glaucoma, con el objetivo de reducir la cantidad de pacientes con glaucoma que se clasifican incorrectamente como sanos y finalmente, se presentan las conclusiones principales del estudio.

## 1. OBJETIVOS

### Objetivo general

- Proponer una estrategia computacional que permita detectar la presencia de sospecha de Glaucoma en imágenes del fondo del ojo para el apoyo diagnóstico de la enfermedad por medio de algoritmos de redes neuronales convolucionales y transformada wavelet.

### Objetivos específicos

- Generar un dataset para el entrenamiento y validación de los algoritmos;
- Diseñar un algoritmo de extracción de características con transformada wavelet;
- Diseñar un algoritmo para la detección de Glaucoma utilizando redes neuronales convolucionales que aproveche las características obtenidas con el algoritmo de transformada wavelet.
- Validar la estrategia para detección de Glaucoma por medio de las métricas de precisión, sensibilidad y especificidad.

## 2. CONTRIBUCIONES

Del proyecto se generaron publicaciones y presentaciones mencionadas a continuación:

Ponencias:

- Título: Computer Assisted Glaucoma Detection using Fundus Images, XXXV congreso panamericano de oftalmología, Marzo 17-20, 2023, Buenos Aires, Argentina. Ver enlace: <https://paao2023.com/>;
- Título: Glaucoma Detection using Fundus Images with Mimetic Anisotropic Filtering and Convolutional Neural Networks, 2022 E-Health and Bioengineering Conference (EHB), Noviembre 17-18, 2022, Iasi, Romania. Ver enlace: <http://www.ehbconference.ro/2022/Home.aspx>;

Artículo:

- Carrillo, J., Villamizar, J., Calderon, G., Rueda, J., Bautista Rozo, L., & Castillo, J. (2022). Glaucoma Detection using Fundus Images with Mimetic Anisotropic Filtering and Convolutional Neural Networks. En *Electronic Health and Biomedicine (EHB)*, publicado en 2022. Autores: Juan Carrillo, Jorge Villamizar, Giovanni Calderón, Juan Rueda, Lola Bautista Rozo y José Castillo. Electronic ISSN: 2329-6259, Electronic ISBN: 978-1-7281-1491-0, INSPEC Accession Number: 2575-5145. DOI: 10.1109/EHB55594.2022.9991342. Publicado por IEEE. Celebrado del 17 al 18 de noviembre de 2022 en Iasi, Rumania.
- Villamizar, J., Calderon, G., Carrillo, J., Bautista Rozo, L., Carrillo, J., Rueda, J., & Castillo, J. (2022). Mimetic finite difference methods for restoration of fundus images for automatic detection of glaucoma suspects. Publicado en 2022 en la revista *Computer Methods in Biomechanics and Biomedical Engineering*:

*Imaging & Visualization*. Autores: Jorge Villamizar, Giovanni Calderón, Julio Carrillo, Lola Bautista Roza, Juan Carrillo, Juan Rueda y José Castillo. DOI: 10.1080/21681163.2021.1914733. Publicado por Taylor & Francis. Fecha de publicación: 26 de noviembre de 2021.

### **3. FUNDAMENTOS Y TRABAJO PREVIO**

En este capítulo se describen los fundamentos necesarios para la realización del proyecto, cubriendo tanto los aspectos médicos relevantes como el procesamiento de imágenes. Además, se presenta una revisión del trabajo previo realizado en el campo de la detección de enfermedades oculares.

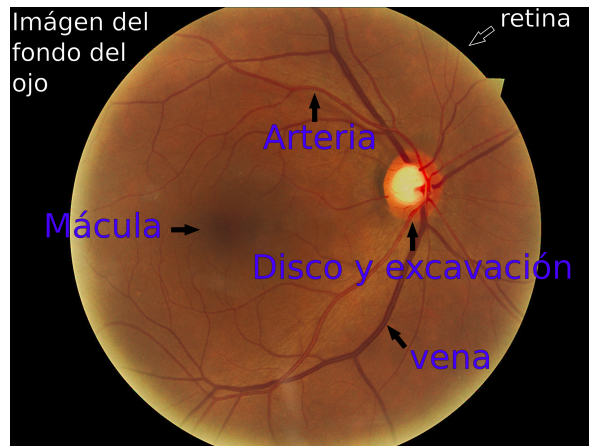
#### **3.1. IMÁGENES DEL FONDO DEL OJO**

Las imágenes del fondo del ojo constituyen un tipo de examen médico que permite al profesional de la salud visualizar de manera no invasiva el interior del ojo a través de la pupila. Este procedimiento, ilustrado en la Figura 1, se utiliza para examinar la salud del nervio óptico, la retina y los vasos sanguíneos que irrigan el ojo, proporcionando una visión detallada de diversas partes oculares. La exploración se lleva a cabo mediante un oftalmoscopio o cámara de fondo de ojo, que emite una luz brillante y facilita al médico u oftalmólogo la observación de las estructuras internas. La imagen resultante puede ser capturada y almacenada en formato digital para un análisis más detenido. Estas imágenes son instrumentos valiosos en el diagnóstico y tratamiento de enfermedades oculares como el glaucoma, la retinopatía diabética, la degeneración macular y la hipertensión ocular. Además, se emplean para monitorear la evolución de las enfermedades a lo largo del tiempo y evaluar la eficacia de los tratamientos.

Es fundamental destacar que la obtención de imágenes del fondo del ojo es un procedimiento médico que debe ser realizado por personal capacitado. A pesar de no ser invasivo, no se requiere la presencia de un oftalmólogo para la captura de la imagen, lo que convierte este procedimiento en una opción rápida, sencilla y de

bajo costo<sup>13</sup>.

Figura 1. Imagen de fondo de ojo



Fuente: Banco de imágenes suministrado por CENTRO DE PREVENCIÓN Y CONSULTORÍA EN GLAUCOMA, [En línea]. Bucaramanga: Fundación oftalmológica de Santander-FOSCAL.2019 (recuperado en 1 diciembre 2019). Disponible en: <http://www.glaucomarueda.com/programas-de-prevencion.html>.

La cámara de fondo de ojo es la unión de microscopio y cámara, enfocados a la captura de imágenes de retina, el proceso de captura de la imagen toma al rededor de diez minutos dependiendo del tipo de cámara utilizada. Existen diferentes tipos de cámaras de fondo de ojo, desde cámaras portátiles, ver Figura 2, hasta equipos de alta gama con tecnología de imagen avanzada<sup>13</sup>, ver Figura 3 .

### 3.2. PARTES DEL OJO

En imágenes del fondo del ojo principalmente se observa la retina, que es una estructura compleja y delicada compuesta por varias capas de células que trabajan juntas para procesar y transmitir la información visual al cerebro. Las principales

---

<sup>13</sup> SAINE Patrick J y TYLER Marshall E. *Ophthalmic photography: retinal photography, angiography, and electronic imaging*. Butterworth-Heinemann Boston. 2002, vol. 132.

Figura 2. Cámara portátil para imágenes de fondo de ojo



Fuente: Digital Eye Center, and more, [Sitio Web]. Bucaramanga: Ophthalmic Digital Solutions for Anterior and Fundus Photography with Slit Lamps and Microscopes.2018 (recuperado en 1 febrero 2023). Disponible en: <https://www.digitaleyecenter.com/es/product/camara-portatil-fondo-ojo-16mpx-luna/>.

partes de la retina incluyen:

- *La capa de células bipolares:* Estas células reciben señales eléctricas de los fotorreceptores y las transmiten a las células ganglionares.;
- *La capa de células ganglionares:* Estas células reciben señales de las células bipolares y las transmiten al cerebro a través del nervio óptico.;
- *La capa de células horizontales y amacrinas:* Estas células trabajan para ajustar la información visual a medida que se mueve a través de la retina antes de ser transmitida al cerebro.;

Además de las capas celulares mencionadas, la retina alberga otros elementos fundamentales, como los vasos sanguíneos que nutren esta estructura y el epitelio pigmentario, una capa de células ubicada entre la retina y la coroides que contribuye al mantenimiento de la salud de las células fotorreceptoras. Cada una de estas partes de la retina desempeña un papel crucial en el proceso de visión, y su correcto

Figura 3. Cámara para imágenes de fondo de ojo



Fuente: INSTITUTO OFTALMOLÓGICO AMIGÓ, [Sitio web]. [Consulta: 17 de octubre 2019]. Disponible en: (  
[http://www.ioamigo.com/galeria-item/retinografia-no %midriatica/](http://www.ioamigo.com/galeria-item/retinografia-no-%midriatica/)

funcionamiento resulta esencial para preservar una óptima salud ocular<sup>14</sup>.

Asimismo, en la imagen del fondo del ojo, es posible observar el sistema de venas y arterias internas del ojo, como se ilustra en la Figura 4(a). Este sistema de irrigación ocular es esencial para mantener la salud ocular y asegurar su correcto funcionamiento. El ojo recibe sangre a través de dos conjuntos de arterias que se ramifican en la retina y otras áreas oculares, suministrando oxígeno y nutrientes a las células y tejidos oculares. Por otro lado, las venas retinianas desempeñan un papel crucial al drenar la sangre de la retina y la coroides<sup>15</sup>. Este sistema vascular puede ser afectado por diversas enfermedades, entre las que se incluyen la retinopatía diabética, la hipertensión arterial y el glaucoma.


La fovea o mácula es una pequeña área en el centro de la retina que es responsable de la visión central aguda, ver Figura 4(b). Contiene un alto número de células

---

<sup>14</sup> RIZZOIII Joseph A y WYATT John. *prospects for a visual prosthesis*. The Neuroscientist. 1997, vol. 3, nro. 4, pp. 251–262.

<sup>15</sup> KAISER Hedwig et al. *Ocular blood flow: new insights into the pathogenesis of ocular diseases*. Karger Medical and Scientific Publishers. 1996.

Figura 4. Partes de la retina



Fuente: Banco de imágenes suministrado por CENTRO DE PREVENCIÓN Y CONSULTORÍA EN GLAUCOMA, [En línea]. Bucaramanga: Fundación oftalmológica de Santander-FOSCAL.2019 (recuperado en 1 diciembre 2019). Disponible en: <http://www.glaucomarueda.com/programas-de-prevencion.html>

fotorreceptoras conocidas como conos, que son esenciales para la percepción de los detalles finos y los colores vivos. Además, la mácula es rica en pigmentos que protegen a los fotorreceptores de la luz dañina<sup>16</sup>, esta suele verse como un área más oscura en la retina, cerca al disco óptico.


El disco óptico, también conocido como papila óptica, constituye una estructura anatómica ubicada en la retina, la capa de tejido fotosensible que recubre la parte posterior del ojo. Este componente es esencial, ya que es el sitio donde se concentran los nervios encargados de transmitir la información visual desde la retina hasta el cerebro, como se evidencia en las imágenes del fondo del ojo, presentadas en la Figura 4(c). Por lo general, presenta una forma circular u ovalada.

La evaluación del disco óptico es una parte fundamental en los exámenes oftalmológicos, ya que proporciona información valiosa sobre la salud del nervio óptico y la retina. Alteraciones en la apariencia del disco óptico pueden ser indicativas de diversas enfermedades, como el glaucoma, la neuropatía óptica y la retinopatía dia-


---

<sup>16</sup> BOYD Kierstan. *What Is Macular Degeneration?* [En línea]. Estados Unidos: AMERICAN ACADEMY OF OPHTHALMOLOGY OPHTHALMOLOGY. 2023. (Recuperado en 03 marzo 2023) Disponible en <https://www.aao.org/eye-health/diseases/amd-macular-degeneration>.


Figura 5. Particularidades encontradas en la retina




a). Aneurismas




b). Neovascularización




c). Isquemia



d). Hemorragia en la retina



e). Hemorragia vitrea



f). Tortuosidad

Fuente: Banco de imágenes suministrado por CENTRO DE PREVENCIÓN Y CONSULTORÍA EN GLAUCOMA, [En línea]. Bucaramanga: Fundación oftalmológica de Santander-FOSCAL.2019 (recuperado en 1 diciembre 2019). Disponible en: <http://www.glaucomarueda.com/programas-de-prevencion.html>

bética<sup>17</sup>.

La Figura 5 ofrece ejemplos de afecciones que pueden afectar diferentes partes del ojo y que son visualizables en imágenes del fondo del ojo. Estos ejemplos incluyen la presencia de aneurismas, neovascularización, isquemia, hemorragias y tortuosidad. Todas estas patologías impactan la visión de las personas y brindan información crucial al oftalmólogo durante el examen médico. Es importante destacar que el

---

<sup>17</sup> SOHAN SINGH Hayreh. *Optic disc changes in glaucoma*. The British journal of ophthalmology. 1972, vol. 56, nro. 3, pp. 175.

glaucoma también puede ser identificado a través de imágenes del fondo del ojo debido a características particulares observadas en el disco óptico.

### **3.3. GLAUCOMA EN IMÁGENES DEL FONDO DEL OJO**

El glaucoma se manifiesta en imágenes del fondo del ojo a través de una afectación discernible en el disco óptico. Una métrica crucial para evaluar esta afectación es la relación copa-disco (C/D), también conocida como ratio disco-excavación. Esta medida oftalmológica proporciona una evaluación del nervio óptico y puede ser un indicativo de la presencia de glaucoma. La relación C/D se refiere a la proporción entre la apariencia de la copa (la zona excavada en el centro del disco óptico) y el tamaño total del disco.

En términos generales, se considera que una relación C/D normal es igual o inferior a 0.6, indicando que la copa ocupa menos del 60 % del disco. Una relación superior podría sugerir la presencia de glaucoma, ya que denota una mayor excavación de la copa debido a la pérdida de células nerviosas en el nervio óptico<sup>18</sup>. Esta excavación se manifiesta como un área más brillante en imágenes del fondo del ojo, como se puede observar en la Figura 4(c). Aunque este indicador es significativo para la sospecha de glaucoma, es necesario realizar estudios adicionales para confirmar la enfermedad.

Otro indicador de la presencia de glaucoma en imágenes del fondo del ojo son los defectos de la capa de fibras nerviosas (DCFN). Estos defectos se presentan como líneas claras cerca de la zona del disco, como se visualiza en la Figura 6, donde parte del defecto se encuentra entre líneas azules. Este hallazgo clínico es común en enfermedades que afectan el nervio óptico, como el glaucoma y la neuropatía


---

<sup>18</sup> QUIGLEY Harry. *Open-angle glaucoma*. New England Journal of Medicine. 1993, vol. 328, nro. 15, pp. 1097–1106.

óptica, indicando la pérdida o adelgazamiento de la capa de fibras nerviosas que conforman el nervio óptico en la retina.

La detección temprana de DCFN es crucial para posibilitar el diagnóstico y tratamiento precoz del glaucoma y otras enfermedades del nervio óptico. Para lograrlo, se recurre a diversas técnicas de imagen de la retina, como la tomografía de coherencia óptica (OCT) y la polarimetría de escaneo láser (PSL)<sup>19</sup>.

Figura 6. Defecto de Capa de Fibras Nerviosas



Fuente: Autor.

### 3.4. ORIGEN Y CONSECUENCIAS DEL GLAUCOMA

El glaucoma, una enfermedad ocular que afecta el nervio óptico, puede resultar en pérdida irreversible de la visión si no se aborda adecuadamente. Aunque su origen aún no se comprende completamente, se cree que está vinculado a diversos factores, incluida la presión intraocular elevada, la edad avanzada, antecedentes familiares de glaucoma y ciertas condiciones médicas como la diabetes.

---

<sup>19</sup> PÉREZ Oliván et al. *Utilidad de la oftalmoscopia láser de barrido en la detección de defectos en la capa de fibras nerviosas retinianas en pacientes con hipertensión ocular*. Archivos de la Sociedad Española de Oftalmología. 2003, vol. 78, nro. 1, pp. 15–20.

Un estudio reciente publicado en la revista *Nature Reviews Disease Primers* sugiere que el glaucoma se desarrolla cuando la presión intraocular elevada provoca daño al nervio óptico y a las células ganglionares de la retina<sup>20</sup>. Este daño puede iniciar en la periferia de la visión y avanzar hacia el centro, provocando una pérdida gradual de la visión. Aunque se considera que la presión intraocular elevada es un factor de riesgo principal, ya que puede afectar los vasos sanguíneos que suministran sangre y nutrientes al nervio óptico y a las células ganglionares de la retina, se ha observado que algunas personas con presión intraocular normal también desarrollan glaucoma, indicando la posible influencia de otros factores<sup>21</sup>.

En casos de presión intraocular elevada, a menudo se debe a bloqueos en el flujo adecuado de los líquidos internos del ojo, estos líquidos son conocidos como humor vítreo y humor acuoso. La Figura 7 ilustra cómo el aumento de la presión intraocular impacta en la retina y el nervio óptico, resultando en la excavación característica asociada al glaucoma.

El glaucoma puede tener consecuencias graves si no se trata adecuadamente. El daño al nervio óptico y las células ganglionares de la retina puede llevar a una pérdida gradual de la visión que puede ser irreversible. Las personas con glaucoma pueden experimentar cambios en su campo visual, puntos ciegos o pérdida de la visión periférica, lo que puede dificultar la realización de tareas cotidianas y aumentar el riesgo de caídas y lesiones.


Además de la pérdida de visión, el glaucoma también puede tener otras consecuencias negativas para la salud. Las personas con glaucoma pueden experimentar do-

---

<sup>20</sup> FUJITA Asahi et al. *Association between lifestyle habits and glaucoma incidence: a retrospective cohort study*. *Eye*. 2023, nro. 10, pp. 1-7.

<sup>21</sup> THAM Yih-Chung et al. *Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis*. *Ophthalmology*. 2014, vol. 121, nro. 11, pp. 2081–2090.

Figura 7. Efecto del glaucoma en el globo ocular



Fuente: MAYO CLINIC. [Sitio web]. NEWS NETWORK. [Consulta: 09 de abril 2020]. Disponible en: <https://newsnetwork.mayoclinic.org/discussion/edad-y-antecedentes-familiares-son-factores-de-riesgo-importantes-para-glaucoma/>

lor ocular, enrojecimiento y visión borrosa. En casos avanzados, el glaucoma puede causar ceguera total y puede afectar la calidad de vida de la persona.

Otra consecuencia importante del glaucoma es que aumenta el riesgo de desarrollar otras afecciones oculares, como cataratas y degeneración macular relacionada con la edad (DMRE). Esto se debe a que el daño al nervio óptico y las células ganglionares de la retina puede afectar la salud general del ojo y aumentar la vulnerabilidad a otras enfermedades oculares<sup>21</sup>.

### 3.5. TRANSFORMADA WAVELET

La transformada wavelet es una técnica matemática que se utiliza para el análisis y procesamiento de señales y datos. Se basa en descomponer una señal en diferentes escalas y frecuencias mediante el uso de una función conocida como wavelet madre, lo que permite identificar patrones y detalles en la señal que no son visibles con otras técnicas de análisis. Ha demostrado ser útil en una amplia variedad de aplicaciones, desde la compresión de imágenes y señales de audio hasta el análisis de datos financieros y biológicos. Una de las principales ventajas de la transformada wavelet es su capacidad para representar señales complejas de manera más

eficiente y precisa que otras técnicas de análisis<sup>22</sup>. La transformada wavelet también se utiliza en el procesamiento de imágenes médicas, como la OCT y la resonancia magnética (RM). En OCT, la transformada wavelet se utiliza para identificar y segmentar diferentes capas de tejido en el ojo, lo que es útil en el diagnóstico y seguimiento de diferentes enfermedades. En RM, la transformada wavelet se utiliza para reducir el ruido y mejorar la resolución de las imágenes<sup>23</sup>.

La transformada wavelet consta de la aplicación de una wavelet madre, ver Figura 8, sobre una señal para posteriormente realizar un análisis de los resultados; lo que se busca con esto es la extracción de características desde la señal original<sup>24</sup>, estas características extraídas son datos que se obtienen de las imágenes del fondo de ojo y en este caso se busca que estén relacionadas al Glaucoma. Esta transformación de la señal entrega datos llamados aproximaciones y detalles, donde estos son obtenidos según variaciones que se le aplican a la wavelet madre, estas variaciones son rotaciones o cambios de escalas en el caso de imágenes<sup>25</sup>. La wavelet madre es una señal que cumple con características como tener un valor promedio nulo, ecuación. 1 y energía finita, ver ecuación. 2. Esta transformada es similar a la transformada de Fourier con la diferencia de que en este caso se utilizan ondas

---

<sup>22</sup> MALLAT Stephane G. *A theory for multiresolution signal decomposition: the wavelet representation*. IEEE transactions on pattern analysis and machine intelligence. 1989, vol. 11, nro. 7, pp. 674–693.

<sup>23</sup> WANG Anna et al. *The application of wavelet transform to multi-modality medical image fusion*. 2006 IEEE International Conference on networking, sensing and control, nro. 6, pp. 270–274.

<sup>24</sup> ADDISON Paul S. *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. CRC press. 2017.

<sup>25</sup> GÓMEZ-LUNA E et al. *Selección de una wavelet madre para el análisis frecuencial de señales eléctricas transitorias usando WPD*. Ingeniare. Revista chilena de ingeniería. 2013, vol. 21, nro. 2, pp. 262–270.

diferentes a senos y cosenos.


$$\int_{-\infty}^{\infty} \Psi(t) dt = 0 \quad (1)$$

$$\int_{-\infty}^{\infty} |\Psi(t)|^2 dt < \infty \quad (2)$$

donde  $\Psi(t)$  es la wavelet madre.

En diferentes trabajos previos se ha visto que la aplicación de transformada wavelet como método de extracción de características mejora los resultados de los algoritmos de clasificación<sup>24</sup>.

Figura 8. Ejemplos de wavelet madre



a)Gaussiana, b)Sombrero mexicano, c)Haar, d)Morlet

Fuente: Addison, P. S. (2017). The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance. CRC press.

### 3.6. EXTRACCIÓN DE CARACTERÍSTICAS

El método de extracción de características tiene un impacto significativo en los resultados obtenidos por las redes neuronales convolucionales, ya que se modifica la entrada que reciben para su procesamiento. Al utilizar métodos de extracción de características, se busca proporcionar a la red datos que representen de manera más efectiva los factores importantes de los datos originales. La transformada wa-

velet es aplicada en este proceso para mejorar la extracción de características, pero es importante tener en cuenta su implementación específica para este problema en particular. En este trabajo, se consideró tanto la transformada wavelet tradicional<sup>23</sup> como la transformada wavelet scattering<sup>26</sup> para llevar a cabo la extracción de características de las imágenes de fondo del ojo.

La transformada wavelet tradicional y el scattering son dos técnicas de procesamiento de señales que utilizan la transformada wavelet como base. Sin embargo, existen algunas diferencias importantes entre ellas:

- La transformada wavelet tradicional se utiliza principalmente para analizar señales en términos de sus componentes de alta y baja frecuencia, mientras que la transformada wavelet scattering se utiliza para extraer información invariante a la escala y a la traslación de la señal.
- Orden de operación: La transformada wavelet tradicional realiza una serie de operaciones de convolución y submuestreo en la señal de entrada para obtener los coeficientes de detalle y aproximación en diferentes escalas y posiciones. La transformada wavelet scattering, por otro lado, realiza estas operaciones en cascada, de tal manera que cada capa de procesamiento agrega información invariante a la escala y a la traslación.
- Invariancia: La transformada wavelet tradicional no es invariante a la traslación de la señal, lo que significa que pequeños cambios en la posición de una característica de la señal pueden afectar significativamente los coeficientes de la transformada. Por el contrario, la transformada wavelet scattering es invariante a la traslación y a la escala, lo que significa que los coeficientes son más estables ante pequeñas deformaciones de la señal.

---

<sup>26</sup> BRUNA Joan y MALLAT Stéphane. *Invariant scattering convolution networks*. IEEE transactions on pattern analysis and machine intelligence. 2013, vol. 35, nro. 8, pp. 1872–1886.

- Capacidad de representación: La transformada wavelet tradicional tiene una capacidad limitada para representar características no estacionarias de la señal, como cambios abruptos o singularidades. La transformada wavelet scattering, por otro lado, puede representar estas características de manera más efectiva debido a su capacidad para extraer información invariante a la escala y a la traslación.

La diferencia fundamental entre la transformada wavelet tradicional y la transformada wavelet scattering radica en cómo se calculan y representan las características de la señal o imagen. En la transformada wavelet tradicional, se obtienen los coeficientes wavelet que representan diferentes escalas y desplazamientos en la señal. Estos coeficientes proporcionan información sobre las características locales de la señal en diferentes niveles de resolución.

Por otro lado, la transformada wavelet scattering va un paso más allá al calcular no solo los coeficientes wavelet, sino también los coeficientes de scattering. La transformada wavelet scattering calcula coeficientes de dispersión que capturan información sobre las relaciones entre las diferentes partes de la señal, lo que resulta en una representación más robusta y discriminativa de la señal. Estos coeficientes de scattering proporcionan información sobre la invariancia a desplazamientos y transformaciones de escala, lo que los hace útiles en aplicaciones como el procesamiento de imágenes y el reconocimiento de patrones.

### **3.7. INTELIGENCIA ARTIFICIAL**

La inteligencia artificial es el área de la ciencia encargada del estudio de la inteligencia en objetos artificiales, con el fin recrear y mejorar el comportamiento inteligente en estos. El aprendizaje y la adaptabilidad son algunos ejemplos de los comportamientos que se buscan replicar por estar relacionados a la inteligencia humana y de

otros seres vivos<sup>27</sup>. La inteligencia artificial se compone de diferentes ramas, como lo son la robótica, procesamiento del lenguaje, máquinas expertas y el aprendizaje automático, entre otras más. La rama en la que se enfatiza en este proyecto es el aprendizaje automático, pues esta nos permite entrenar algoritmos utilizando cantidades grandes de datos para la solución de un problema determinado. Si se cuenta con una cantidad de imágenes de suficiente, el aprendizaje automático presenta herramientas que pueden aportar de sobremanera a la solución de dicho problema<sup>28</sup>.

**3.7.1. APRENDIZAJE AUTOMÁTICO** Es el área de la inteligencia artificial que se enfoca en el desarrollo de algoritmos y técnicas para el aprendizaje de la máquina, estos algoritmos se clasifican según el tipo de aprendizaje: supervisado, no supervisado, semi supervisado o por refuerzo; estas clases se derivan de la naturaleza de las entradas del algoritmo. Entre estos el más destacado para el caso a tratar en el proyecto actual es el de aprendizaje supervisado, pues el requerimiento principal es tener unas entradas previamente clasificadas, lo cual llevado a este problema en específico equivale a tener las imágenes del fondo del ojo previamente clasificadas por especialistas oftalmólogos.

Existen diferentes algoritmos presentados por el aprendizaje automático para trabajar por medio de el aprendizaje supervisado; a lo largo del tiempo las redes neuronales convolucionales han presentado buenos resultados para la clasificación en el área de la detección de enfermedades en diferentes tipos de imágenes.

---

<sup>27</sup> ROMERO J.J. et al. *Matlab deep learning*. Inteligencia artificial y computación avanzada. 2007, vol. 13.

<sup>28</sup> KIM Phil. *Matlab deep learning*. With Machine Learning, Neural Networks and Artificial Intelligence. 2017, vol. 130.

**3.7.2. REDES NEURONALES CONVOLUCIONALES** Las redes neuronales constituyen un modelo de aprendizaje automático que se inspira en las neuronas del cerebro humano. Estas redes están compuestas por nodos, representados matemáticamente como matrices, organizados en capas, tal como se ilustra en la Figura 9. En su forma más elemental, una red neuronal es un conjunto de nodos (también denominados neuronas) interconectados, diseñados para procesar y transmitir información. Cada nodo realiza operaciones matemáticas simples en su entrada y genera una salida.

Durante el entrenamiento de las redes neuronales, se ajustan los pesos (o coeficientes) de las conexiones entre los nodos para minimizar el error en la salida de la red en comparación con las salidas de entrenamiento conocidas. Este proceso implica dividir el conjunto de datos de entrada en datos de entrenamiento y datos de validación. Así, la red neuronal se entrena para resolver un problema específico definido por los datos utilizados<sup>29</sup>.

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) son una variante de la red neuronal que ha demostrado ser muy efectiva en el procesamiento de imágenes. En lugar de tratar cada píxel de una imagen como una entrada separada, una CNN utiliza capas de convolución para extraer características útiles de la imagen; como se muestra en la Figura 10 la imagen pasa primero por las capas de convolución donde se aplican diferentes operaciones para la extracción de características, las capas de convolución aplican filtros a pequeñas áreas de la imagen, extrayendo patrones como bordes, líneas y texturas. Estas características se agrupan en mapas de características y se alimentan a través de capas adicionales de la red neuronal para realizar la clasificación.


Las CNN se han utilizado en una amplia gama de aplicaciones de procesamiento de

---

<sup>29</sup> GOODFELLOW Ian et al. *Deep learning*. MIT press. 2016.


imágenes, como la clasificación de objetos en imágenes, la detección de objetos y el reconocimiento facial. También se han adaptado para trabajar con datos de otros tipos, como el procesamiento de voz y el procesamiento de texto.

Figura 9. Red neuronal



Fuente: autor

Figura 10. Red neuronal convolucional



Fuente: Phil KIM. Matlab deep learning. With Machine Learning, Neural Networks and Artificial Intelligence. 2017, vol. 130

Existen modelos de redes neuronales convolucionales que han sido utilizados en detección y clasificación de objetos y fueron entrenadas con un reconocido conjunto de datos (imageNet), estas son conocidas como redes neuronales convolucionales previamente entrenadas, se pueden encontrar en diferentes lenguajes de programación para aplicarlas a nuevos problemas. El proceso de adaptar estas redes a un

nuevo desafío consiste en una transferencia de aprendizaje, donde algunas capas de la red se modifican, a su vez se congela parte de las capas convolucionales de la red y el modelo es nuevamente entrenado con los datos pertinentes al nuevo problema. Algunos ejemplos de estas redes son: GoogLeNet<sup>30</sup>, Inceptionv3<sup>31</sup>, resnet-18<sup>32</sup>. Las redes neuronales preentrenadas presentan varias ventajas sobre las redes sin entrenamiento previo, especialmente en lo que respecta a la cantidad de datos necesarios para el entrenamiento. Esto se debe a que las redes preentrenadas ya tienen la capacidad de identificar y extraer características útiles de una imagen, lo que facilita la adaptación a un nuevo conjunto de datos mediante la técnica de congelamiento de capas.

### 3.8. TRABAJOS PREVIOS

La detección de anomalías en imágenes es una problemática tratada por diferentes investigadores, incluyendo imágenes del fondo del ojo y enfermedades oftalmológicas, donde se han utilizado diferentes enfoques para abordar los problemas que se presentan en el tratamiento de imágenes. Asimismo, se han desarrollado diferentes algoritmos que permiten hacer cálculos con las imágenes o llevar a cabo procesamientos para mejorar los resultados al momento de analizarlas.

Por esto mismo, se pueden encontrar trabajos que presentan algoritmos para la detección de enfermedades. Al ser imágenes que pueden ser adquiridas de manera relativamente sencilla y a bajo costo, el problema ha sido abordado en otras ocasio-

---

<sup>30</sup> SZEGEDY Christian et al. *Going deeper with convolutions*. Proceedings of the IEEE conference on computer vision and pattern recognition. 2015, pp. 1-9.

<sup>31</sup> SZEGEDY Christian et al. *Rethinking the inception architecture for computer vision*. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016, pp. 2818–2826.

<sup>32</sup> HE Kaiming et al. *Deep residual learning for image recognition*. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016, pp. 770–778.

nes y se hablará de los trabajos encontrados en el estado del arte para la detección de Glaucoma. Un ejemplo de esto es el trabajo realizado en <sup>9</sup>, donde se muestra que la detección automática de Glaucoma se lleva a cabo a través de técnicas de tratamiento de imágenes, con procesos a nivel de los píxeles de la imagen y detección de las diferentes partes de la retina utilizando métodos de segmentación, detección de bordes y umbralización.

Así mismo, se puede encontrar variedad en los enfoques utilizados para dicho fin. En otros trabajos, los algoritmos se basan en el uso de técnicas de inteligencia artificial, como las redes neuronales, siendo estas las que parecen mostrar mejores resultados en el área. Como se muestra en <sup>33</sup>, proponen un método que utiliza redes neuronales convolucionales y un conjunto de imágenes de 1630 capturas de fondo de ojo sanos y 46 imágenes con Glaucoma ya diagnosticado. Estas imágenes fueron usadas para el entrenamiento de la red, llegando a un 88.7% de precisión para la detección de Glaucoma. En el trabajo <sup>34</sup> es realizada una revisión sistemática centrada en el uso de algoritmos de aprendizaje automático o Machine Learning (ML) en el procesamiento de imágenes retinianas para el diagnóstico y detección del glaucoma. ML ha demostrado ser una herramienta significativa en el desarrollo de tecnología asistida por computadora, especialmente en oftalmología. La revisión, realizada mediante investigación secundaria, destaca la importancia de ML en el procesamiento de imágenes retinianas. Los métodos incluyeron la selección de publicaciones de bases de datos como Scopus, PubMed, IEEEXplore y Science Direct, abarcando los años 2014 a 2019. Durante este proceso de selección, se excluye-

---

<sup>33</sup> CHEN Xiangyu et al. *Glaucoma detection based on deep convolutional neural network*. 37th annual international conference of the IEEE engineering in medicine and biology society. 2015, pp. 715-718.

<sup>34</sup> BARROS Daniel et al. *Machine learning applied to retinal image processing for glaucoma detection: review and perspective*. Biomedical engineering online. 2020, vol. 19, pp. 1–21.

ron aquellos trabajos que se basaban en el método de disco óptico segmentado, al considerarse un enfoque distinto, y se priorizaron aquellos que se centraban en el proceso de clasificación de imágenes. La discusión resalta diversas arquitecturas de ML utilizadas en este campo, desde extracción de características hasta redes convolucionales profundas, diferenciándose principalmente en la cantidad de imágenes necesarias y los altos costos computacionales asociados. En las conclusiones, se sugiere la viabilidad de desarrollar un sistema automatizado para el diagnóstico del glaucoma, respaldado por la gravedad y prevalencia de la enfermedad. A pesar de los requisitos de bases de datos extensas y costos computacionales elevados, las técnicas de aprendizaje profundo, como el aumento de datos y el aprendizaje por transferencia, se aplican como alternativas para optimizar y reducir el entrenamiento de redes.

También se pueden encontrar diversos trabajos resaltando la relevancia de la inteligencia artificial en el área, como, <sup>35</sup>. Este artículo destaca el papel crucial de la inteligencia artificial, específicamente el aprendizaje profundo, en el campo de la oftalmología, con un enfoque especial en el análisis de datos provenientes de pruebas de imagen. Se examina el potencial de los algoritmos de aprendizaje profundo para mejorar la capacidad diagnóstica en casos de glaucoma, detallando ventajas y desafíos. El artículo trata acerca de la capacitación y validación de estos modelos en el contexto específico del glaucoma, considerando diversas pruebas, como la fotografía de fondo de ojo y la tomografía de coherencia óptica. Además, se destaca la importancia de una validación cuidadosa en la práctica clínica, teniendo en cuenta la población objetivo, los estándares de referencia y posibles sesgos. Otro trabajo

---

<sup>35</sup> THOMPSON AtalieC et al. *A review of deep learning for screening, diagnosis, and detection of glaucoma progression*. The Association for Research in Vision and Ophthalmology. 2020, vol. 9, nro. 2, pp. 42–42.

similar es presentado en <sup>36</sup>. Este estudio presenta la primera revisión de marcos de inteligencia artificial (IA) para la detección de glaucoma que utilizan imágenes de fondo de ojo y producen la segmentación del disco óptico como primer paso. Se identificaron 36 artículos publicados entre enero de 2011 y diciembre de 2021, centrándose en la imagen de fondo de ojo debido a su simplicidad y bajo costo. Los resultados indican que los marcos de IA de dos pasos que realizan la segmentación del disco óptico presentan resultados alentadores, con enfoques basados en reglas lógicas y modelos de aprendizaje automático/estadísticos. Sin embargo, se destaca que los marcos basados en reglas lógicas tienen limitaciones en la detección de glaucoma, y se resalta la importancia de la comparación directa entre enfoques de un paso y dos pasos en los mismos conjuntos de datos. Además, se señala la necesidad de trabajar en marcos de IA que utilicen imágenes de fondo de ojo a color para proporcionar contornos del disco óptico como primer paso, así como la importancia de construir y compartir conjuntos de datos adecuados y desarrollar pautas para informar de manera integral sobre marcos de IA.

La competición REFUGE <sup>37</sup> atrajo a diversos investigadores y condujo a desarrollos significativos en la detección de glaucoma mediante el análisis de imágenes. Los participantes utilizaron el conjunto de datos proporcionado para entrenar y evaluar algoritmos de clasificación de glaucoma y segmentación de disco/taza óptica. Este documento analiza los resultados y las contribuciones metodológicas de REFUGE, destacando su importancia en la mejora de las herramientas de diagnóstico y su potencial impacto clínico en la detección efectiva de sospechas de glaucoma. Tras

---

<sup>36</sup> COAN Lauren J et al. *Automatic detection of glaucoma via fundus imaging and artificial intelligence: A review*. Survey of ophthalmology. 2023, vol. 68, nro. 1, pp. 17–41.

<sup>37</sup> ORLANDO José Ignacio et al. *Refuge challenge: A unified framework for evaluating automated methods for glaucoma assessment from fundus photographs*. Medical image analysis. 2020, vol. 59, pp. 101570.

analizar los resultados del desafío, se destacan conclusiones metodológicas clave. A continuación, se abordan las fortalezas y limitaciones del desafío que podrían considerarse en futuras ediciones. Por último, se exploran las implicaciones clínicas de los resultados obtenidos.

Se observó que algunos de los modelos propuestos para la segmentación fueron capaces de obtener estimaciones precisas de la relación copa-disco vertical (vCDR). El mejor equipo en la tarea de segmentación (CUHKMED) logró el tercer lugar en la clasificación al utilizar el vCDR como una probabilidad de glaucoma, con valores de sensibilidad y especificidad casi iguales a dos expertos humanos, y estadísticamente equivalentes a los obtenidos utilizando las mediciones reales. Sin embargo, los equipos mejor clasificados complementaron las mediciones del disco óptico con los resultados de modelos basados en aprendizaje profundo, logrando superar significativamente a los expertos en glaucoma. Estos resultados indican que los modelos de aprendizaje profundo son capaces de identificar características complementarias, invisibles a simple vista, esenciales para un diagnóstico más preciso de la enfermedad.

Un trabajo previo significativo en esta área es el AIROGS: Artificial Intelligence for Robust Glaucoma Screening Challenge <sup>38</sup>. Este desafío aborda la disminución del rendimiento de los modelos de IA en escenarios del mundo real debido a la presencia de imágenes fuera de distribución y de baja calidad. El desafío incluye un extenso conjunto de datos de alrededor de 113,000 imágenes provenientes de aproximadamente 60,000 pacientes y 500 centros de detección diferentes. Los resultados de este desafío revelaron que los mejores equipos lograron un rendimiento comparable a un grupo de 20 expertos oftalmólogos y optometristas, alcanzando un área bajo la curva característica operativa del receptor de 0.99 para detectar imágenes no

---

<sup>38</sup> DEVENTE Coen et al. *AIROGS: Artificial Intelligence for robust glaucoma screening challenge*. IEEE transactions on medical imaging. 2023.

clasificables sobre la marcha. Estos hallazgos demuestran la viabilidad y la importancia de desarrollar algoritmos robustos para la detección de glaucoma mediante IA, contribuyendo significativamente al avance en este campo.

También se encuentran en el estado del arte trabajos que intentan atenuar el ruido presentado en las imágenes para mejorar los resultados de los algoritmos de detección de sospecha de enfermedad, como es el caso de <sup>39</sup>, donde se propone el uso de un filtro de difusión anisotrópica, también llamado filtro de difusión Perona-Malik, como parte del paso de preprocesamiento de la imagen. Este tipo de técnica de filtrado atenúa el ruido y el brillo en las imágenes, conservando también información sobre el disco óptico y los bordes tanto en el mismo disco óptico como en el sistema vascular de la retina, que son particularmente importantes en la detección de sospecha de Glaucoma y enfermedades de la diabetes. Ellos proponen solucionar el problema numérico con ecuaciones diferenciales parciales que representan el filtro de difusión, utilizando métodos miméticos de diferencias finitas. Además, se destaca el trabajo desarrollado en <sup>40</sup>, que utiliza este filtrado mimético anisotrópico aplicado a la detección de glaucoma con redes neuronales convolucionales. Demostraron que la aplicación del filtro mejora los resultados obtenidos por la red neuronal en un 1.5 % para precisión y 3.27 % para la sensibilidad del algoritmo.

En búsqueda de mejorar los resultados obtenidos por algoritmos de clasificación aplicados a este problema, se encuentran estrategias que utilizan la transformada wavelet en el estado del arte. De estos trabajos, se puede evidenciar que es posible llevar a cabo una detección de Glaucoma por medio de algoritmos que, al procesar

---

<sup>39</sup> VILLAMIZAR Jorge et al. *Mimetic finite difference methods for restoration of fundus images for automatic detection of glaucoma suspects*. Computer methods in biomechanics and biomedical engineering: imaging & visualization. 2022, vol. 10, nro. 5, pp. 492–499.

<sup>40</sup> CARRILLO Juan S et al. *Glaucoma Detection using Fundus Images with Mimetic Anisotropic Filtering and Convolutional Neural Networks*. 2022 E-Health and Bioengineering Conference (EHB). 2022, pp. 01–04.

las imágenes, entreguen una alerta para aquellas imágenes que presenten indicios de la presencia de las enfermedades.

En primera instancia, en <sup>41</sup>, proponen una descomposición de una señal de acuerdo a la información contenida utilizando la transformada wavelet. En el trabajo <sup>42</sup> del mismo autor, se aplica la teoría a señales 2D como parte del preprocesamiento y la extracción de características. Otro enfoque más aplicado a la clasificación se encuentra en <sup>26</sup>, donde se propone una aplicación de la transformada wavelet con filtros Gabor a imágenes para su posterior clasificación con algoritmos de inteligencia artificial. Esta estrategia se prueba en imágenes de números escritos a mano con un dataset de 70,000 imágenes. En los resultados, se compara una red neuronal convolucional y la estrategia propuesta utilizando una SVM como algoritmo de clasificación, donde se encuentra que el error es menor para el algoritmo propuesto. También se encontró un trabajo más afín al tratamiento de imágenes médicas, <sup>43</sup>, el cual busca detectar tumor cerebral en imágenes de resonancias magnéticas utilizando deep learning y la transformada wavelet. La estrategia consiste en realizar la descomposición de la imagen mediante la transformada wavelet y luego realizar la clasificación utilizando una red neuronal convolucional. Los resultados muestran una precisión del 99.3% para 100 casos de prueba.

---

<sup>41</sup> GILLES Jerome. *Empirical wavelet transform*. IEEE transactions on signal processing. 2013, vol. 61, nro. 16, pp. 3999–4010.

<sup>42</sup> GILLES Jerome et al. *2D empirical transforms. Wavelets, ridgelets, and curvelets revisited*. SIAM Journal on Imaging Sciences. 2014, vol. 7, nro. 1, pp. 157–186.

<sup>43</sup> SARHAN Ahmad M et al. *Brain tumor classification in magnetic resonance images using deep learning and wavelet transform*. Journal of Biomedical Science and Engineering. 2020, vol. 13, nro. 6, pp. 102.

## **4. MÉTODOS Y DESARROLLO**

En este capítulo se describen los métodos, procedimientos, enfoque metodológico, recursos, herramientas y tecnologías utilizados para llevar a cabo el proyecto. Se presentan las etapas y fases seguidas para su elaboración, brindando una descripción detallada de la implementación de la estrategia computacional.

### **4.1. RECOLECCIÓN DE DATOS**

La recolección de datos es una etapa crítica en el desarrollo de un modelo de red neuronal convolucional para el procesamiento de imágenes. Para entrenar una CNN, se necesitan grandes cantidades de datos de alta calidad que representen de manera fiel el problema que se desea resolver.

La recolección de datos puede llevarse a cabo de diversas maneras, dependiendo de la naturaleza del problema y de los recursos disponibles. Una opción es recopilar imágenes manualmente a partir de diversas fuentes, como bases de datos públicas, imágenes de internet o fotografías tomadas específicamente para el proyecto. Otra opción es generar imágenes de manera sintética, mediante técnicas de modelado 3D o simulaciones.

Una vez que se han recopilado las imágenes, es importante etiquetarlas de manera adecuada para poder utilizarlas en el entrenamiento de la CNN. Esto implica asignar una categoría o etiqueta a cada imagen, indicando a qué clase pertenece, como por ejemplo, un objeto específico, una persona o una escena.

Es importante tener en cuenta que la calidad y cantidad de los datos de entrenamiento tienen un impacto directo en el desempeño y precisión del modelo de CNN. Por lo tanto, se recomienda realizar una selección cuidadosa de los datos, asegurándose de que sean representativos, variados y de alta calidad.

Para el desarrollo de este proyecto se utilizó un banco de imágenes dispuesto por el Centro de Prevención y Consultoría en Glaucoma, 1538 imágenes del fondo del ojo que con ayuda de médicos especialistas se realizó el respectivo etiquetado. El etiquetado fue llevado a cabo por medio de una plataforma web desplegada para la tarea de lectura y tamizaje por parte de los especialistas, donde para cada imagen deben dar una valoración de glaucoma, también tienen posibilidad de descartar imágenes que no permitan la valoración de glaucoma o que presenten problemas de calidad, esto para mejorar la calidad del conjunto de imágenes para entrenar y validar los algoritmos. Los resultados de esta valoración médica pueden ser estratificados como se muestra en la tabla 2, donde se menciona la cantidad de imágenes disponible para cada valoración de Glaucoma.

Tabla 2. Estratificación de los datos

clasificación	0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
Cantidad	9	205	134	214	206	284	224	175	76	11

Fuente: autor

Es necesario aclarar que cada imagen tiene asignada una valoración de Glaucoma, en la tabla 2 se llama clasificación, esta valoración es un número entre 0 y 1, debido a que este es el formato utilizado por los oftalmólogos, donde valoraciones de 0.6 o mayores son clasificadas como una señal de glaucoma para el ojo.

El medio utilizado para el tamizaje y valoración en línea de las imágenes fue una plataforma web desarrollada para los fines de este proyecto, se entrará un poco en detalle a continuación.

**4.1.1. PLATAFORMA WEB** La plataforma web fue concebida con un enfoque centrado en la facilidad de uso y la accesibilidad para los usuarios, priorizando una interfaz de usuario intuitiva y herramientas de ayuda destinadas a facilitar el proceso de valoración de las imágenes. Este desarrollo fue específicamente diseñado para

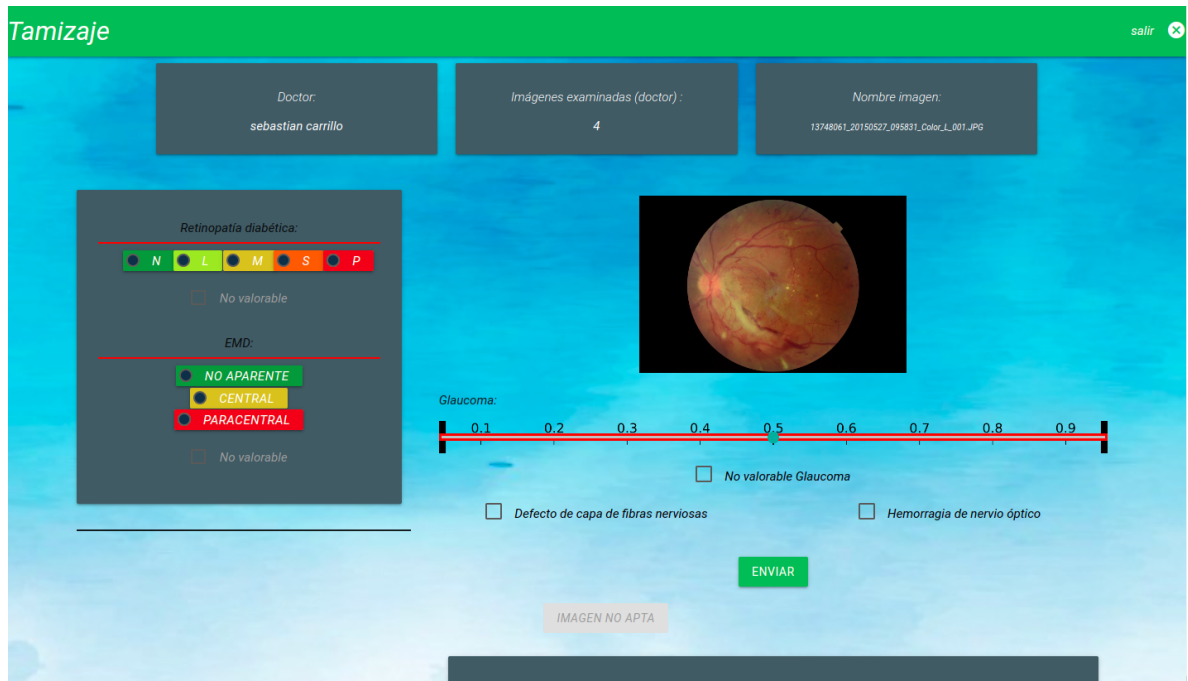
respaldar el proyecto de detección de enfermedades oculares, incluido el glaucoma, y fue utilizado por el grupo de trabajo conformado por matemáticos, médicos oftalmólogos y el ingeniero de sistemas, quien desempeñó un papel fundamental y principal en su diseño e implementación. La plataforma, desarrollada de manera más general, tuvo como uno de sus objetivos específicos la recopilación y clasificación de imágenes para la detección de glaucoma, aunque no se limitó exclusivamente a este propósito. Además, se implementaron medidas de seguridad y privacidad para salvaguardar las imágenes y la información recopilada por los médicos especialistas involucrados en el proyecto.

Para el ingreso los usuarios deben contar con un usuario y contraseña que se les es asignado de forma única a cada oftalmólogo. Seguidamente se les permite ingresar a una vista de la plataforma donde pueden realizar las valoraciones de imágenes previamente cargadas por el administrador del sitio, la valoración se realiza en la vista que se muestra en la Figura 11. Cuando el oftalmólogo realiza el tamizaje de la imagen da la valoración de glaucoma utilizando la barra mostrada en la Figura 11, esto fue diseñado para permitirle una mayor agilidad entre diferentes lecturas. Cabe mencionar que adicionalmente se le solicitan para cada imagen diferentes valoraciones médicas de enfermedades como el defecto de capa de fibras nerviosas (DCFN); retinopatía y edema macular diabético; estas son algunas opciones que se han almacenado en la base de datos de la misma valoración de imágenes para futuros proyectos.

La plataforma fue desarrollada utilizando HTML, PHP, JS junto con una base de datos MySQL que se administra por medio de phpMyAdmin con la posibilidad de guardar la lectura de cada imagen por separado independientemente del tipo de imagen (RGB o escala de grises).

La base de datos presentada en la Figura 13, se creó con el proceso de normalización de base de datos para almacenar de forma apropiada y eficiente los di-

Figura 11. Vista en la plataforma para lectura de imágenes




Fuente: BIOMEDICAL IMAGING VISION AND LEARNING LABORATORY. Glaucoma. [En línea]. Bucaramanga: Universidad Industrial de Santander. 2021. (Recuperado en 1 diciembre 2021.).

ferentes datos requeridos para la lectura de imágenes de la plataforma web, se pueden apreciar los diferentes campos utilizados para almacenar información sobre enfermedades como glaucoma o defecto de capa de fibras nerviosas, hemorragias, enfermedad macular, entre otras, también hay definidos campos para la información del doctor o calidad de la imagen.

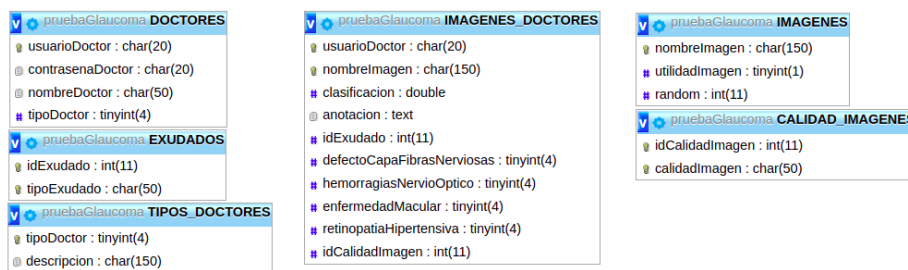
Esta plataforma web permitió realizar el etiquetado de las imágenes de forma eficiente para el entrenamiento y validación de los algoritmos desarrollados, cada una de las imágenes presentadas a los oftalmólogos pasó por validación con respecto a calidad y se almacenó de forma segura la lectura realizada por el especialista. Por medio de esta plataforma se cumplió el primer objetivo específico de este proyecto.

Figura 12. Valoración de glaucoma en la plataforma



Fuente: BIOMEDICAL IMAGING VISION AND LEARNING LABORATORY. Glaucoma. [En línea]. Bucaramanga: Universidad Industrial de Santander. 2021. (Recuperado en 1 diciembre 2021.).

Figura 13. Base de datos



Fuente: autor.

## 4.2. ESTRATEGIA COMPUTACIONAL

Como se evidenció en la revisión de la literatura, es viable desarrollar algoritmos computacionales para la detección de enfermedades en imágenes médicas, mejorando incluso los resultados mediante procesamiento previo de la imagen o extracción de características. Las estrategias computacionales pueden desempeñar un papel fundamental en el respaldo a la identificación de sospechas de glaucoma a través de imágenes del fondo del ojo, con algoritmos que llevan a cabo la detección correspondiente y amplían así el alcance del cuidado de la salud visual.

La clave reside en la capacidad de transferir parte del conocimiento de los especialistas a estrategias computacionales mediante algoritmos de aprendizaje supervisado. Esto posibilita que estas estrategias emulen el tamizaje realizado por un oftalmólogo especializado. Al abstraer parte del conocimiento de un profesional de

la salud, las estrategias computacionales facilitan la obtención de imágenes médicas para la identificación del glaucoma. En el estado del arte, existen algoritmos que permiten el procesamiento previo de datos o la extracción de características, potenciando así los procesamientos subsiguientes.

Dada la superioridad demostrada por la computación en términos de eficiencia en la lectura de imágenes, se puede abordar de manera efectiva la problemática relacionada con la detección del glaucoma a través de una estrategia computacional.

**4.2.1. EXTRACCIÓN DE CARACTERÍSTICAS** Se exploran dos métodos principales para desvelar información valiosa en las imágenes de fondo de ojo. La transformada wavelet tradicional destaca como una herramienta poderosa que realiza una descomposición multi-escala de las imágenes, capturando detalles fundamentales. Por otro lado, la transformada wavelet scattering, es un método que aprovecha las propiedades de invarianza y estabilidad para proporcionar una representación robusta de las características de las imágenes. A continuación, se presenta la implementación y consideraciones asociadas con ambos métodos, destacando su relevancia en el enfoque.

En primera instancia, la obtención de la transformada wavelet tradicional implica la descomposición multi-escala de la imagen utilizando una función wavelet. La descomposición multi-escala conlleva a la separación de la imagen en diferentes escalas y la transformación de cada una de estas escalas utilizando la función wavelet. Existen varios tipos de funciones wavelet o wavelet madre que se pueden utilizar en la descomposición multi-escala, cada una con diferentes propiedades y aplicaciones. Algunas de las funciones wavelet más utilizadas son la wavelet de Haar, la wavelet de Daubechies, la wavelet de Coiflet y la wavelet de Morlet.

Una vez que se ha aplicado la descomposición multi-escala utilizando la función wavelet seleccionada, se obtienen una serie de coeficientes de wavelet para cada escala. Estos coeficientes representan la cantidad de energía de la imagen que se

encuentra en cada escala y dirección.


Cuando se aplica la transformada wavelet tradicional a una imagen de fondo de ojo, la aplicamos sobre una de las tres bandas. Esto implica que es posible realizar diferentes combinaciones de entrada a la red, variando la aplicación de la transformada en determinado canal de la imagen, incluso variando la aplicación a un único canal. Tomando en cuenta que las imágenes, en principio, tienen tres canales RGB, se podrán tener combinaciones como  $R_w G B$  o  $R G_w B$ , entre otras, donde  $w$  representa la aplicación de la transformada en determinado canal.

Al aplicar la transformada wavelet tradicional, se obtiene un número determinado de coeficientes wavelet. Estos coeficientes se presentan en forma de matrices, y la cantidad de matrices dependerá de la escala a la que se lleve a cabo la transformada. Es importante tener en cuenta que esta transformada implica una descomposición de la información en diferentes escalas, por lo que utilizar niveles de aplicación muy grandes podría agregar información que no contribuye a la detección de glaucoma y entorpecer los cálculos necesarios debido al mayor tiempo de computación requerido para la transformada.

Los coeficientes obtenidos al realizar la transformada se pueden observar en la imagen Figura 14, donde se calculó la transformada tradicional wavelet de primer nivel de la imagen mostrada utilizando la wavelet madre Haar, estos coeficientes son llamados detalles y aproximación, donde en la Figura 14 a,b y c son los detalles obtenidos y la imagen d es la aproximación de primer nivel. Estos detalles incluyen (a) detalle diagonal, cuyo borde es resaltado en rojo, (b) detalle vertical, con borde en azul y (c) detalle horizontal, con borde verde, donde la dirección mencionada se debe al ángulo de aplicación de la wavelet madre con quien se realiza la convolución. Finalmente la imagen (d) aproximación, a la cual se le agregó un borde amarillo, es la imagen original pasada por un filtro de paso baja.

En la Figura 15, se presenta el modelo de la transformada wavelet tradicional para

Figura 14. Detalles y aproximación de la transformada wavelet tradicional




Fuente: autor.

obtener los detalles y la aproximación de nivel 3, generando un total de 10 matrices. Estas matrices comprenden 3 detalles por cada nivel y la aproximación del último nivel. Es fundamental destacar que, para introducir estos datos como entrada en la red neuronal convolucional preentrenada utilizada, estas matrices resultantes deben fusionarse en un máximo de 3 matrices del tamaño de la imagen original, de acuerdo con la configuración predefinida de la capa de entrada de la red neuronal, originalmente diseñada para trabajar con imágenes RGB.

Es importante subrayar que, en el caso de la transformada wavelet tradicional, todos los detalles y aproximaciones obtenidos de una matriz, independientemente del nivel de aplicación, pueden ser ensamblados en una única matriz del tamaño original de la imagen, como se ilustra en la Figura 14. No obstante, este último enfoque no es aplicable a la transformada wavelet scattering.

En la transformada wavelet tradicional, el tamaño de las matrices de detalles y aproximación disminuye a medida que se aumenta el nivel de la transformada, debido a la cantidad de convoluciones que se aplican a las aproximaciones. Esto nos lleva

Figura 15. Modelo de transformada wavelet tradicional



Fuente: autor.

a proponer un modelo de matriz compuesto por detalles y aproximaciones que se muestra en la Figura 16. En dicha figura, se puede observar cómo una transformada de nivel 3 queda acoplada en una matriz del tamaño original. Para crear esta matriz propuesta, no es necesario modificar los tamaños de las matrices de detalles o aproximación. Con este modelo se puede ubicar los detalles y aproximación en una única matriz y enviarla como parte de la entrada a la red neuronal.

Partiendo de que en general una wavelet ortogonal 2D puede ser formulada como se muestra a continuación:


$$\psi_{a_1, a_2, b_1, b_2}(x, y) = \frac{1}{\sqrt{a_1 a_2}} \psi \left( \frac{x - b_1}{a_1}, \frac{y - b_2}{a_2} \right) \quad (3)$$

donde  $a_1, a_2$  son parámetros de escala y  $b_1, b_2$  son parámetros de posición y  $\psi$  es la wavelet.

La transformada wavelet discreta de una función o imagen  $f(x, y)$  está dada por:

$$W(k, l) = \frac{1}{s} \sum_n \sum_m f(m, n) \psi \left( \frac{m - k}{s}, \frac{n - l}{s} \right) \quad (4)$$

Figura 16. Modelo propuesto de imagen con transformada wavelet tradicional



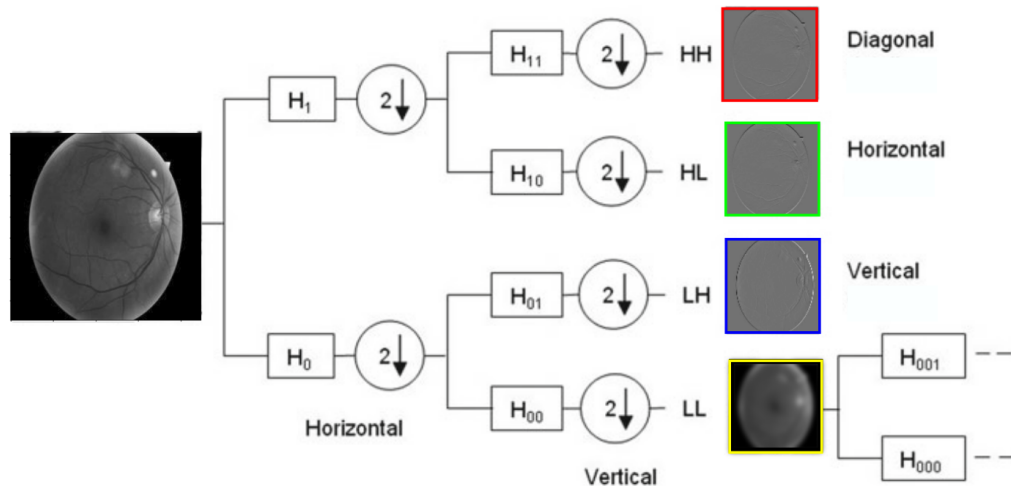
Fuente: autor.

donde  $m$  y  $n$  son el tamaño de la función o imagen,  $(k, l)$  son la posición de la wavelet y  $s$  el escalado.

En la Figura 17 se evidencia gráficamente el proceso para obtener los detalles y aproximación de la transformada wavelet tradicional, donde  $H_1$  referencia a la aplicación de la transformada wavelet en la dirección indicada y  $H_0$  la aplicación de un filtrado paso bajo. De esta manera la transformada wavelet tradicional analiza y representa la señal en diferentes rangos de frecuencia repitiendo el proceso de obtención de los detalles que buscan detectar altas frecuencias en la imagen y aproximación que toma las bajas frecuencias, cabe recalcar que en la Figura 17 las letras HH, HL, LH, LL hacen referencia al tipo de filtrado que se aplica para cada dirección, estando primero la componente horizontal y luego la vertical, entendiéndose así que el detalle diagonal se obtiene de un filtrado HH, es decir un filtro de paso alto para sus dos componentes, en este caso por medio de la aplicación de la wavelet madre de forma horizontal y luego de forma vertical.

El proceso para encontrar los detalles y aproximación puede resumirse matemática-

Figura 17. Proceso para encontrar la transformada wavelet tradicional de una imagen



Fuente: autor.

mente de la siguiente manera:

$$\phi(x, y) = \phi(x) \phi(y) \rightarrow \text{filtradoLL} \quad (5)$$

$$\psi^H(x, y) = \phi(x) \psi(y) \rightarrow \text{filtradoHL} \quad (6)$$

$$\psi^V(x, y) = \psi(x) \phi(y) \rightarrow \text{filtradoLH} \quad (7)$$

$$\psi^D(x, y) = \psi(x) \psi(y) \rightarrow \text{filtradoHH} \quad (8)$$

donde  $\phi$  y  $\psi$  son funciones de filtrado de paso bajo y wavelet respectivamente,  $\phi(x, y)$  es el coeficiente de aproximación,  $\psi^H(x, y)$  es el detalle horizontal,  $\psi^V(x, y)$  es el detalle vertical y por último  $\psi^D(x, y)$  es el detalle diagonal<sup>44</sup>.

Para la implementación de la extracción de características por medio de transformada wavelet scattering, se utilizó la librería kymatio <sup>45</sup>, esta presenta algoritmos implementados en Python para calcular la transformada de forma eficiente utilizando GPU, esta implementación utiliza la wavelet madre Morlet para el cálculo de la transformada en imágenes.

La transformada scattering realiza uno o más niveles de transformada donde el autor recomienda usar máximo 2, pues en este punto se consiguen las propiedades mencionadas anteriormente sobre escala y translación, evitando costes computacionales innecesarios por el cálculo de niveles posteriores que no generarían mayor aporte.

Estos niveles pueden ser resumidos de la siguiente manera:

$$S_J x = [S_J^{(0)} x, S_J^{(1)} x, S_J^{(2)} x] \quad (9)$$

donde  $x$  es la imagen de entrada,  $S_J x$  son los coeficientes scattering de  $x$ ,  $J$  hace referencia a la escala de los coeficientes obtenidos, y  $S_J^{(d)} x$  son los coeficientes scattering según el nivel  $d$  con  $d \in \mathbb{Z}^+$

$$S_J^{(0)} x = x \star \phi_J \quad (10)$$

---

<sup>44</sup> ZHANG Dengsheng. *Wavelet transform*. Fundamentals of Image Data Mining: Analysis, Features, Classification and Retrieval. 2019, pp. 35–44.

<sup>45</sup> ANDREUX Mathieu et al. *Kymatio: Scattering transforms in python*. The Journal of Machine Learning Research. 2020, vol. 21, nro. 1, pp. 2256–2261.

$$S_J^{(1)} x = \left[ \left| x \star \psi_\lambda^{(1)} \right| \star \phi_J \right]_\lambda \quad (11)$$

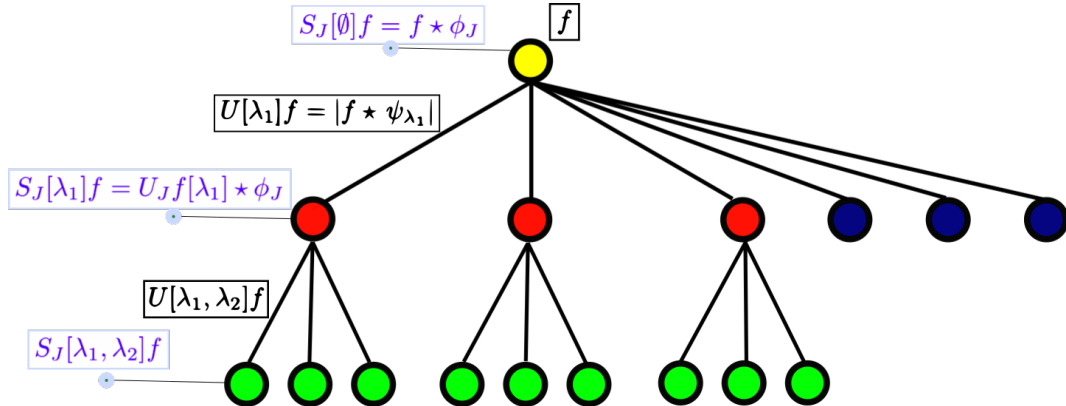
$$S_J^{(2)} x = \left[ \left| \left| x \star \psi_\lambda^{(1)} \right| \star \psi_\mu^{(2)} \right| \star \phi_J \right]_{\lambda, \mu} \quad (12)$$

donde  $\star$  denota la operación de convolución,  $\phi_J$  es el filtro de paso bajo,  $\psi_\lambda^{(1)}$  es una familia de filtros wavelet Morlet,  $\psi_\mu^{(2)}$  es otra familia de filtros wavelet Morlet.

La ecuación 10 efectúa un filtrado de la imagen donde elimina parte de las frecuencias altas para obtener el detalle de aproximación del nivel. En la aplicación a imágenes se tiene que la familia de filtros mencionada en la ecuación 11 es un conjunto generado por la variación del ángulo para la aplicación de la wavelet madre a una escala  $2^J$ ; en este nivel es posible variar y definir la cantidad de ángulos  $\lambda$  a utilizar. Finalmente, en el cálculo del segundo nivel en la ecuación 12 de la transformada se tiene una convolución con otra wavelet madre, siendo esta una única wavelet madre a la cual no se le modifican los ángulos de aplicación como en el primer nivel.

En la Figura 18, se observa el árbol de caminos seguido para obtener los coeficientes scattering. Este árbol se apega a las ecuaciones anteriormente mencionadas, donde el primer nivel del árbol corresponde a los coeficientes scattering  $S_J^{(0)} x$  mencionados en la ecuación 10. El segundo nivel del árbol se obtiene al aplicar la convolución de la imagen de entrada con cada una de las wavelets dentro del primer banco de filtros. Cada uno de los nodos del árbol representa la aplicación del operador  $U$  que es la convolución de la respectiva entrada al nodo con los filtros en el banco del nivel. Luego de esto, al ser convolucionados con el filtro de paso bajo, que aplica el escalado, se obtienen los coeficientes scattering  $S_J^{(1)} x$ , mencionados en la ecuación 11. Esto mismo sucede en el cada nivel, con la diferencia de que se utiliza

Figura 18. Proceso para encontrar la transformada wavelet Scattering de una imagen




Fuente: autor.

el respectivo banco de filtros correspondiente. Por lo tanto, el proceso para obtener los coeficientes scattering puede ser resumido de la siguiente manera:

- 1 Aplicar el filtro de paso bajo  $\phi_J$  a la imagen original para obtener el primer coeficiente scattering;
- 2 Aplicar la convolución de la imagen con cada uno de los filtros wavelet del primer banco  $\psi_{\lambda}^{(1)}$ ;
- 3 Aplicar el filtro paso bajo  $\phi_J$  a los resultados del paso anterior para obtener los coeficientes scattering del nivel correspondiente;
- 4 Repetir los pasos 2 y 3 variando el banco de filtros wavelet  $\psi_{\lambda}^{(d)}$ ;

Es importante destacar que el filtrado de paso bajo también incluye un escalado que reduce el tamaño de la imagen a  $m/2^j, n/2^j$ , donde  $m$  y  $n$  representan el tamaño de la imagen en píxeles, y  $j$  indica la escala. Este proceso asegura que todos los coeficientes generados tengan el mismo tamaño. Posteriormente, estos coeficientes pueden ser combinados en una sola imagen, como se muestra en la Figura 19, para

Figura 19. Imagen generada con coeficientes de la transformada wavelet Scattering



Fuente: autor

ser utilizados como datos de entrada en redes neuronales convolucionales. Esta imagen sigue la paleta de colores mostrada en el árbol Scattering en la Figura 18.

**4.2.2. RED NEURONAL CONVOLUCIONAL** La elección de implementar redes neuronales convolucionales en este estudio se fundamenta en su ventaja principal: la capacidad para aprender automáticamente características complejas a partir de datos de entrada sin procesar mediante el aprendizaje supervisado. Esta capacidad las convierte en una opción ideal para tareas de visión por computadora, como la clasificación de imágenes, la detección de objetos y la segmentación de imágenes. Por ende, se busca emplear una CNN para la detección de glaucoma. Además, como se señaló en secciones anteriores, es posible potenciar los resultados obtenidos por la red neuronal convolucional mediante la aplicación de algoritmos a los datos de entrada.

Este proyecto dispone de un conjunto de datos detallado anteriormente, donde cada imagen del fondo del ojo ha sido evaluada por un oftalmólogo y asignada a un número en un rango del cero al uno. Esta circunstancia motiva la búsqueda de la

implementación de un modelo que facilite la regresión lineal para ajustar los datos proporcionados por los oftalmólogos. Este aspecto es crucial para la red neuronal, ya que las capas de entrada y salida deben adaptarse a los datos específicos del proyecto. En este sentido, la capa final del modelo de inteligencia artificial debe contar con una única neurona para generar un valor numérico. Respecto a la capa de entrada, podría permitir el uso de imágenes de diversos tamaños, aunque este parámetro se ve condicionado por la capacidad computacional disponible. Es importante destacar que imágenes más grandes requieren una mayor cantidad de RAM y capacidad de cómputo para el entrenamiento de la red.


En este caso, se ha optado por utilizar redes neuronales convolucionales pre-entrenadas, ya que estas redes ya tienen conocimiento adquirido a partir de otro conjunto de datos. Esto aporta al modelo la capacidad de adaptarse más rápidamente, ya que estos modelos suelen requerir menos datos para el nuevo entrenamiento. Es importante resaltar que los modelos preentrenados son usualmente entrenados previamente con el conjunto de datos público ImageNet, que es un conjunto de imágenes RGB diseñado para el reconocimiento de objetos. Por lo tanto, estas redes no tienen conocimiento directo sobre imágenes de fondo del ojo o de glaucoma, pero sí aprenden a extraer algunas características importantes de las imágenes. Estas son las capacidades que se busca heredar al modelo adaptado a un nuevo problema. Además, estos modelos pueden ser cargados en diferentes lenguajes de programación.

El proceso para cargar una red previamente entrenada permite obtener el modelo completo o solo parte de él. En general, estos modelos se implementan para aplicarlos a nuevos problemas, lo que significa que se puede cargar solo la parte convolucional de la red, ignorando la sección de red neuronal profunda y clasificación que se encuentra en las últimas capas del modelo. La Figura 20 muestra la arquitectura original de la red neuronal convolucional ResNet-18. Es importante mantener la ca-

pa de entrada para la consistencia del modelo y su aprendizaje previo. Sin embargo, las últimas capas para clasificación pueden ser cambiadas por nuevas versiones que se adapten al nuevo problema. En el caso del problema de detección de glaucoma, se busca realizar una regresión. Por lo tanto, las capas finales originales del modelo, que en la Figura 20 se llaman Fully Connected (FC), son reemplazadas por 3 capas: una capa flatten y dos capas densas. La primera capa densa cuenta con 32 neuronas y la segunda con una sola neurona para realizar la regresión.

Se propone una arquitectura que utiliza la capa de entrada original de ResNet-18, por lo que seguirá recibiendo imágenes RGB, es decir con tres canales. Es importante tener en cuenta este aspecto al integrar los modelos previos de extracción de características y la red neuronal convolucional. La arquitectura de ResNet-18 utiliza bloques residuales, lo que permite que la información fluya alternativamente al camino lineal de las capas de convolución. Esto significa que las capas posteriores reciben información procesada por los bloques anteriores y, a su vez, información que aún no ha sido procesada. De esta manera, se reduce la alteración de los datos y la red puede determinar qué información es relevante para cada capa, lo que permite aprovechar mejor los datos extraídos por los algoritmos de transformada wavelet y acelerar el proceso de entrenamiento de la red.

Figura 20. Arquitectura ResNet-18



Fuente: autor

## 5. RESULTADOS

En esta sección, se presentarán los resultados obtenidos tras el entrenamiento de diferentes redes neuronales sobre el conjunto de datos mencionado anteriormente. Los modelos se han entrenado con el objetivo de realizar una regresión lineal para encontrar el valor entre 0 y 1 que indican los especialistas para detectar glaucoma, y las redes se han evaluado utilizando las métricas de sensibilidad, especificidad y error para medir su desempeño.

En primera instancia sobre la implementación de la red neuronal convolucional que es utilizada, se hicieron pruebas para determinar parámetros de entrenamiento que permitan convergencia del modelo, estos parámetros encontrados fueron:

- *Congelamiento de capas*: se congelan las primeras 11 capas del modelo para realizar nuevos entrenamientos.;
- *Optimizador*: SGD;
- *Tasa de aprendizaje*:  $4e^{-3}$ ;
- *Momentum*: 0.9;

La red neuronal convolucional (CNN) implementa una función ReLu como activación en la capa inmediatamente anterior y una función sigmoide en la capa final, las funciones de activación desempeñan un papel crucial en el funcionamiento de una red neuronal convolucional, ya que determinan cómo se propagan y transforman los datos a través de las capas. Es crucial señalar que la capa sigmoide realiza una regresión, lo cual implica la generación de valores en un rango específico, en este caso, de 0 a 1. Este aspecto se aborda en el contexto de un problema de clasificación al aplicar un umbral de 0.6, comúnmente utilizado por oftalmólogos

para la detección de casos de glaucoma. Es importante destacar que la clasificación se realiza posteriormente, junto con la aplicación del umbral, permitiendo identificar eficientemente los casos relevantes.

El conjunto de datos comprende imágenes del fondo del ojo, divididas en un 70 % para el entrenamiento y un 30 % para pruebas. Para asegurar una evaluación robusta del modelo y evitar el sobreajuste, se implementó la técnica de validación cruzada durante el entrenamiento, utilizando el 10 % del conjunto de entrenamiento para la validación. Además, se utilizó un lote (batch) de tamaño 24 y se llevó a cabo un entrenamiento con 50 epochs para optimizar el rendimiento de la red. Durante este proceso, se utilizó un dropout del 0.2 como técnica de regularización para prevenir el sobreajuste. Es importante destacar que el conjunto de pruebas se utilizó fuera del entrenamiento principal para evaluar el rendimiento de la red ante imágenes que no había visto anteriormente. Esta práctica asegura una evaluación imparcial de la capacidad predictiva del modelo en nuevos y no observados previamente durante el proceso de entrenamiento

En este proyecto, el conjunto de datos se somete a un proceso de preprocesamiento inicial para estandarizar el tamaño de las imágenes a 224x224 píxeles. Originalmente, cada imagen consta de 3 canales RGB. Posteriormente, estas imágenes se procesan mediante un algoritmo de extracción de características que utiliza la transformada wavelet. Como resultado, se generan nuevas imágenes que sirven como entrada a la red neuronal, permitiendo así llevar a cabo el proceso de regresión. La adaptación de los coeficientes generados por la transformada wavelet y la creación de las imágenes se detallan en las figuras 16 y 19.

Para prevenir el sobreajuste, se implementó una técnica de regularización mediante un dropout de 0.2. Es fundamental destacar que el conjunto de pruebas se emplea fuera del proceso de entrenamiento, permitiendo evaluar la eficacia de la red al enfrentarse a imágenes que no ha visualizado previamente. Este enfoque contribuye

a garantizar la generalización y robustez del modelo ante nuevos conjuntos de datos. La elección de Stochastic Gradient Descent (SGD) como optimizador para la red neuronal convolucional se fundamenta en varias razones. En primer lugar, SGD es conocido por su simplicidad y eficiencia computacional. Esto resulta especialmente beneficioso cuando se trabaja con grandes conjuntos de datos, como es común en tareas de aprendizaje automático. Además, la naturaleza estocástica de SGD permite una convergencia más rápida del modelo durante el entrenamiento. Al actualizar los parámetros del modelo de forma aleatoria en cada paso, SGD puede evitar quedar atrapado en óptimos locales y, en cambio, buscar soluciones más generales que puedan adaptarse mejor a datos nuevos. Estas características hacen que SGD sea una opción robusta y confiable para la optimización de modelos de clasificación, especialmente en el contexto médico de la detección de enfermedades oftalmológicas.

## 5.1. MÉTRICAS

En la evaluación del rendimiento del modelo de detección de glaucoma, se emplearon métricas fundamentales como la sensibilidad y la especificidad. Estas métricas proporcionan una comprensión cuantitativa de la capacidad del modelo para clasificar correctamente las instancias positivas (presencia de glaucoma) y negativas (ausencia de glaucoma), respectivamente.

**5.1.1. SENSIBILIDAD (RECALL O TASA DE VERDADEROS POSITIVOS)** La sensibilidad se define como la proporción de casos positivos correctamente identificados por el modelo con respecto al total de casos positivos presentes en el conjunto de datos. Se expresa mediante la fórmula:

$$\text{Sensibilidad} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Negativos}} \quad (13)$$

La sensibilidad, en el contexto de la detección de glaucoma, reviste una importancia

crucial. Este parámetro se define como la proporción de casos positivos correctamente identificados por el modelo con respecto al total de casos positivos presentes en el conjunto de datos.

Cuando se busca detectar glaucoma, una alta sensibilidad implica que los casos positivos de glaucoma son detectados de manera efectiva. Este enfoque se justifica al considerar que priorizar una alta sensibilidad tiene ventajas significativas.

Una alta sensibilidad asegura que menos casos glaucomatosos sean erróneamente clasificados como sanos, evitando así falsos negativos. En este contexto, es preferible activar una alarma para un caso sano que dejar pasar a un paciente glaucomatoso, ya que la detección temprana es esencial para prevenir la progresión de la enfermedad y mitigar el riesgo de ceguera. La sensibilidad desempeña un papel fundamental al garantizar la identificación efectiva de casos positivos de glaucoma, contribuyendo así a la eficacia y relevancia clínica del modelo. Según la opinión de los médicos oftalmólogos, la sensibilidad se destaca como uno de los factores importantes a tener en cuenta debido a la valiosa información que proporciona sobre la salud visual del paciente. Esta consideración refuerza la importancia de desarrollar técnicas de procesamiento de imágenes retinianas que maximicen la sensibilidad para una detección precisa y temprana de afecciones oculares.

**5.1.2. ESPECIFICIDAD (TASA DE VERDADEROS NEGATIVOS)** La especificidad mide la capacidad del modelo para identificar correctamente los casos negativos, es decir, aquellos sin presencia de glaucoma. Se calcula mediante la siguiente fórmula:

$$\text{Especificidad} = \frac{\text{Verdaderos Negativos}}{\text{Verdaderos Negativos} + \text{Falsos Positivos}} \quad (14)$$

**5.1.3. ERROR** El error, que representa la tasa de error del modelo, se define como:

$$\text{Error} = 1 - \text{Precisión} \quad (15)$$

Estas métricas son esenciales para evaluar el rendimiento del modelo en términos de detección precisa y clasificación correcta de casos positivos y negativos.

## **5.2. TRANSFORMADA WAVELET TRADICIONAL**

Los posibles parámetros que se pueden variar al momento de realizar la transformada wavelet tradicional incluyen el nivel al que se aplica la transformada, la wavelet madre utilizada y cómo se transmiten los datos de esta a la red neuronal convolucional. Para llegar a un consenso sobre los parámetros, en primera instancia se decidió utilizar 3 niveles de la transformada. Se llegó a esta conclusión porque usar un nivel mayor no aporta más información a la red. Además, cada nivel reduce el tamaño de las matrices coeficientes a cerca de 1/4 del tamaño en el nivel anterior. Si bien es posible utilizar un mayor número de niveles, estos suelen introducir ruido que no mejora los resultados y, en muchos casos, dificulta la convergencia del entrenamiento. Esto se debe a una disminución en las métricas utilizadas y aumento en el tiempo de cómputo requerido.

Se llevaron a cabo experimentos enfocados a encontrar la manera adecuada de acoplar la transformada wavelet tradicional como método de extracción de características para alimentar la red neuronal. Estos experimentos constaron de pruebas en las que se varió la información en los tres canales que recibe la red neuronal. Como se mencionó en la sección 4.2, al aplicar la transformada tradicional, el método propuesto ubica todos los coeficientes obtenidos en una misma matriz del tamaño de la imagen original. Esto permitió diferentes combinaciones en los canales, en las que se puede o no aplicar la transformada de manera particular a cada canal.

**5.2.1. WAVELET MADRE HAAR** Este experimento se llevó a cabo fijando la wavelet madre Haar para el cálculo de la transformada, se busca probar algunas de las posibles combinaciones de 3 canales para una imagen y verificar los resultados que obtiene la red neuronal al ser entrenada con cada una de estas entradas; para esto se entrenaron veinte redes para cada opción de configuración de canales, cada una utilizando los parámetros de entrenamiento mencionados anteriormente. Los resultados se muestran en la tabla 3 y la tabla 4.

Durante el desarrollo de este experimento, la misma red neuronal fue sometida a entrenamiento en 20 instancias, conservando invariables los parámetros previamente mencionados. No obstante, se introdujo una variación en el tipo de imagen de entrada al utilizar la wavelet madre Haar para la implementación de la transformada wavelet tradicional, donde dicha variación podría afectar uno o varios canales de la imagen simultáneamente. Asimismo, se llevaron a cabo evaluaciones de los resultados prescindiendo de la aplicación de dicha transformada, sirviendo esta comparación como método de análisis.

Tabla 3. Sensibilidad del modelo con la variación en canales

Entrada	<i>RGB</i>	<i>RRR</i>	<i>GGG</i>	<i>BBB</i>
Sens. max	88.46 %	86.53 %	94.23 %	87.5 %
Sens. promedio todos	49.61 %	51.53 %	54.47 %	44.03 %
Sens. promedio Convergentes	55.02 %	62.59 %	67.76 %	62.89 %
DE todos	22.97 %	26.30 %	28.50 %	30.14 %
DE Convergentes	12.58 %	10.38 %	11.08 %	11.57 %
Convergencia Sens.	74.44 %	78.66 %	78.33 %	69.33 %

Fuente: autor

Las tablas 3 y 4 muestran cómo varía la sensibilidad de la detección de glaucoma según la entrada a la red neuronal convolucional. Cada entrada consta de tres canales, originalmente *RGB*. Siguiendo esta notación, se denominan las diferentes combinaciones dependiendo del canal que se utiliza para el cálculo de la transformada y del

Tabla 4. Sensibilidad del modelo con la variación en canales y transformada wavelet tradicional

Entrada	$G_wGB$	$R_wG_wB_w$	$G_wG_wG$	$G_wGG$
Sens. max	89.42 %	87.5 %	91.34 %	94.23 %
Sens. promedio todos	63.56 %	54.10 %	57.44 %	65.48 %
Sens. promedio Convergentes	71.07 %	64.44 %	63.63 %	70.65 %
DE. todos	22.30 %	24.22 %	20.64 %	16.58 %
DE. Convergentes	10.57 %	9.40 %	8.48 %	8.32 %
Convergencia Sens.	82.88 %	84.88 %	86.11 %	87.01 %

Fuente: autor

orden en que se ubican en la imagen de entrada. Por ejemplo,  $R$  corresponde al canal rojo original, mientras que  $R_w$  se refiere a la transformada del canal rojo. Esta misma convención se aplica para el canal verde ( $G$ ) y el canal azul ( $B$ ).

Los resultados de este estudio se presentan en las tablas 3 y 4, donde se analiza el impacto de la aplicación de la transformada wavelet tradicional en diferentes combinaciones de canales, estas tablas muestran la sensibilidad máxima obtenida durante los entrenamientos, así como la sensibilidad promedio y el porcentaje de convergencia. Este último indicador representa el porcentaje de entrenamientos que resultaron en una red con una sensibilidad mayor a cero. En la tabla 3, se muestran los resultados sin aplicar la transformada a ningún canal, y se observa que la repetición del canal verde en las tres posiciones ( $GGG$ ) proporciona la mejor sensibilidad para el algoritmo sin transformada. Por otro lado, en la tabla 4, se presentan los resultados de la aplicación de la transformada en algunas combinaciones de los canales. Se puede apreciar que la entrada  $G_wGG$  produce la misma sensibilidad máxima que la entrada  $GGG$  siendo estas las mejores del experimento, y se concluye que estas son las mejores combinaciones y que al aplicar la transformada en esta combinación ( $G_wGG$ ), el modelo tiene más probabilidades de obtener sensibilidades diferentes de cero, mejorando la obtenida por la combinación  $GGG$  que fue de 78.33 % a 87.01 % obtenida por la configuración  $G_wGG$ . Cabe destacar que, en algunos casos, la sen-

sibilidad puede no converger a cero, incluso cuando el error de la red es pequeño, esto ocurre debido a una mayor cantidad de casos con sanos que de casos glaucomatosos en el dataset, sumado a que el resultado de la regresión puede entregar valores de ratio de disco-excavación más pequeños de lo esperado. Finalmente, es importante destacar que el porcentaje de convergencia es mayor en la tabla 4 que en la tabla 3, lo que refuerza la idea de que la aplicación de la transformada wavelet tradicional mejora en general la convergencia de la sensibilidad.

Tabla 5. Especificidad y error del modelo con la variación en canales

Entrada	<i>RGB</i>	<i>RRR</i>	<i>GGG</i>	<i>BBB</i>
Error promedio	11.97 %	11.95 %	11.65 %	12.14 %
DE. error	3.16 %	2.90 %	2.29 %	2.74 %
Error min.	9.57 %	9.60 %	9.39 %	9.47 %
Esp. promedio	86.22 %	85.18 %	84.78 %	88.46 %
DE. Esp.	6.37 %	6.65 %	7.03 %	8.62 %

Fuente: autor

Tabla 6. Especificidad y error del modelo con la variación en canales y transformada wavelet tradicional

Entrada	$G_wGB$	$R_wG_wB_w$	$G_wG_wG$	$G_wGG$
Error promedio	11.65 %	11.56 %	11.45 %	11.50 %
DE. error	2.56 %	2.44 %	2.16 %	2.03 %
Error min.	9.32 %	9.58 %	9.39 %	9.34 %
Esp. promedio	85.71 %	88.80 %	87.78 %	85.13 %
DE. Esp.	6.36 %	5.23 %	8.17 %	6.94 %

Fuente: autor

Se han tenido en cuenta las métricas de especificidad y error, y se presentan en las tablas 5 y 6. Se observa que las entradas con transformada obtienen mejores resultados en términos de error promedio y mínimo, aunque se detectan valores similares para las distintas combinaciones. En cuanto al error mínimo, la entrada  $G_wGB$  obtiene el mejor resultado, seguida por  $G_wGG$ . Dado que la especificidad indica la

cantidad de casos sanos detectados, en el desarrollo del proyecto se ha priorizado obtener resultados de sensibilidad alta. Sin embargo, se observa que el modelo supera el 84 % de especificidad promedio para todas las entradas, alcanzando un máximo de 88.80 % con la entrada  $R_w G_w B_w$ .

**5.2.2. VARIACIÓN DE LA WAVELET MADRE** Entre los parámetros que requieren ajuste manual se encuentra la selección de la wavelet madre utilizada para el cálculo de la transformada wavelet tradicional. Para ello, se diseñaron experimentos en los que se fijaron los demás parámetros y se varió la wavelet madre. Se entrenaron 20 redes neuronales utilizando los mismos parámetros de entrenamiento descritos anteriormente. Este experimento fue llevado a cabo con entradas  $G_w G G$  por el desempeño mostrado en la prueba anteriormente mencionada.

Tabla 7. Variación de la wavelet madre(Sensibilidad)

Wavelet	Haar	Bior1.3	Db2	Sym2
Sens. máxima.	94.23 %	91.34 %	90.38 %	91.34 %
Sens. promedio todos	65.48 %	59.76 %	59.25 %	59.41 %
Sens. promedio Convergentes	70.65 %	65.45 %	63.25 %	68.35 %
DE. sens.	16.58 %	17.92 %	18.48 %	17.62 %
DE. sens. convergentes	8.32 %	9.50 %	10.81 %	10.42 %
convergencia sens.	87.01 %	88.44 %	84.77 %	88.55 %

Fuente: autor

La tabla 7 muestra los resultados de sensibilidad obtenidos en este experimento, en los que se destaca que la sensibilidad se mantiene por encima del 84 %, superando así los resultados obtenidos por las entradas de la red que no incluyen la transformada wavelet tradicional en el experimento anterior. De las opciones evaluadas en este experimento, la wavelet madre Haar presenta los mejores resultados en cuanto a sensibilidad máxima y promedio. Sin embargo, en términos de convergencia de la sensibilidad, la wavelet madre bior1.3 supera a la Haar por una diferencia de 1.43

unidades porcentuales.

Tabla 8. Variación de la wavelet madre(Error y especificidad)

Wavelet	Haar	Bior1.3	Db2	Sym2
Error promedio	11.50 %	11.14 %	11.14 %	11.11 %
DE. Error	2.72 %	3.43 %	3.15 %	3.94 %
Error min.	9.34 %	9.29 %	9.23 %	9.27 %
Esp. promedio	85.13 %	86.56 %	87.416 %	86.60 %
DE. esp	6.21 %	5.48 %	7.03 %	5.83 %

Fuente: autor

También se presentan los resultados obtenidos para este experimento concernientes al error y la especificidad, mostrado en la tabla 8, donde el mejor error mínimo fue obtenido por la wavelet madre db2, aun así los diferentes wavelet tuvieron resultados parecidos, diferenciándose en no más de 0.11 unidades porcentuales del mejor resultado.

### 5.3. TRANSFORMADA WAVELET SCATTERING

Los experimentos que involucraron la transformada wavelet scattering se llevaron a cabo mediante el entrenamiento de 20 redes neuronales para cada entrada, utilizando los mismos parámetros de entrenamiento que en pruebas anteriores, junto con la estrategia de matriz para scattering descrita en la sección 4.2. En este caso, la cantidad de coeficientes que se pueden utilizar como entrada a la red neuronal está limitada debido a que no es posible colocarlos en una única matriz como en el caso de la transformada tradicional. Para la transformada wavelet scattering, cuanto mayor es la escala y mayor cantidad de ángulos se utilizan, los coeficientes (todos del mismo tamaño) se incrementan en número y ocupan más matrices que en la transformada tradicional.

Por lo tanto, para las pruebas relacionadas con la transformada wavelet scattering, se buscaron combinaciones de valores de  $L$  y  $J$  que permitieran aprovechar de

mejor manera el espacio disponible en uno, dos o tres canales. Las combinaciones elegidas fueron  $J = 1, L = 3$ ,  $J = 2, L = 3$ ,  $J = 3, L = 4$ , donde  $J$  se refiere a la escala y  $L$  a los ángulos aplicados. Estas combinaciones permitieron obtener coeficientes que completaron el espacio de una matriz llena de coeficientes para el caso de  $J = 1$ , dos matrices llenas de coeficientes para el caso de  $J = 2$ , y tres matrices para el caso de  $J = 3$ . De esta forma, se evitaron espacios vacíos en las matrices y se abarcaron las tres posibilidades de escala que se pueden utilizar para el problema.

Tabla 9. Variación de la entrada con transformada wavelet Scattering(sensibilidad)

Entrada	$J = 1, L = 3$	$J = 2, L = 3$	$J = 3, L = 4$
Sens. max	91.34 %	96.15 %	90.38 %
Sens. promedio todos	64.52 %	66.75 %	65.46 %
Sens. promedio convergentes	80.67 %	81.29 %	81.61 %
DE. Sens.	18.14 %	19.82 %	20.64 %
DE. Sens. convergentes	6.84 %	8.93 %	5.32 %
Convergencia Sens.	74.66 %	70.66 %	68.22 %

Fuente: autor

En la tabla 9 se muestran los resultados obtenidos en la prueba de sensibilidad. Se puede observar que la transformada scattering demostró una superioridad en términos de sensibilidad en comparación con los resultados obtenidos en los experimentos anteriores. Además, esta superó tanto los resultados de la transformada wavelet tradicional como los de los datos sin transformada wavelet, manteniendo parte de la convergencia de sensibilidad que se obtuvo con la transformada tradicional.

Con respecto a la especificidad y error entregadas por las pruebas con transformada scattering en la tabla 10, se obtienen valores similares a los de la transformada tradicional.

En resumen, es fundamental resaltar la mejora en la sensibilidad lograda tanto con la transformada tradicional como con la transformada scattering en el contexto de la

Tabla 10. Variación de la entrada con transformada wavelet Scattering(error y especificidad)

Entrada	$J = 1, L = 3$	$J = 2, L = 3$	$J = 3, L = 4$
Error promedio	11.79 %	11.83 %	11.91 %
DE. error	2.74 %	2.97 %	2.87 %
Error min.	9.52 %	9.61 %	9.60 %
Esp. promedio	86.41 %	86.49 %	87.41 %
DE. esp.	9.45 %	7.34 %	9.73 %

Fuente: autor

detección de glaucoma. Este valor es crucial, ya que indica la capacidad del algoritmo para clasificar correctamente los casos de glaucoma. En última instancia, este es el objetivo principal de los algoritmos de detección de enfermedades.

**5.3.1. PRUEBAS EN DATASET PÚBLICO** En esta sección se llevan a cabo experimentos utilizando nuestro modelo sobre el conjunto de datos ORIGA. Este dataset público contiene 650 imágenes de fondo del ojo recolectadas por un estudio en Singapur. Los autores del dataset proporcionaron las imágenes junto con una valoración de ratio disco-excavación correspondiente, la cual se utiliza para la evaluación de glaucoma. La distribución de los valores de ratio disco-excavación en el conjunto de datos ORIGA se presenta en la tabla 11. Al establecer un umbral de 0.6, se identificaron 263 imágenes clasificadas como glaucomatosas y 386 imágenes como sanas en el conjunto de datos. En el artículo citado, los autores proporcionan información detallada sobre los algoritmos y herramientas utilizados para recopilar y evaluar los datos <sup>46</sup>.

El propósito de estas pruebas es evaluar la capacidad del modelo para adaptarse

---

<sup>46</sup> ZHANG Zhuo et al. *Origalight: An online retinal fundus image database for glaucoma analysis and research*. 2010 Annual international conference of the IEEE engineering in medicine and biology. 2010, pp. 3065–3068.

Tabla 11. Estratificación de los datos(ORIGA)

Clasificación	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
Cantidad	2	4	26	140	214	175	62	24	2
Porcentaje	0.3 %	0.6 %	4 %	21.5 %	32.9 %	26.9 %	9.5 %	3.6 %	0.3 %

Fuente: autor

a nuevos datos, lo que permitirá identificar fortalezas y áreas de mejora en nuestro enfoque.

Para entrenar la red con el nuevo conjunto de imágenes, se utilizó la red previamente entrenada con un conjunto de imágenes privadas. Se modificaron los parámetros de entrenamiento del optimizador de la red disminuyendo la tasa de aprendizaje a  $1e^{-3}$  y reduciendo el momentum a 0.8. Estas modificaciones se enfocaron en conservar gran parte del aprendizaje adquirido con el primer conjunto de datos. Además, se congelaron 11 capas del modelo para transferir el aprendizaje previo de manera apropiada.

La red utilizada es un modelo obtenido mediante la estrategia computacional que utiliza transformada wavelet scattering como método de extracción de características. En la tabla 12 se muestran los valores obtenidos por la red cuando solo ha sido entrenada con el conjunto de datos privado, este dataset fue el brindado por medio de Centro de Prevención y consultaría en Glaucoma.

Tabla 12. Comparación de resultados entre datasets(entrenamiento unicamente con privado)

	Dataset privado	Dataset ORIGA
Sensibilidad	96.72 %	30.04 %
Especificidad	72.33 %	87.30 %
Error	11.56 %	14 %

Fuente: autor

En la tabla 13 se muestran los valores obtenidos por la red para cada dataset luego

de que fue entrenada con el dataset ORIGA.

Tabla 13. Comparación de resultados entre datasets (entrenamiento con dataset privado y ORIGA)

.	Dataset privado	Dataset ORIGA
Sensibilidad	90.12 %	95.81 %
Especificidad	82.60 %	52.84 %
Error	8.47 %	7.37 %

Fuente: autor

Después del entrenamiento con ORIGA, el modelo logró identificar una gran cantidad de casos de glaucoma en el nuevo conjunto de datos, alcanzando una sensibilidad del 95.81 %. Esto indica que la mayoría de los casos de glaucoma podrían ser detectados por el modelo. Por otro lado, se observa una especificidad baja junto a un error del 7.37 %. Esto sugiere que algunos casos sanos son evaluados como si fueran glaucomatosos, y estos se encuentran cercanos al umbral de 0.6.

**5.3.2. DEFORMACIONES Y DESPLAZAMIENTOS** En esta sección, se busca evaluar cómo se comportan los modelos ante cambios en las imágenes. En este caso, se considerarán dos tipos de cambios: traslaciones y deformaciones. Para las traslaciones, se aplican rotaciones en un ángulo aleatorio distinto para cada imagen del conjunto privado. Por otro lado, los cambios de tipo deformación se llevan a cabo utilizando la función de deformación elástica disponible en Python a través de la librería `elasticdeform`.

Durante las pruebas, se compararon los resultados obtenidos por dos tipos de modelos: aquellos que fueron entrenados utilizando imágenes  $GGG$  como entrada, y aquellos que utilizaron imágenes con la transformada wavelet scattering  $GG_{ws}G$ , con parámetros  $J = 2$  y  $L = 3$ . Para ambos casos se utilizó el mismo conjunto de datos y se le aplicaron los mismos cambios a las imágenes.

En cuanto a la sensibilidad, se puede observar en la tabla 14 que esta métrica dis-

minuye para ambos modelos cuando se les aplican modificaciones a las imágenes de entrada. Sin embargo, el modelo que utiliza la transformada wavelet scattering ofrece mejores resultados al presentar una menor disminución en la sensibilidad, tanto en los cambios de traslación como en los de deformación de la imagen.

Tabla 14. Variación de la sensibilidad por rotaciones o deformaciones

	Normal	Rotaciones	Deformaciones
Modelo GGG	93.27 %	81.73 %	58.63 %
Modelo con scattering	92.31 %	84.61 %	66.35 %

Fuente: autor

Además, se presentan las tablas de especificidad 15 y error 16. En estas tablas se puede apreciar que los resultados sufren variaciones al aplicar los cambios en la imagen, aunque estos no resultan ser determinantes o diferenciales para ambos modelos, ya que en ambos casos se observan porcentajes y variaciones similares.

Tabla 15. Variación de la especificidad por rotaciones o deformaciones

	Normal	Rotaciones	Deformaciones
Modelo GGG	63.59 %	66.95 %	72.54 %
Modelo con scattering	66.67 %	64.42 %	71.99 %

Fuente: autor

Tabla 16. Variación del error por rotaciones o deformaciones

	Normal	Rotaciones	Deformaciones
Modelo GGG	14.08 %	13.60 %	14.38 %
Modelo con scattering	12.63 %	13.59 %	14.51 %

Fuente: autor

Es importante aclarar que las modificaciones o alteraciones realizadas en las imágenes se aplican artificialmente mediante algoritmos y no se presentan de manera natural en las imágenes. Incluso si se presentaran de manera natural, lo harían en

menor grado. A pesar de esto, los resultados de las pruebas muestran que las estrategias que utilizan la transformada wavelet scattering como método de extracción de características son más estables a posibles alteraciones de la imagen en términos de sensibilidad.

#### **5.4. DISCUSIÓN DE LOS RESULTADOS**

En este capítulo, se presenta una detallada discusión sobre los resultados obtenidos en el presente estudio. Se analizan en profundidad los hallazgos y se establecen conexiones con los objetivos planteados en la tesis. Además, se exploran las implicaciones de los resultados en el contexto de la problemática abordada, brindando una visión crítica y reflexiva sobre los hallazgos obtenidos.

La sección de discusión de resultados incluye gráficos que sintetizan y visualizan los resultados obtenidos en varias secciones anteriores de la tesis. Estos gráficos ayudan a presentar de manera clara y concisa la información relevante, permitiendo una mejor comprensión de los patrones y tendencias identificados en los datos.

En primer lugar, se presenta una síntesis de los resultados obtenidos al evaluar la sensibilidad de la red neuronal ante diferentes tipos de entrada. Esto resulta crucial, ya que la sensibilidad es un indicador fundamental para evaluar la capacidad de detección y la eficacia del modelo en la identificación de casos positivos. En la Figura 21, se muestra una comparación de los resultados obtenidos, destacando que la red neuronal convolucional que utiliza imágenes de entrada sometidas a un proceso de extracción de características utilizando transformada wavelet scattering con parámetros  $J = 2$  y  $L = 3$  ha demostrado el mejor desempeño en términos de sensibilidad.

La sensibilidad es un factor crítico en el contexto de la detección de glaucoma, ya que nos indica la capacidad de la red neuronal para identificar correctamente los casos positivos de la enfermedad. Una sensibilidad alta implica que la red neuronal

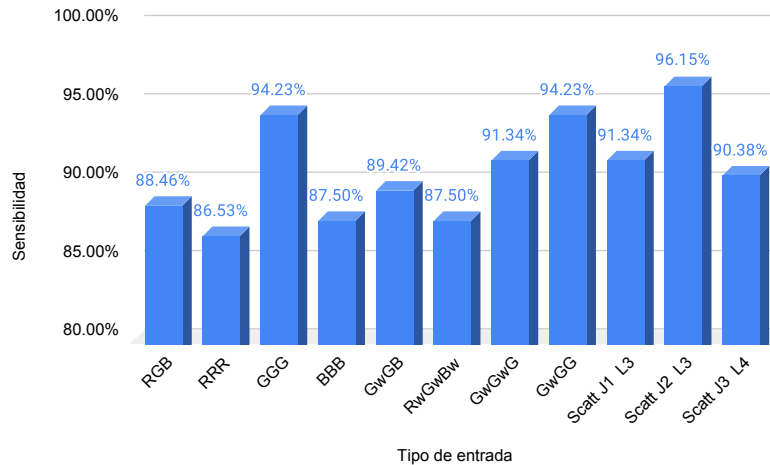
es capaz de detectar la presencia de glaucoma en un alto porcentaje de los casos reales de la enfermedad, minimizando así los falsos negativos. Esto es particularmente relevante, ya que un diagnóstico temprano y preciso del glaucoma es fundamental para un tratamiento adecuado y la prevención de posibles daños visuales irreversibles.

Los resultados obtenidos resaltan la importancia de utilizar técnicas avanzadas de extracción de características, como la transformada wavelet scattering, en conjunción con redes neuronales convolucionales para mejorar la sensibilidad del modelo de detección de glaucoma. Este enfoque permite capturar patrones y detalles relevantes en las imágenes del fondo del ojo, lo que a su vez fortalece la capacidad del modelo para identificar cambios sutiles asociados al glaucoma.

Una sensibilidad alta tiene implicaciones significativas en la práctica clínica y la toma de decisiones médicas. Al mejorar la capacidad de detección de la red neuronal, se puede reducir el riesgo de sub diagnóstico y retrasos en el tratamiento, lo que a su vez puede mejorar los resultados de salud para los pacientes. Además, una mayor sensibilidad puede ayudar a reducir la carga de trabajo de los profesionales de la salud al identificar de manera más eficiente los casos sospechosos de glaucoma, permitiéndoles enfocarse en los casos más críticos y proporcionar una atención personalizada de manera oportuna.

La Figura 22 ilustra los resultados de convergencia obtenidos al utilizar diferentes tipos de entrada durante el entrenamiento del modelo. Durante el proceso de entrenamiento, es posible que algunos modelos arrojen resultados en los que la sensibilidad tienda a ser cero y la precisión sea baja. Sin embargo, se observa que la transformada wavelet tradicional muestra los mejores resultados de convergencia, alcanzando hasta 87.01 % de éxito en los entrenamientos. Este hallazgo destaca el importante aporte que la transformada wavelet realiza al proceso de aprendizaje de la red neuronal convolucional para la detección de glaucoma.

Figura 21. Sensibilidad máxima obtenida variando el tipo de entrada



Fuente: autor

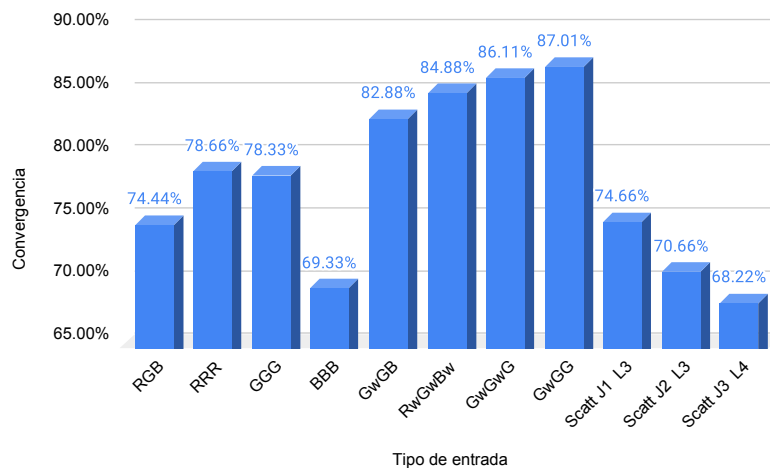
La convergencia de un modelo es un indicador clave de su capacidad para aprender y ajustarse a los datos de entrenamiento. Una alta tasa de convergencia indica que el modelo está aprendiendo de manera efectiva y mejorando su capacidad para detectar patrones relevantes asociados al glaucoma en las imágenes del fondo del ojo. En este sentido, el rendimiento destacado de la transformada wavelet tradicional en términos de convergencia resalta su utilidad y efectividad como una técnica de preprocesamiento valiosa en el entrenamiento de la red neuronal convolucional.

La transformada wavelet, al aplicarse a las imágenes de entrada, permite capturar y representar de manera eficiente las características y detalles importantes presentes en las imágenes del fondo del ojo. Esto, a su vez, facilita el proceso de aprendizaje de la red neuronal, ya que proporciona información enriquecida y reduce la redundancia en los datos de entrada. La transformada wavelet tradicional, en particular, ha demostrado su eficacia en la detección de patrones relevantes para el glaucoma, lo que se refleja en su destacada contribución a la convergencia del modelo.

El hecho de que la transformada wavelet tradicional haya demostrado una conver-

gencia exitosa en un alto porcentaje de los entrenamientos es de gran relevancia. Indica que esta técnica de preprocesamiento no solo es efectiva para mejorar la capacidad de detección de la red neuronal convolucional, sino que también es robusta y confiable en términos de su desempeño en múltiples entrenamientos. Esto brinda mayor confianza en los resultados y fortalece la validez y utilidad de la aplicación de la transformada wavelet en el contexto de la detección de glaucoma.

Figura 22. Convergencia obtenida variando el tipo de entrada



Fuente: autor

La Figura 23 revela que la precisión obtenida no varía significativamente entre las diferentes entradas utilizadas. En este sentido, para estas mismas entradas la transformada wavelet tradicional muestra unos mayores valores de precisión con respecto a los obtenidos sin el uso de la transformada wavelet. Sin embargo, es importante destacar que al entrenar modelos se puede alcanzar una alta precisión en conjunto con una baja sensibilidad. Esto se debe a la dificultad de reconocer los casos en los que la evaluación se acerca a 0.6, lo cual tiende a generar variaciones en la sensibilidad y especificidad de los modelos.

La aplicación de la transformada wavelet a las imágenes de entrada desempeña

un papel fundamental en la mejora del rendimiento de la red neuronal convolucional (CNN) utilizada para la detección de glaucoma. Esta técnica de descomposición wavelet posibilita la captura eficiente de características y detalles esenciales presentes en las imágenes del fondo del ojo, lo cual se traduce en un enriquecimiento significativo de la información disponible para la CNN.

En el contexto de la red neuronal convolucional, la transformada wavelet contribuye a facilitar el proceso de aprendizaje al proporcionar una representación más completa y discriminativa de los datos de entrada. Al reducir la redundancia en la información, la descomposición wavelet permite a la CNN centrarse en aspectos específicos y relevantes para la detección de patrones asociados al glaucoma. Esto resulta en una convergencia más eficiente del modelo durante el entrenamiento.

La transformada wavelet tradicional ha demostrado aportar a la identificación de patrones característicos del glaucoma. Al resaltar detalles a diferentes escalas y direcciones, esta transformada facilita a la CNN la tarea de discernir entre imágenes normales y aquellas que presentan signos tempranos de la enfermedad. La capacidad de la transformada wavelet para proporcionar información enriquecida y relevante se refleja claramente en su contribución destacada a la mejora del desempeño de la CNN.

La precisión es un indicador que mide la concordancia entre las evaluaciones realizadas por el modelo y las realizadas por médicos especialistas en glaucoma. En el contexto de la detección de glaucoma, una alta precisión implica que el modelo tiene una buena capacidad para evaluar con precisión el avance del glaucoma en la escala del 0 al 1 utilizada por los médicos. No obstante, la sensibilidad también es de vital importancia.

La sensibilidad se refiere a la capacidad del modelo para detectar de manera efectiva los casos positivos de glaucoma, es decir, la proporción de casos positivos que son correctamente identificados como tales. Por otro lado, la especificidad se rela-

ciona con la capacidad del modelo para identificar correctamente los casos negativos de glaucoma, es decir, la proporción de casos negativos que son correctamente clasificados como negativos.


Es común que exista un equilibrio entre la sensibilidad y la especificidad, y que un aumento en la sensibilidad pueda llevar a una disminución en la especificidad, y viceversa. En el contexto del glaucoma, una alta sensibilidad es particularmente relevante, ya que implica que el modelo es capaz de detectar correctamente la enfermedad en la mayoría de los casos positivos. Esto es crucial para evitar falsos negativos, es decir, casos en los que la enfermedad está presente pero no es detectada.

La dificultad de reconocer los casos en los que la valoración se acerca al 0.6 puede influir en las variaciones en la sensibilidad y especificidad de los modelos. Es importante tener en cuenta que estos valores cercanos a 0.6 pueden representar casos ambiguos o borderline, donde el modelo puede tener dificultades para tomar una decisión clara. En tales situaciones, es posible que se produzcan variaciones en la sensibilidad y especificidad, lo que puede afectar la interpretación de los resultados y la capacidad de detección del modelo.

A modo de comparación, se presentan las mejoras logradas en relación con trabajo anterior realizado durante la etapa de trabajo previo. Dicho trabajo también se enfocó en la detección de glaucoma, sin embargo, los resultados obtenidos en este estudio actual superan significativamente tanto la sensibilidad, ver Figura 25, como la precisión, ver Figura 24.

Estos resultados representan un avance sustancial en el campo de la detección de glaucoma, demostrando el impacto positivo de las nuevas técnicas y enfoques implementados en este estudio. La mejora en la sensibilidad implica una mayor capacidad del modelo para identificar correctamente los casos positivos de glaucoma, reduciendo así los falsos negativos. Por otro lado, la mejora en la precisión indi-

Figura 23. Precisión máxima obtenida variando el tipo de entrada




Fuente: autor

ca una mayor concordancia entre las evaluaciones del modelo y las realizadas por expertos médicos en el diagnóstico de glaucoma.

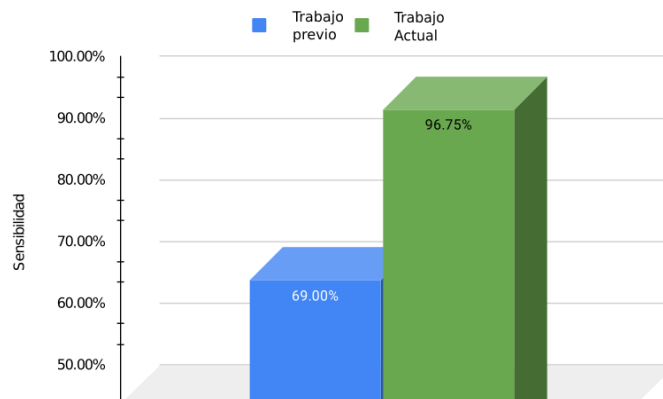
Estos hallazgos son de gran importancia, ya que contribuyen al desarrollo de herramientas más efectivas y confiables para la detección temprana y precisa del glaucoma. Además, destacan la relevancia de la investigación continua en el campo de la detección de enfermedades oculares, brindando oportunidades para mejorar la atención médica y reducir los riesgos asociados con el diagnóstico tardío o incorrecto del glaucoma.

Figura 24. Comparación de precisión con trabajo previo



Fuente: autor

Figura 25. Comparación de sensibilidad con trabajo previo



Fuente: autor

## 6. RECOMENDACIONES

La detección de glaucoma utilizando redes neuronales convolucionales (CNN) es una área de investigación prometedora que puede mejorar significativamente el diagnóstico temprano y preciso de esta enfermedad ocular. Sin embargo, durante el desarrollo de este trabajo de investigación, se han identificado diversas dificultades y desafíos que deben abordarse adecuadamente. A continuación, se presentan algunas recomendaciones para superar estas dificultades:

- Dado que la cantidad de imágenes requeridas para entrenar modelos de CNN es grande, es recomendable utilizar estrategias de selección de muestras representativas. En lugar de recopilar indiscriminadamente un gran volumen de imágenes, se puede emplear un enfoque selectivo para recopilar imágenes que abarquen una amplia gama de características y variaciones relevantes para el glaucoma. Además, se puede considerar la utilización de técnicas de aumento de datos, como la rotación, el recorte y el cambio de escala, para aumentar la diversidad y cantidad de imágenes disponibles para el entrenamiento de los modelos. Esto puede reducir la dependencia de una gran cantidad de datos originales etiquetados.
- Teniendo en cuenta que existen diferentes combinaciones de parámetros para las redes neuronales convolucionales y algoritmos de extracción de características, se recomienda llevar a cabo un estudio sistemático de los parámetros y algoritmos más relevantes para la detección de glaucoma. Se pueden utilizar técnicas de optimización automática, como la búsqueda en cuadrícula o la optimización bayesiana, para explorar eficientemente el espacio de parámetro. Además, es importante considerar la utilización de arquitecturas de redes preentrenadas, como VGG, ResNet o Inception, que han demostrado buen

rendimiento en tareas de clasificación de imágenes médicas. Estas arquitecturas preentrenadas pueden servir como punto de partida y acelerar el proceso de entrenamiento y convergencia.

- Con respecto a los datos, se puede considerar la colaboración con otros centros médicos y oftalmológicos para obtener conjuntos de datos adicionales y enriquecer la diversidad de la muestra. Esto puede mejorar la generalización de los modelos entrenados y su aplicabilidad a una población más amplia.
- Dada la importancia de la detección temprana de enfermedades como el glaucoma, se recomienda enfocarse en la mejora de la sensibilidad de los algoritmos de detección. Esto implica optimizar los modelos para minimizar los falsos negativos y maximizar la capacidad de identificar correctamente los casos positivos de glaucoma, incluso en sus etapas iniciales.

## 7. TRABAJO FUTURO

A pesar de los avances logrados en esta investigación al desarrollar una estrategia computacional para la detección de glaucoma utilizando el preprocesamiento con transformada wavelet, existen varias oportunidades para futuros trabajos que pueden mejorar aún más los resultados y ampliar el alcance de esta investigación. A continuación, se presentan algunas áreas de trabajo a considerar:

- Explorar el potencial de las Máquinas de Soporte Vectorial (SVM) en el proyecto. Las SVM, conocidas por su eficacia en problemas de clasificación, podrían ofrecer una alternativa robusta para mejorar la precisión del modelo utilizando las imágenes recopiladas. La evaluación comparativa de las SVM con los enfoques existentes, como las redes neuronales convolucionales, podría proporcionar información valiosa sobre las fortalezas y limitaciones de cada método, contribuyendo así a la mejora continua del proyecto.
- Evaluación de otros algoritmos de clasificación o regresión: Aunque se ha utilizado la transformada wavelet como estrategia de preprocesamiento, sería interesante evaluar la efectividad de otros algoritmos de clasificación o regresión después del preprocesamiento. Por ejemplo, se pueden explorar métodos basados en aprendizaje profundo, como redes neuronales convolucionales (CNN) más complejas o modelos de redes neuronales recurrentes (RNN) que puedan capturar mejor las características y patrones ocultos en las imágenes o series temporales asociadas al glaucoma. se pueden considerar algoritmos de clasificación no lineales, como las máquinas de soporte vectorial (SVM) o métodos de clasificación basados en agrupamiento.
- Propuesta de un modelo propio de red neuronal: en lugar de utilizar únicamente redes preentrenadas, se puede explorar la posibilidad de proponer y en-

trenar un modelo propio de CNN específicamente diseñado para la detección de glaucoma. Esto implica diseñar y ajustar la arquitectura de la red, así como entrenarla desde cero utilizando conjuntos de datos adecuados. Se puede realizar un análisis exhaustivo de las características específicas del glaucoma en las imágenes oftalmológicas y aprovechar ese conocimiento para diseñar una red que sea más sensible y precisa en la detección temprana y precisa de la enfermedad.

- Optimización y selección de características: aunque se ha utilizado la transformada wavelet como estrategia de preprocesamiento, se pueden investigar otras técnicas de extracción de características que sean más adecuadas para las imágenes oftalmológicas y el problema específico de detección de glaucoma. Esto incluye el uso de técnicas de aprendizaje profundo para extraer automáticamente las características más relevantes y discriminativas, se puede emplear técnicas de selección automática de características, como métodos de análisis de varianza (ANOVA), información mutua o técnicas basadas en la ganancia de información, para identificar las características más relevantes y reducir la dimensionalidad del problema.
- Evaluación en diferentes conjuntos de datos y validación externa: para validar y evaluar la efectividad del enfoque propuesto, se recomienda realizar pruebas en diferentes conjuntos de datos, preferiblemente de diferentes poblaciones o adquiridos en distintos centros médicos. Esto permitirá evaluar la robustez y generalización del modelo en diferentes escenarios y poblaciones, también, se sugiere realizar una validación externa mediante la colaboración con expertos y médicos oftalmólogos independientes para evaluar la efectividad del modelo propuesto en situaciones clínicas reales.
- La integración con sistemas de telemedicina: considerando la importancia de

la detección temprana del glaucoma y la creciente disponibilidad de sistemas de telemedicina, se puede investigar la integración del enfoque propuesto en un sistema de detección de glaucoma en línea. Esto permitirá el diagnóstico remoto y temprano de la enfermedad, mejorando el acceso a la atención oftalmológica en áreas remotas o con recursos limitados.

## 8. CONCLUSIONES

En conclusión, este trabajo de investigación ha abordado la detección de glaucoma mediante el uso de redes neuronales convolucionales (CNN) y algoritmos de extracción de características basados en la transformada wavelet. Se ha demostrado que la combinación de la transformada wavelet tradicional y la transformada wavelet scattering, en conjunto con el canal verde de las imágenes del fondo del ojo, permite obtener resultados prometedores en términos de precisión y sensibilidad.

La estrategia computacional desarrollada ha permitido superar la limitación de la cantidad de imágenes disponibles mediante la creación de una plataforma web para la recopilación de datos. Esta plataforma ha facilitado la colaboración con especialistas en glaucoma y ha enriquecido el banco de imágenes utilizado para entrenar los modelos de detección.

Se ha observado que las redes neuronales convolucionales han mostrado resultados más robustos en comparación con los algoritmos previos utilizados para la detección de glaucoma. Además, se ha demostrado que el uso de redes neuronales convolucionales preentrenadas, como ResNet18, ha mejorado aún más los resultados en términos de precisión cuando se utilizan algoritmos de extracción de características previamente al procesamiento de la imagen con la red neuronal.

Dado que el modelo es sometido a una evaluación exhaustiva mediante el empleo de un conjunto de pruebas, es fundamental destacar la importancia de esta práctica. El conjunto de datos de pruebas consiste en datos previamente no expuestos al modelo durante el proceso de entrenamiento, lo que asegura que el modelo se evalúe en datos completamente nuevos y no sesgados. Esta inclusión de datos no vistos previamente proporciona una evaluación más robusta de la capacidad predictiva del modelo en condiciones realistas y contribuye significativamente a la generalización de sus capacidades más allá de los datos de entrenamiento.

Además, para garantizar una evaluación aún más confiable del rendimiento del modelo, se utilizó validación cruzada. Esta técnica implica dividir el conjunto de datos en múltiples subconjuntos, donde el modelo se entrena repetidamente en diferentes combinaciones de estos subconjuntos. En cada iteración, un subconjunto se utiliza como conjunto de validación, mientras que los demás se utilizan como conjunto de entrenamiento. Esta práctica asegura que el modelo sea evaluado de manera exhaustiva en diferentes conjuntos de datos y evita el sesgo asociado con una sola división de los datos.

La razón fundamental detrás de la elección de no presentar resultados del conjunto de validación y, en cambio, centrarse únicamente en el conjunto de pruebas radica en la necesidad de una evaluación objetiva y generalizable del modelo. A medida que el modelo se entrena, también se ajusta a los datos de validación, lo que significa que se adapta específicamente a esos datos. Por lo tanto, los resultados obtenidos utilizando el conjunto de validación pueden ser engañosos y no representativos del rendimiento del modelo sobre datos nuevos e invisibles. Por otro lado, al informar los resultados solo con el conjunto de pruebas, se demuestra la capacidad del modelo para generalizar eficazmente sobre datos que no ha visto durante el entrenamiento ni durante la validación. Esto proporciona una evaluación más sólida del rendimiento real del modelo en situaciones del mundo real, donde se encuentran nuevas instancias que no estaban presentes durante el proceso de entrenamiento. La utilización de la transformada wavelet para extraer características ha mostrado ser una elección acertada, ya que ha permitido capturar patrones relevantes en las imágenes del fondo del ojo. En particular, se ha encontrado que el canal verde de las imágenes proporciona información crucial para la detección de glaucoma de manera precisa y confiable.

El uso de la transformada wavelet tradicional ha demostrado ser beneficioso al mejorar la convergencia de los modelos de redes neuronales convolucionales, lo cual

resulta en un entrenamiento más eficiente y rápido. Por otro lado, al emplear la transformada wavelet scattering, se ha logrado una mayor sensibilidad en la detección de casos de glaucoma. Un aspecto relevante es que al agregar rotaciones o deformaciones al conjunto de imágenes, la utilización de la transformada scattering brinda estabilidad y los resultados se mantienen con mejores valores en términos de sensibilidad. Esto demuestra el potencial de la transformada wavelet en el tratamiento de deformaciones y rotaciones, ya que permite obtener una representación robusta y precisa de las características relevantes en las imágenes del fondo del ojo. Estos hallazgos respaldan la utilidad y la eficacia de la transformada wavelet para mejorar la detección temprana y precisa del glaucoma, y sugieren que su combinación con técnicas de aprendizaje automático puede ser una estrategia prometedora en el campo de la oftalmología.

Estos resultados validan la importancia de combinar el poder de las redes neuronales convolucionales con técnicas de extracción de características como la transformada wavelet. La capacidad de las redes neuronales convolucionales para aprender y reconocer patrones complejos en las imágenes, en conjunto con la capacidad de la transformada wavelet para capturar detalles relevantes en diferentes escalas y direcciones, ha demostrado ser una combinación exitosa en la detección de glaucoma.

Es importante destacar que este enfoque computacional no solo tiene aplicaciones clínicas, sino que también puede ayudar a mejorar el acceso a la detección temprana de glaucoma en áreas con recursos limitados. Al utilizar técnicas computacionales, se puede superar la dependencia de la disponibilidad de especialistas en oftalmología, permitiendo un diagnóstico más rápido y preciso.

En conclusión, este trabajo de tesis ha demostrado que la detección de glaucoma utilizando redes neuronales convolucionales y la transformada wavelet es una estrategia prometedora y efectiva. Los resultados obtenidos respaldan la importancia

de este enfoque en la mejora del diagnóstico temprano y preciso de la enfermedad ocular. Además, se ha resaltado la relevancia del canal verde de las imágenes y la combinación de diferentes transformadas wavelet para obtener mejores resultados en términos de sensibilidad y convergencia de los modelos. Este estudio contribuye al avance de la investigación en el campo de la detección de glaucoma y sienta las bases para futuros desarrollos y aplicaciones clínicas.

## BIBLIOGRAFÍA

Ahmad M et al., SARHAN. *Brain tumor classification in magnetic resonance images using deep learning and wavelet transform*. Journal of Biomedical Science and Engineering. 2020, vol. 13, nro. 6, pp. 102 (vid. pág. 48).

Anna et al., WANG. *The application of wavelet transform to multi-modality medical image fusion*. 2006 IEEE International Conference on networking, sensing and control, nro. 6, pp. 270–274 (vid. págs. 35, 37).

Asahi et al., FUJITA. *Association between lifestyle habits and glaucoma incidence: a retrospective cohort study*. Eye. 2023, nro. 10, pp. 1-7 (vid. pág. 33).

AtalieC et al., THOMPSON. *A review of deep learning for screening, diagnosis, and detection of glaucoma progression*. The Association for Research in Vision and Ophthalmology. 2020, vol. 9, nro. 2, pp. 42–42 (vid. pág. 44).

BLIDNESS, THE INTERNATIONAL AGENCY FOR THE PREVENTION OF. *[Sitio web]. Glaucoma*. [Consulta: 03 de agosto 2019]. Disponible en:<https://www.iapb.org/knowledge/what-is-avoidable-blindness/glaucoma/>. (vid. pág. 15).

BLIDNESS., THE INTERNATIONAL AGENCY FOR THE PREVENTION OF. *[Sitio web]. Global Vision Impairment Facts*. [Consulta: 03 de agosto 2019]. Disponible en: <https://www.iapb.org/vision-2020/who-facts/>. (vid. pág. 14).

BLIDNESS, THE INTERNATIONAL AGENCY FOR THE PREVENTION OF. *[Sitio web]. Universal Eye Health - a vital component of health coverage*. [Consulta: 03

de agosto 2019]. Disponible en: <http://atlas.iapb.org/global-action-plan/universal-eye-health/>. (vid. pág. 15).

BUCAL DEL CÁNCER Y OTRAS., GRUPO DE GESTIÓN INTEGRADA DE LA SALUD CARDIOVASCULAR. *Lineamiento para la implementación de actividades de promoción de la salud visual, control de alteraciones visuales y discapacidad visual evitable (Estrategia VISIÓN 2020)*. [En línea]. Bogotá: Ministerio de salud y protección social. 2020. (Recuperado en 03 agosto 2019) Disponible en <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/RIDE/VS/PP/ENT/li-neamientos-salud-visual-2017.pdf> (vid. pág. 14).

CARRILLO, Juan. *CLASIFICACIÓN COMPUTARIZADA DE ENFERMEDADES OFTALMOLÓGICAS UTILIZANDO IMÁGENES DEL FONDO DEL OJO*. Tesis de grado para optar por el título de ingeniero de sistemas, Bucaramanga, Universidad Industrial de Santander 2019 (vid. pág. 19).

Christian et al., SZEGEDY. *Going deeper with convolutions*. Proceedings of the IEEE conference on computer vision and pattern recognition. 2015, pp. 1-9 (vid. pág. 42).

— *Rethinking the inception architecture for computer vision*. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016, pp. 2818–2826 (vid. pág. 42).

Coen et al., DEVENTE. *AIROGS: Artificial Intelligence for robust glaucoma screening challenge*. IEEE transactions on medical imaging. 2023 (vid. pág. 46).

- Daniel et al., BARROS. *Machine learning applied to retinal image processing for glaucoma detection: review and perspective*. Biomedical engineering online. 2020, vol. 19, pp. 1–21 (vid. pág. 43).
- Dar-Ren et al., CHEN. *Diagnosis of breast tumors with sonographic texture analysis using wavelet transform and neural networks*. Ultrasound in medicine & biology. 2002, vol. 28, nro. 10, pp. 1301-1310 (vid. pág. 20).
- Dengsheng, ZHANG. *Wavelet transform*. Fundamentals of Image Data Mining: Analysis, Features, Classification and Retrieval. 2019, pp. 35–44 (vid. pág. 60).
- E et al., GÓMEZ-LUNA. *Selección de una wavelet madre para el análisis frecuencial de señales eléctricas transitorias usando WPD*. Ingeniare. Revista chilena de ingeniería. 2013, vol. 21, nro. 2, pp. 262–270 (vid. pág. 35).
- GLAUCOMA, CENTRO DE PREVENCIÓN Y CONSULTORÍA EN. [En línea]. Bucaramanga: Fundación oftalmologica de santander-FOSCAL.2019 (recuperando en 1 diciembre 2019). Disponible en: <http://www.glaucomarueda.com/programas-de-prevencion.html>. (vid. pág. 18).
- Harry, QUIGLEY. *Open-angle glaucoma*. New England Journal of Medicine. 1993, vol. 328, nro. 15, pp. 1097–1106 (vid. pág. 31).
- Hayreh, SOHAN SINGH. *Optic disc changes in glaucoma*. The British journal of ophthalmology. 1972, vol. 56, nro. 3, pp. 175 (vid. pág. 30).
- Hedwig et al., KAISER. *Ocular blood flow: new insights into the pathogenesis of ocular diseases*. Karger Medical and Scientific Publishers. 1996 (vid. pág. 28).
- Ian et al., GOODFELLOW. *Deep learning*. MIT press. 2016 (vid. pág. 40).

Jerome, GILLES. *Empirical wavelet transform*. IEEE transactions on signal processing. 2013, vol. 61, nro. 16, pp. 3999–4010 (vid. pág. 48).

Jerome et al., GILLES. *2D empirical transforms. Wavelets, ridgelets, and curvelets revisited*. SIAM Journal on Imaging Sciences. 2014, vol. 7, nro. 1, pp. 157–186 (vid. pág. 48).

J.J. et al., ROMERO. *Matlab deep learning*. Inteligencia artificial y computación avanzada. 2007, vol. 13. (vid. pág. 39).

Joan, BRUNA y MALLAT Stéphane. *Invariant scattering convolution networks*. IEEE transactions on pattern analysis and machine intelligence. 2013, vol. 35, nro. 8, pp. 1872–1886 (vid. págs. 37, 48).

Jorge et al., VILLAMIZAR. *Mimetic finite difference methods for restoration of fundus images for automatic detection of glaucoma suspects*. Computer methods in biomechanics and biomedical engineering: imaging & visualization. 2022, vol. 10, nro. 5, pp. 492–499 (vid. pág. 47).

José Ignacio et al., ORLANDO. *Refuge challenge: A unified framework for evaluating automated methods for glaucoma assessment from fundus photographs*. Medical image analysis. 2020, vol. 59, pp. 101570 (vid. pág. 45).

Joseph A, RIZZOIII y WYATT John. *prospects for a visual prosthesis*. The Neuroscientist. 1997, vol. 3, nro. 4, pp. 251–262 (vid. pág. 28).

José Elías et al., DELGADO. *Análisis de Situación de Salud Visual en Colombia 2016*. [En línea]. Bogotá: Ministerio de salud y protección social. 2016. (Recuperado en 03 agosto 2019) Disponible en <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/asis-salud-visual-colombia-2016.pdf>. (vid. págs. 15, 16).

- Juan S et al., CARRILLO. *Glaucoma Detection using Fundus Images with Mimetic Anisotropic Filtering and Convolutional Neural Networks*. 2022 E-Health and Bioengineering Conference (EHB). 2022, pp. 01–04 (vid. pág. 47).
- Juan Sebastian et al., CARRILLO. *Glaucoma Detection Using Fundus Images of The Eye*. 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA). 2019, pp. 1-4. (vid. págs. 18, 43).
- Kaiming et al., HE. *Deep residual learning for image recognition*. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016, pp. 770–778 (vid. pág. 42).
- Kierstan, BOYD. *What Is Macular Degeneration?* [En línea]. Estados Unidos: AMERICAN ACADEMY OF OPHTHALMOLOGY OPHTHALMOLOGY. 2023. (Recuperado en 03 marzo 2023) Disponible en <https://www.aao.org/eye-health/diseases/amd-macular-degeneration> (vid. pág. 29).
- Lauren J et al., COAN. *Automatic detection of glaucoma via fundus imaging and artificial intelligence: A review*. Survey of ophthalmology. 2023, vol. 68, nro. 1, pp. 17–41 (vid. pág. 45).
- Mathieu et al., ANDREUX. *Kymatio: Scattering transforms in python*. The Journal of Machine Learning Research. 2020, vol. 21, nro. 1, pp. 2256–2261 (vid. pág. 60).
- Michael D et al., ABRÀMOFF. *Retinal imaging and image analysis*. IEEE reviews in biomedical engineering. 2010, vol. 3, pp. 169-208. (vid. pág. 17).
- Oliván et al., PÉREZ. *Utilidad de la oftalmoscopia láser de barrido en la detección de defectos en la capa de fibras nerviosas retinianas en pacientes con hipertensión*

- ocular*. Archivos de la Sociedad Española de Oftalmología. 2003, vol. 78, nro. 1, pp. 15–20 (vid. pág. 32).
- Patrick J, SAINE y TYLER Marshall E. *Ophthalmic photography: retinal photography, angiography, and electronic imaging*. Butterworth-Heinemann Boston. 2002, vol. 132. (vid. pág. 26).
- Paul S, ADDISON. *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. CRC press. 2017 (vid. págs. 35, 36).
- Phil, KIM. *Matlab deep learning*. With Machine Learning, Neural Networks and Artificial Intelligence. 2017, vol. 130. (vid. pág. 39).
- Rishab, GARGEYA y LENG Theodore. *Automated identification of diabetic retinopathy using deep learning*. Elsevier. 2017, vol.124, nro.7, pp. 962-969 (vid. pág. 18).
- SANTANDER, GOBERNACIÓN DE. *Secretaría de Salud Departamental lidera el programa 'Santander sin ceguera'*. [<http://www.santander.gov.co>]. Bucaramanga: gobernación de santander. [Consulta: 03 de agosto 2019]. Disponible en: <http://www.santander.gov.co/index.php/actualidad/item/3131-secretaria-de-salud-departamental-lidera-el-programa-santander-sin-ceguera>. (vid. pág. 18).
- Stephane G, MALLAT. *A theory for multiresolution signal decomposition: the wavelet representation*. IEEE transactions on pattern analysis and machine intelligence. 1989, vol. 11, nro. 7, pp. 674–693 (vid. pág. 35).
- Xiangyu et al., CHEN. *Glaucoma detection based on deep convolutional neural network*. 37th annual international conference of the IEEE engineering in medicine and biology society. 2015, pp. 715-718 (vid. pág. 43).

Yih-Chung et al., THAM. *Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis*. *Ophthalmology*. 2014, vol. 121, nro. 11, pp. 2081–2090 (vid. págs. 33, 34).

Zhuo et al., ZHANG. *Origa-light: An online retinal fundus image database for glaucoma analysis and research*. 2010 Annual international conference of the IEEE engineering in medicine and biology. 2010, pp. 3065–3068 (vid. pág. 77).