



**Universidad Nacional Mayor de San Marcos**

**Universidad del Perú. Decana de América**

**Facultad de Ingeniería de Sistemas e Informática**

**Escuela Profesional de Ingeniería de Software**

**Qhaway: una herramienta de apoyo para el  
diagnóstico del glaucoma con aprendizaje profundo**

**TESIS**

Para optar el Título Profesional de Ingeniero de Software

**AUTORES**

Nahum FLORES GUTIERREZ

José Carlos LA ROSA MENACHO

**ASESOR**

Dr. David Santos MAURICIO SÁNCHEZ

Lima, Perú

2022



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

## Referencia bibliográfica

---

Flores, N. & La Rosa, J. (2022). *Qhaway: una herramienta de apoyo para el diagnóstico del glaucoma con aprendizaje profundo*. [Tesis de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática, Escuela Profesional de Ingeniería de Software]. Repositorio institucional Cybertesis UNMSM.

---

## Metadatos complementarios

<b>Datos de autor 1</b>	
Nombres y apellidos	Nahum Flores Gutierrez
Tipo de documento de identidad	DNI
Número de documento de identidad	70071747
URL de ORCID	<a href="https://orcid.org/0000-0002-5807-4323">https://orcid.org/0000-0002-5807-4323</a>
<b>Datos de autor 2</b>	
Nombres y apellidos	José Carlos La Rosa Menacho
Tipo de documento de identidad	DNI
Número de documento de identidad	76554907
URL de ORCID	<a href="https://orcid.org/0000-0002-8824-4274">https://orcid.org/0000-0002-8824-4274</a>
<b>Datos de asesor</b>	
Nombres y apellidos	David Santos Mauricio Sanchez
Tipo de documento de identidad	DNI
Número de documento de identidad	06445495
URL de ORCID	<a href="https://orcid.org/0000-0001-9262-626X">https://orcid.org/0000-0001-9262-626X</a>
<b>Datos del jurado</b>	
<b>Presidente del jurado</b>	
Nombres y apellidos	Juan Gamarra Moreno
Tipo de documento	DNI
Número de documento de identidad	20039857
<b>Miembro del jurado 1</b>	
Nombres y apellidos	Jorge Leoncio Guerra Guerra

Tipo de documento	DNI
Número de documento de identidad	08473333
<b>Miembro del jurado 2</b>	
Nombres y apellidos	David Santos Mauricio Sanchez
Tipo de documento	DNI
Número de documento de identidad	06445495
<b>Datos de investigación</b>	
Línea de investigación	C.0.3.22
Grupo de investigación	No aplica
Agencia de financiamiento	Sin financiamiento
Ubicación geográfica de la investigación	Edificio: Universidad Nacional Mayor de San Marcos País: Perú Departamento: Lima Provincia: Lima Distrito: Lima Latitud: -12.0545901 Longitud: -77.0833251
Año o rango de años en que se realizó la investigación	2017 - 2021
URL de disciplinas OCDE	Ingeniería de sistemas y comunicaciones <a href="https://purl.org/pe-repo/ocde/ford#2.02.00">https://purl.org/pe-repo/ocde/ford#2.02.00</a>  Ciencias de la computación <a href="https://purl.org/pe-repo/ocde/ford#1.02.00">https://purl.org/pe-repo/ocde/ford#1.02.00</a>  Informática y Ciencias de la Información <a href="https://purl.org/pe-repo/ocde/ford#1.00.00">https://purl.org/pe-repo/ocde/ford#1.00.00</a>



# Universidad Nacional Mayor de San Marcos

Universidad del Perú, DECANA DE AMÉRICA

Facultad de Ingeniería de Sistemas e Informática

Escuela Profesional de Ingeniería de Software

## *Acta de Sustentación Virtual de Tesis*

Siendo las quince (15) horas del día 08 (ocho) del mes de noviembre de 2022, se reunieron en la sala virtual [meet.google.com/rcr-bdrj-kuf](https://meet.google.com/rcr-bdrj-kuf), presidido por el Mg. Juan Gamarra Moreno, el Mg. Jorge Leoncio Guerra Guerra (Miembro) y el Dr. David Santos Mauricio Sánchez (Miembro Asesor), para la sustentación virtual de la Tesis intitulada **“QHAWAY: UNA HERRAMIENTA DE APOYO PARA EL DIAGNÓSTICO DEL GLAUCOMA CON APRENDIZAJE PROFUNDO”**, por el Bachiller **Nahum Flores Gutierrez**, para optar el Título Profesional de Ingeniero de Software.

Acto seguido de la exposición de la Tesis, el presidente invitó al bachiller a dar respuesta a las preguntas establecidas por los miembros del jurado.

El bachiller en el curso de sus intervenciones demostró pleno dominio del tema, al responder con acierto y fluidez a las observaciones y preguntas formuladas por los señores miembros del jurado.

Finalmente, habiendo efectuado la calificación correspondiente por los miembros del jurado, el bachiller **Nahum Flores Gutierrez** obtuvo la nota de 18 (dieciocho).

A continuación, el presidente del jurado, Mg. Juan Gamarra Moreno, declara al bachiller **Ingeniero de Software**.

Siendo las 16:00 horas, se levantó la sesión.

Mg. Juan Gamarra Moreno  
Presidente

Mg. Jorge Leoncio Guerra Guerra  
Miembro

Dr. David Santos Mauricio Sánchez  
Miembro Asesor



# Universidad Nacional Mayor de San Marcos

Universidad del Perú, DECANA DE AMÉRICA

Facultad de Ingeniería de Sistemas e Informática

Escuela Profesional de Ingeniería de Software

## *Acta de Sustentación Virtual de Tesis*

Siendo las quince (15) horas del día 08 (ocho) del mes de noviembre de 2022, se reunieron en la sala virtual [meet.google.com/rcr-bdrj-kuf](https://meet.google.com/rcr-bdrj-kuf), presidido por el Mg. Juan Gamarra Moreno, el Mg. Jorge Leoncio Guerra Guerra (Miembro) y el Dr. David Santos Mauricio Sánchez (Miembro Asesor), para la sustentación virtual de la Tesis intitulada **“QHAWAY: UNA HERRAMIENTA DE APOYO PARA EL DIAGNÓSTICO DEL GLAUCOMA CON APRENDIZAJE PROFUNDO”**, por el Bachiller **José Carlos La Rosa Menacho**, para optar el Título Profesional de Ingeniero de Software.

Acto seguido de la exposición de la Tesis, el presidente invitó al bachiller a dar respuesta a las preguntas establecidas por los miembros del jurado.

El bachiller en el curso de sus intervenciones demostró pleno dominio del tema, al responder con acierto y fluidez a las observaciones y preguntas formuladas por los señores miembros del jurado.

Finalmente, habiendo efectuado la calificación correspondiente por los miembros del jurado, el bachiller **José Carlos La Rosa Menacho** obtuvo la nota de 18 (dieciocho).

A continuación, el presidente del jurado, Mg. Juan Gamarra Moreno, declara al bachiller **Ingeniero de Software**.

Siendo las 16:00 horas, se levantó la sesión.

Mg. Juan Gamarra Moreno  
Presidente

Mg. Jorge Leoncio Guerra Guerra  
Miembro

Dr. David Santos Mauricio Sánchez  
Miembro Asesor



**Universidad Nacional Mayor de San Marcos**  
Universidad del Perú. Decana de América  
**Facultad de Ingeniería de Sistemas e Informática**  
**Escuela Profesional de Ingeniería Software**

**INFORME DE EVALUACIÓN DE ORIGINALIDAD**  
**N° 014-EPISW-FISI-2022**

1. <i>Autoridad Académica que emite el Informe de Originalidad:</i>	<i>Directora de la Escuela Profesional de Ingeniería de Software</i>
2. <i>Apellidos y Nombres de la autoridad académica:</i>	<i>Dra. Nora Bertha La Serna Palomino</i>
3. <i>Operador del programa informático de similitudes:</i>	<i>Dra. Nora Bertha La Serna Palomino</i>
3. <i>Documento evaluado:</i>	<i>Tesis para Pregrado Título: “<b>Qhaway: Una herramienta de apoyo para el Diagnóstico del glaucoma con aprendizaje profundo</b>”</i>
5. <i>Autores del documento:</i>	<i>- Flores Gutierrez Nahum - La Rosa Menacho José Carlos</i>
6. <i>Fecha de recepción de documento</i>	<i>Recepción: 01/08/2022</i>
7. <i>Fecha de aplicación del programa detector de similitudes:</i>	<i>Revisión: 07/08/2022</i>
8. <i>Software utilizado:</i>	<i>Turnitin</i>
9. <i>Configuración del programa detector de similitudes:</i>	<i>Excluye textos entrecomillados: Sí Excluye biografías: Sí Excluye cadenas menores a 40 palabras: Sí Otro criterio (especificar): No</i>
10. <i>Porcentaje de similitudes según programa detector de similitudes</i>	<i>Ocho por ciento (8%)</i>
11. <i>Fuentes originales de las similitudes encontradas</i>	<i>Se adjuntan en 02 (dos) fojas al presente informe</i>
12. <i>Observaciones:</i>	<i>Ninguna</i>
13. <i>Calificación de originalidad</i> <i>i. Documento cumple criterios de originalidad, sin observaciones</i> <i>ii. Documento cumple criterios de originalidad, con observaciones</i> <i>iii. Documento no cumple criterios de originalidad.</i>	<i>Documento cumple criterio de originalidad, sin observación</i>
14. <i>Fecha del Informe:</i>	<i>08/11/2022</i>

**Dra. Nora Bertha La Serna Palomino**  
*Directora (e) de la EPISW*



Queremos dedicar este trabajo a nuestros padres por su apoyo incondicional, y por ser nuestro motivo para seguir creciendo como profesionales.

## **AGRADECIMIENTOS**

Al profesor Dr. David Mauricio Sánchez, por su apoyo, orientación, esfuerzo y consejos desinteresados, gracias a todo ello fue posible culminar este trabajo de investigación y cumplir con los objetivos trazados.

A la Universidad Nacional Mayor de San Marcos y a la Facultad de Ingeniería de Sistemas e Informática, por habernos permitido realizar y concluir nuestros estudios superiores.

A cada uno de los profesores en el pregrado, quienes ciclo a ciclo nos inculcaron no solo conocimientos académicos, sino la perseverancia, el poder superarnos como persona, gracias por habernos guiado en nuestro desarrollo profesional.

A nuestras familias, por su gran apoyo incondicional, por transmitirnos su fortaleza y perseverancia.

A nuestros amigos que conocimos en la etapa de pregrado, quienes nos demostraron que, con mucha paciencia, perseverancia y trazándose un objetivo, es posible hacer realidad todo lo que uno se proponga, gracias a ellos porque indirectamente nos ayudaron a culminar este trabajo.

# Qhaway: Una herramienta de apoyo para el Diagnóstico del glaucoma con aprendizaje profundo

## RESUMEN

El glaucoma es una enfermedad neurodegenerativa irreversible que afecta al nervio óptico y puede causar una pérdida de visión parcial o completa. La detección temprana y precisa puede prevenir la pérdida de visión, por ello, surge la necesidad de desarrollar alternativas para su diagnóstico con alta precisión, siendo una promisoría el deep learning (DL). En este estudio, se propone un método para el diagnóstico del glaucoma basado en un modelo híbrido de modelos DL, con el cual usando imágenes del fondo de ojo de un paciente se consigue hacer el diagnóstico con alta precisión. Se consideró la integración de los dataset públicos de glaucoma HRF, Drishti-GS1, sjchoi86-HRF, RIM-ONE y ACRIMA, con un total de 1707 imágenes (919 normal y 788 glaucoma) del fondo de ojo, un modelo híbrido de Voting sobre los modelos de DL ResNet50 con dos tipos de fine tuning y ResNet50V2, y la implementación usando Keras y Tensor Flow, con lo que se consiguió un diagnóstico con exactitud del 96.55%, sensibilidad del 98.54% y especificidad del 94.32%. Además, los experimentos numéricos muestran que el aprendizaje usando 5 bases de datos permite mejores resultados que por separado, incluso aplicando transfer learning, también muestran que el modelo híbrido voting genera una exactitud superior en 20.69% a la mejor exactitud obtenido por el mejor modelo de DL (DenseNet169) usando un dataset, 13.22% al mejor modelo (ResNet50V2) usando transfer learning con los 5 datasets, y 1.72% al mejor modelo (ResNet50) considerando los 5 dataset.

**Keywords:** Inteligencia Artificial, Aprendizaje Profundo, Fine-tuning, Diagnóstico del glaucoma, Imagen del fondo de ojo.

# Qhaway: Support Tool for Deep Learning Glaucoma

## Diagnosis

### ABSTRACT

Glaucoma is an irreversible neurodegenerative disease that targets the optic nerve and can cause partial or complete loss of vision. An early and accurate detection can prevent blindness; therefore, it's necessary to develop high precision alternatives for its diagnosis, being deep learning (DL) a promising one. In this study, considering the incorporation of the public glaucoma datasets HRF, Drishti-GS1, sjchoi86-HRF, RIM-ONE and ACRIMA, with a total of 1707 images of the fundus (919 normal and 788 glaucoma), a hybrid Voting model based on DL ResNet50 models with two types of fine-tuning, and ResNet50V2 implemented using Keras and TensorFlow, it was possible to achieve a diagnosis with 96.55% accuracy, 98.54% sensitivity and 94.32% specificity. Moreover, the numerical experiments showed that the learning process using 5 databases delivers better results than working with each one separately. Even applying transfer learning, it is shown that the hybrid voting model generates a superior accuracy by 20.69% compared to the highest accuracy obtained by the best model of DL (DenseNet169) using a dataset, 13.22% to the best model (ResNet50V2) using transfer learning with the 5 datasets, and 1.72% to the best model (ResNet50) considering the 5 datasets.

**Keywords:** Artificial Intelligence, Deep Learning, Fine-tuning, glaucoma diagnosis, fundus eye image.

## Lista de Figuras

Figura 1.1. Esquema general de la propuesta.....	17
Figura 1.2. Estructura y secuencia de la tesis .....	18
Figura 3.1. Proceso de revisión de la literatura.....	28
Figura 4.1. Proceso de ML para el diagnóstico del glaucoma .....	40
Figura 4.2. Esquema general de una CNN.....	41
Figura 4.3. Modelos de DL propuesto .....	42
Figura 4.4. Imágenes del fondo de ojo etiquetadas: (a) normal, (b) glaucoma.....	42
Figura 4.5. Ejemplos de pre-procesamiento: (a) Imagen original, (b) CLAHE, (c) Filtro gaussiano, (d) Filtro de la mediana .....	43
Figura 4.6. Proceso de transferencia de aprendizaje y ajuste fino para un modelo de DL .....	44
Figura 4.7. Esquema general de los modelos de DL seleccionados: (a) primer tipo de fine tuning, (b) segundo tipo de fine tuning.....	45
Figura 4.8. Modelos de DL: (a) Alex-Net, (b) VGG16, (c) InceptionV3, (d) ResNet50.....	46
Figura 4.9. Esquema de criterio de votación.....	48
Figura 5.1. Diagrama de la arquitectura de la herramienta web .....	52
Figura 5.2. Diagrama Entidad-Relación de la herramienta de apoyo para el diagnóstico del glaucoma....	53
Figura 5.3. Estructura de una carpeta media en el servidor de la herramienta.....	53
Figura 5.4. Interfaz para el diagnóstico del glaucoma .....	54
Figura 5.5. Interfaz para crear, modificar y eliminar registros en el sistema.....	55
Figura 5.6. Interfaz de resultado del diagnóstico .....	56
Figura 5.7. Diagrama de componentes de servicios de la herramienta .....	59
Figura 5.8. Tareas del tablero Kanban .....	65
Figura 6.1. Esquema de entrenamiento del generador de modelos.....	70
Figura 6.2. Esquema de entrenamiento del generador de modelos.....	71
Figura 6.3. Esquema de validación cruzada de 10 folds .....	72
Figura 6.4. Comparación de resultados del test de HRF.....	79
Figura 6.5. Resultados de test del tercer escenario para los modelos entrenados con HRF.....	80
Figura 6.6. Comparación de resultados del test de Drishti .....	82
Figura 6.7. Resultados de test del tercer escenario de los modelos entrenados con Drishti .....	83
Figura 6.8. Comparación de resultados del test de Sjchoi86-HRF .....	85
Figura 6.9. Resultados de test del tercer escenario de los modelos entrenados con Sjchoi86-HRF .....	86
Figura 6.10. Comparación de resultados del test de RIM ONE.....	88
Figura 6.11. Resultados de test del tercer escenario de los modelos entrenados con RIM ONE.....	89
Figura 6.12. Comportamiento de los resultados del Test de los modelos usando ACRIMA (primer escenario).....	91
Figura 6.13. Comportamiento de los resultados del Test de todos los dataset para los modelos entrenado con ACRIMA (primer escenario) .....	92
Figura 6.14. Resultados de test del tercer escenario de los modelos entrenados con el data set definido en el segundo escenario .....	94
Figura 6.15. Resultados de test del tercer escenario de los modelos entrenados con el data set definido en el segundo escenario .....	95
Figura 6.16. Comparación de los resultados (acc) de los modelos para los 3 escenarios con el data set de test del tercer escenario.....	96

## Lista de Tablas

Tabla 3.1. Cadenas de búsqueda utilizadas en las fuentes .....	26
Tabla 3.2. Criterios de inclusión y exclusión.....	27
Tabla 3.3. Cantidad de documentos por motor de búsqueda .....	28
Tabla 3.4. Documentos seleccionados para el estudio.....	31
Tabla 3.5. Herramientas web o móvil que diagnostican el glaucoma.....	32
Tabla 3.6. Métodos de preprocesamiento encontradas en la literatura .....	33
Tabla 3.7. Métodos de extracción de características encontradas en la literatura.....	35
Tabla 3.8. Métodos de selección de características encontradas en la literatura .....	35
Tabla 3.9. Métodos de clasificación encontrados en la literatura .....	36
Tabla 3.10. Dispositivos que capturan una imagen del fondo de ojo encontrados en la literatura .....	37
Tabla 3.11. Modelos de aprendizaje profundo entrenados para clasificar el glaucoma a partir de imágenes del fondo de ojo encontrados en la literatura .....	38
Tabla 4.1. Modelos de aprendizaje profundo entrenados para clasificar el glaucoma a partir de imágenes del fondo de ojo encontrados en la literatura.....	47
Tabla 4.2. Tamaño de imágenes de entrada para cada modelo.....	47
Tabla 5.1. Requerimientos funcionales del sistema.....	58
Tabla 5.2. Requerimientos no funcionales del sistema.....	59
Tabla 6.1. Data sets encontrados en la literatura.....	73
Tabla 6.2. Información de origen de cada conjunto de datos.....	73
Tabla 6.3. Tabla de división de datos para cada escenario .....	74
Tabla 6.4. Instancias para el entrenamiento, validación y pruebas .....	74
Tabla 6.5. Experimentos definidos en para el primer escenario .....	76
Tabla 6.6. Experimentos definidos en para el segundo escenario.....	76
Tabla 6.7. Experimentos definidos en para el tercer escenario.....	77
Tabla 6.8. Resultados del test del primer escenario de los modelos entrenados con HRF .....	78
Tabla 6.9. Resultados del test del tercer escenario de los modelos entrenados con HRF.....	80
Tabla 6.10. Resultados del test del primer escenario de los modelos entrenados con Drishti .....	81
Tabla 6.11. Resultados del test del tercer escenario de los modelos entrenados con Drishti.....	83
Tabla 6.12. Resultados del test del primer escenario de los modelos entrenados con Sjchoi86-HRF.....	84
Tabla 6.13. Resultados del test del tercer escenario de los modelos entrenados con Sjchoi86-HRF .....	86
Tabla 6.14. Resultados del test del primer escenario de los modelos entrenados con RIM ONE .....	87
Tabla 6.15. Resultados del test del tercer escenario de los modelos entrenados con Sjchoi86-HRF .....	89
Tabla 6.16. Resultados del test de los modelos usando ACRIMA (primer escenario) .....	90
Tabla 6.17. Resultados del Test de todos los dataset para los modelos entrenado con ACRIMA (primer escenario).....	92
Tabla 6.18. Resultados del test de los modelos entrenados con el data set del segundo escenario .....	93
Tabla 6.19. Resultados del test de los modelos entrenados con el data set del tercer escenario.....	95

## TABLA DE CONTENIDOS

CAPÍTULO 1: INTRODUCCIÓN .....	12
1.1. Antecedentes .....	12
1.2. Problema .....	14
1.3. Importancia .....	14
1.4. Motivación .....	15
1.5. Objetivos .....	16
1.5.1. Objetivo general .....	16
1.5.2. Objetivos específicos .....	16
1.6. Propuesta .....	16
1.7. Organización .....	17
CAPÍTULO 2: MARCO TEÓRICO .....	19
2.1. Anatomía del fondo de ojo .....	19
2.2. Enfermedades de los ojos .....	20
2.3. Algoritmos supervisados .....	21
2.4. Algoritmos no supervisados .....	23
CAPÍTULO 3: ESTADO DEL ARTE .....	25
3.1. Metodología de la investigación .....	25
3.2. Planificación de la revisión .....	25
3.3. Realización de la revisión .....	27
3.3.1. Documentos seleccionados .....	29
3.4. Análisis .....	31
3.4.1. ¿Qué aplicaciones móviles o web que diagnostiquen el glaucoma existen? .....	32
3.4.2. ¿Qué técnicas de preprocesamiento para una imagen del fondo de ojo existen? .....	32
3.4.3. ¿Qué técnicas para la extracción de características son utilizadas? .....	33
3.4.4. ¿Qué técnicas para la selección de características son utilizadas? .....	35
3.4.5. ¿Qué modelos de clasificación basado en machine learning existen para el diagnóstico del glaucoma a partir de imágenes del fondo de ojo? .....	36
3.4.6. ¿Qué dispositivos son utilizados para tomar una foto del fondo de ojo? .....	36
3.4.7. ¿Qué modelos de clasificación basado en aprendizaje profundo existen para el diagnóstico del glaucoma a partir de imágenes del fondo de ojo? .....	37
CAPÍTULO 4: MODELO DE APRENDIZAJE PROFUNDO PARA EL DIAGNÓSTICO DEL GLAUCOMA .....	39
4.1. Justificación del modelo .....	39
4.2. Modelo de aprendizaje profundo propuesto .....	41
4.2.1. Data Set .....	42
4.2.2. Preprocesamiento .....	43
4.2.3. Generador de modelo .....	44
4.2.4. Modelos de DL .....	46
4.2.5. Diagnosticador .....	48
4.2.6. Interpretación y evaluación .....	48
CAPÍTULO 5: DESARROLLO DE LA HERRAMIENTA DE APOYO PARA EL DIAGNÓSTICO DEL GLAUCOMA .....	50
5.1. Descripción de la herramienta .....	50
5.2. Arquitectura de la herramienta .....	51
5.3. Estructura de datos .....	52
5.4. Modelado de la herramienta .....	54
5.4.1. Requerimientos funcionales .....	57
5.4.2. Requerimientos no funcionales .....	58

5.4.3.	Lista de servicios.....	59
5.5.	Implementación.....	64
5.5.1.	Metodología de desarrollo .....	64
5.5.2.	Lenguajes de programación .....	65
5.6.	Requisitos para el uso de la herramienta.....	66
5.6.1.	Requisitos mínimos a nivel de hardware .....	66
5.6.2.	Requisitos mínimos a nivel de software.....	67
5.6.3.	Requisitos mínimos a imágenes de fondo de ojo .....	68
<b>CAPÍTULO 6: ENTRENAMIENTO Y VALIDACIÓN DEL MODELO DE APRENDIZAJE PROFUNDO PARA EL DIAGNÓSTICO DEL GLAUCOMA .....</b>		<b>69</b>
6.1.	Diseño de validación.....	69
6.2.	Ambiente de entrenamiento y validación.....	72
6.2.1.	Ambiente de entrenamiento .....	72
6.2.2.	Ambiente de validación .....	72
6.3.	Instancias de pruebas .....	73
6.3.1.	Preparación de datos .....	74
6.3.2.	Instancias de pruebas para el entrenamiento, validación y pruebas .....	74
6.4.	Métricas.....	75
6.5.	Entrenamiento de los modelos de aprendizaje profundo .....	75
6.5.1.	Definir configuración de experimentos.....	75
6.5.2.	Ejecutar experimento .....	77
6.6.	Resultados.....	78
6.6.1.	Escenario 1.....	78
6.6.2.	Escenario 2.....	93
6.6.3.	Escenario 3.....	94
<b>CAPÍTULO 7: CONCLUSIONES Y TRABAJOS FUTUROS .....</b>		<b>97</b>
7.1.	Conclusiones.....	97
7.1.1.	Conclusión general.....	97
7.1.2.	Conclusiones específicas.....	97
7.2.	Limitaciones.....	98
7.3.	Trabajos futuros .....	98
<b>ANEXO A: Manual de usuario de la herramienta de apoyo.....</b>		<b>106</b>
1.	Descripción del Sistema.....	107
1.1.	Introducción .....	107
1.2.	Objeto.....	107
2.	Estructura General del Sistema.....	107
2.1.	Componentes de la interfaz de usuario .....	107
3.	Operatividad general .....	108
3.1.	Pantalla de inicio de sesión .....	108
3.2.	Pantalla de herramientas .....	110
3.2.1.	Buscar paciente .....	111
3.2.2.	Tomar/Cargar imagen .....	112
3.2.3.	Diagnóstico .....	113
3.2.4.	Mis pacientes .....	114
3.2.5.	Últimos diagnósticos.....	115
3.3.	Vista de paciente .....	116
3.4.	Barra lateral.....	117
3.5.	Mi perfil .....	118
4.	Accesos .....	119



# CAPÍTULO 1: INTRODUCCIÓN

## 1.1. Antecedentes

El glaucoma es una neuropatía crónica y progresiva que afecta al nervio óptico, lo que ocasiona en una pérdida gradual e irreversible de la visión, además, es la segunda causa de ceguera en el mundo (Glaucoma Research Foundation, 2013; World Health Organization, 2020). La academia Americana de Oftalmología proyecta 111 millones de casos en el 2040 (Tham et al., 2014). Intervenciones como la medicación o la cirugía pueden marcar una gran diferencia en la calidad de vida y retrasar el proceso de progresión de la enfermedad, pero rara vez cambian el pronóstico a largo plazo (Díaz, 2010). El diagnóstico temprano y oportuno de estos cambios puede prevenir la ceguera, ya que el glaucoma se puede tratar en las etapas iniciales (Bua & Supuran, 2019).

El glaucoma se puede distinguir en dos tipos, el Glaucoma primario de ángulo abierto (GPAA) y el Glaucoma de ángulo cerrado (GAC). El primero es el más frecuente y reduce de forma gradual la visión periférica sin síntomas, y para cuando los síntomas son visibles, ya habrá ocurrido daño permanente; la destrucción causada por la GPAA puede progresar hasta desarrollar la llamada “visión túnel”, en la cual solo se podrá ver lo que se encuentre directamente delante del sujeto (Castañeda-Díez et al., 2014). El segundo es mucho menos frecuente, produce síntomas repentinos de dolor en el ojo, cefaleas, halos rodeando las luces, dilatación de las pupilas, pérdida de visión, ojos rojos, náuseas y vómitos (Castañeda-Díez et al., 2014). Por otro lado, el ataque de GAC puede durar algunas horas, y luego volver a suceder, o puede ser continuo o no dar descanso; en cada ataque puede provocar de forma progresiva mayor pérdida de visión (Rieger-Reyes & Rubio-Galán, 2013).

Entre los métodos tradicionales para el diagnóstico, se tiene a la tonometría, que consiste en medir la presión interior del ojo (PIO), el intervalo de presión normal está en el rango de 12 a 22 mm Hg la mayoría de los casos se diagnostican con una presión que supera los 22 mm Hg; sin embargo, algunas personas pueden tener glaucoma dentro del rango normal (Glaucoma Research Foundation, 2020; Luna et al., 2009). La oftalmoscopia es un procedimiento que ayuda al médico a examinar su nervio óptico para detectar los daños a causa del glaucoma mediante la observación de la forma y el color del nervio óptico (Belduma & Valarezo, 2019). La perimetría es una prueba del campo visual que genera un mapa de la totalidad de su campo visual, esta prueba ayudará al médico a determinar si el glaucoma ha afectado su vista (Glaucoma Research Foundation, 2020), por otro lado, la paquimetría es una prueba simple que mide el espesor de la córnea (la ventana transparente que se encuentra en la parte frontal del ojo), este método puede ayudar al diagnóstico, ya que existe la posibilidad de que el espesor de la córnea influya en las lecturas de presión ocular (PIO) (Sánchez-Tocino et al., 2007). Los métodos de diagnóstico mencionados, generalmente, son métodos complementarios para el diagnóstico del glaucoma.

En contraste con los métodos tradicionales, a la fecha, se han desarrollado dos herramientas: una móvil, Yanbao (Guo et al., 2018), y otra web, Glaucoma Detection Tool (Soorya et al., 2019), con el fin de dar un diagnóstico automatizado del glaucoma a partir del fondo del ojo. Ambos sistemas, haciendo uso técnicas de aprendizaje automático y aprendizaje profundo, respectivamente, proponen una herramienta que sirva como apoyo a los oftalmólogos haciendo uso de fotos del fondo de ojo de alta calidad tomadas por una oftalmoscopia directa. Los algoritmos aplicados en ambos sistemas lograron obtener un buen rendimiento en el diagnóstico del glaucoma, sin embargo, estos son muy mejorables.

## **1.2. Problema**

El problema de la presente tesis es proveer una Herramienta de software para el diagnóstico automatizado que tenga un bajo costo y alta precisión del glaucoma a partir de una imagen del fondo de ojo, para los oftalmólogos que no tengan al alcance aparatos especializados para la visualización del fondo del ojo, por lo que se propone la siguiente interrogante: “¿Cómo diagnosticar el glaucoma con un bajo costo y una alta precisión a partir de una imagen del fondo de ojo?”.

## **1.3. Importancia**

El glaucoma es una de las razones principales por las que se desarrolla la discapacidad sensorial de la vista (la pérdida de la vista puede ser parcial o total). Cerca del 10% de la población con glaucoma que reciben tratamiento pierden la vista de todos modos (Yin et al., 2012). No existe grupo etario que no pueda desarrollar el glaucoma, ya que puede afectar desde bebés (1 de cada 10.000 en Estados Unidos) hasta adultos y, esencialmente, a las personas de edad avanzada, ya que son el grupo con mayor riesgo de desarrollar glaucoma.(Glaucoma Research Foundation, 2013). En el caso del GPAA, que es la más frecuente, prácticamente, no existen síntomas detectables (no existe dolor asociado al incremento de la PIO), hasta que inicia la pérdida de la gradual de la visión (Mantravadi & Vadhar, 2015; P. Schacknow & Samples, 2010).

Debido a la pérdida gradual de la visión, es muy probable que inconscientemente se compense moviendo la cabeza, y esto retrasa el diagnóstico hasta que se tenga una pérdida significativa (Moreano, 2019). Por ello, es muy importante proteger la vista realizándose un examen oftalmológico, y, en caso se diagnostique glaucoma, iniciar el tratamiento de inmediato.

El glaucoma es incurable e irreversible. Con medicación y/o cirugía, se puede detener la pérdida la pérdida adicional de la visión, sin embargo, los controles deberán ser de por vida. Por ello, el diagnóstico rápido es el primer paso para conservar la visión (Glaucoma Research Foundation, 2013). En América Latina, los estudios realizados (Lossio, 2021) estiman que el 20% de las personas ciegas son ciegas por glaucoma y el 70 % de ellas se encuentran en situación de pobreza y pobreza extrema (Marshall et al., 2018). La Estrategia Nacional de Salud para la Salud Ocular y la Prevención de la Ceguera, en Perú, muestran una alarmante prevalencia de glaucoma. Para el 2022 se prevé que más de 5 millones de personas quedarán ciegas bilateralmente debido al glaucoma primario de ángulo abierto (Crisol-Deza, 2022). Esto sumado a la precariedad del sistema de salud público evidenciado desde el inicio de la pandemia (Lossio, 2021), inclusive, se ha reportado, por parte de directivos de la salud pública, la falta de médicos especializados y una evidente escasez de recursos humanos (Espinoza-Portilla et al., 2020).

#### **1.4. Motivación**

Este trabajo ha sido motivado por una razón principal: proveer de una Herramienta de software que pueda aprender automáticamente a identificar pacientes con o sin glaucoma, a partir una imagen del fondo de ojo, puesto que el glaucoma es una enfermedad silenciosa y difícil de identificar sin los aparatos médicos adecuados. Actualmente, estos aparatos médicos tienen un alto precio en el mercado, siendo sus precios los motivos por el que existe la dificultad para diagnosticar el glaucoma en zonas rurales, donde existe un factor económico limitante, además de la falta de médicos especializados.

## **1.5. Objetivos**

### **1.5.1. Objetivo general**

Desarrollar una herramienta de apoyo de bajo costo y alta precisión para el diagnóstico del glaucoma, a partir de una imagen del fondo de ojo.

### **1.5.2. Objetivos específicos**

Los objetivos específicos de esta tesis son los siguientes:

- (a) Diseñar e implementar un modelo de aprendizaje profundo que permita identificar el glaucoma a través de una imagen del fondo de ojo.
- (b) Implementar una herramienta de apoyo al diagnóstico del glaucoma para centros médicos en la ciudad como en el medio rural.
- (c) Realizar pruebas numéricas que permitan validar la exactitud del modelo propuesto.

## **1.6. Propuesta**

Se propone el desarrollo de una herramienta de apoyo para el diagnóstico, el cual se basa en técnicas automatizadas de aprendizaje profundo, que deberá ser capaz de identificar los casos cuyos pacientes tengan glaucoma o no a partir de imágenes del fondo de ojo que sean tomadas por

una máquina especializada o por un teléfono inteligente. El esquema de la herramienta planteada se presenta en la Figura 1.1.

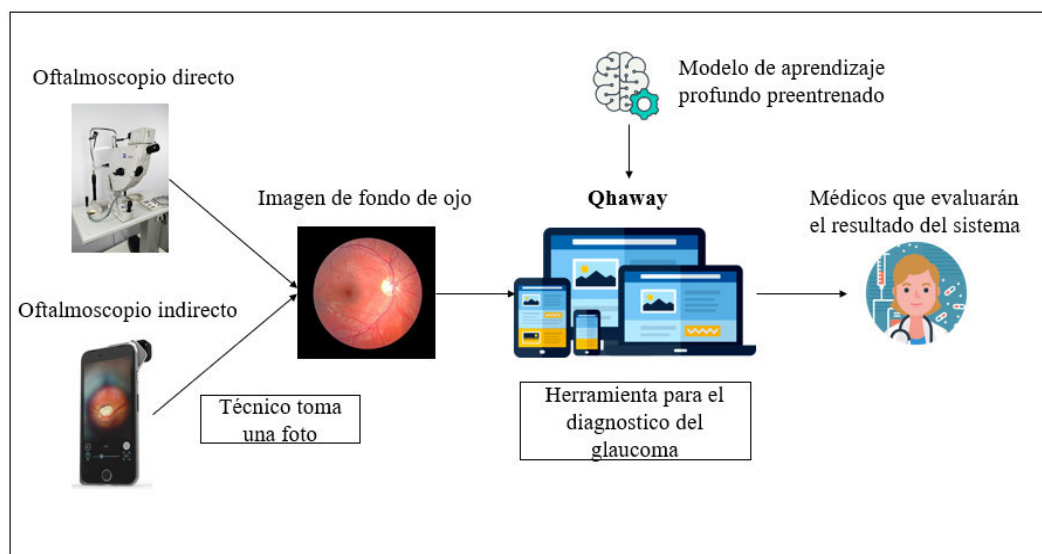


Figura 1.1. Esquema general de la propuesta

Fuente: Elaboración propia.

## 1.7. Organización

Esta tesis está organizada en 7 capítulos, los cuales se mencionan a continuación:

En el capítulo 2, se presentan los conceptos fundamentales del Machine Learning para una mejor comprensión de esta tesis.

En el capítulo 3, se realiza una revisión exhaustiva del estado del arte de los trabajos relacionados con el diagnóstico del glaucoma mediante Machine Learning y Deep Learning.

En el capítulo 4, se introduce y desarrolla los modelos de aprendizaje profundo para el diagnóstico del glaucoma mediante una comparación de 24 modelos y 5 modelos híbridos.

En el capítulo 5, se explica, de forma detallada, el proceso de desarrollo la herramienta que permite el diagnóstico del glaucoma mediante un aplicativo multiplataforma.

En el capítulo 6, se ejecuta el entrenamiento de los modelos de Deep Learnig que fueron propuestos en esta tesis. Además, se realiza la validación de los resultados del entrenamiento, con el objetivo de encontrar el escenario y modelo con el mejor rendimiento.

En el capítulo 7, se preparan las conclusiones de esta tesis, así como también los trabajos futuros que abre esta investigación (ver Figura 1.2.).

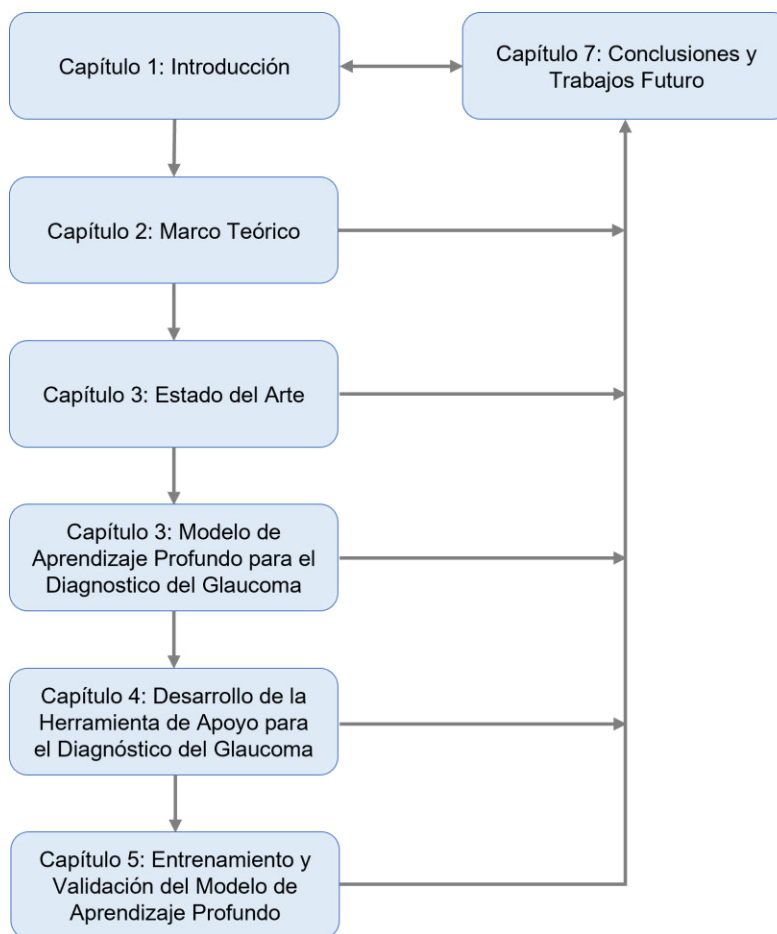


Figura 1.2. Estructura y secuencia de la tesis

Fuente: Elaboración propia.

## CAPÍTULO 2: MARCO TEÓRICO

Este capítulo presenta una breve explicación sobre los aspectos anatómicos de la parte posterior de la retina humana, las principales causas de pérdida de visión en países desarrollados y los algoritmos de última generación desarrollados para la clasificación de imágenes.

### 2.1. Anatomía del fondo de ojo

El ojo es un órgano complejo que comprende una gran cantidad de estructuras que trabajan juntas para proporcionar el sentido de la vista. Se divide en dos partes principales: la anterior y la posterior. La parte anterior es visible desde el exterior y está compuesta por la córnea, la pupila, el iris y el cristalino. La parte posterior está compuesta por el humor vítreo y una pared formada por tres capas diferentes de tejido, la fibrosa (córnea y esclerótica), la vascular (vasos sanguíneos) y la capa interna llamada retina (Ng & Oliver, 2018).

La retina está compuesta anatómicamente por tres estructuras principales: el disco óptico, la red vascular, la mácula y la fovea. El disco óptico, también llamado nervio óptico, es el cable de fibras nerviosas que transporta las señales eléctricas desde la retina al cerebro. Dentro del disco óptico se encuentra la copa óptica, que se caracteriza por el área más brillante en una imagen del fondo de ojo. La red vascular está compuesta por arterias y venas que suministran oxígeno y alimentan la retina. La mácula es una región amarilla que se especializa en la vista de detalle fino ubicada en la parte posterior de la retina (J. Salazar et al., 2019).

La fovea, ubicada en el centro de la mácula, es un pequeño hoyo (aproximadamente, 500  $\mu\text{m}$  de diámetro) que no contiene bastones y tiene la concentración más densa de conos en el ojo (Diaz-Pinto et al., 2019).



## **2.2. Enfermedades de los ojos**

De acuerdo con la Organización Mundial de la Salud, la degeneración macular, retinopatía diabética y el glaucoma son las causas principales de pérdida de visión en países desarrollados (Acharya et al., 2008).

La degeneración macular senil (DMS) es una enfermedad de la retina que causa la interrupción de la visión al afectar la región de la mácula (Liang et al., 2010).

La DMS es también conocida como la tercera causa de ceguera en el mundo. En Pakistán, más de 15 millones de personas sufren de esta enfermedad. Su tratamiento es posible si se diagnostica en etapas tempranas a su desarrollo. En la DMS, la mácula se ve afectada debido a los depósitos de colesterol en las capas de la retina y estos depósitos se conocen como drusas (Khalid et al., 2021).

Las drusas son depósitos amarillos que se pueden ver en la mácula (el centro de la retina) en un gran porcentaje de personas a medida que envejecen. Las personas con drusas, especialmente drusas grandes, tienen un mayor riesgo de degeneración macular relacionada con la edad (DMS). (Virgili et al., 2015). La detección y el diagnóstico temprano de estos drusens es fundamental para el tratamiento oportuno de la DMS (Khalid et al., 2021).

La retinopatía diabética o enfermedad ocular es la principal causa de ceguera en los países desarrollados. Actualmente, su tratamiento se basa en el uso de láseres. Dado que el tratamiento con láser es un procedimiento que destruye células importantes del ojo, se han desarrollado tratamientos farmacológicos para prevenir o mejorar el daño ocular en personas con diabetes (Lopes et al., 2008). El glaucoma es una enfermedad ocular crónica que puede causar una pérdida irreversible de la visión, si no se detecta en una etapa temprana (P. Schacknow & Samples, 2010).

La Organización Mundial de la Salud ha declarado que el glaucoma es la segunda causa principal de ceguera y se espera que el número aumente a 80 millones en 2020 (Quigley & Broman, 2006).

El glaucoma, generalmente, es el resultado de un incremento en la presión intraocular, el cual conduce a un daño progresivo del nervio óptico. Esto se manifiesta como una pérdida gradual del campo visual, comenzando con una disminución de la visión lateral, para, finalmente, ir perdiendo toda la visión. Dado que la pérdida de visión por glaucoma no se puede revertir, el diagnóstico y tratamiento tempranos son esenciales para preservar tanto el campo visual como la calidad de vida total de los pacientes. El glaucoma, generalmente, se desarrolla lentamente con el tiempo sin dolor ni ataques agudos, por lo que la falta de síntomas claros dificulta la detección y detección del glaucoma a través de exámenes oculares regulares. A medida que avanza el glaucoma, se producirá un ahuecamiento patológico adicional del disco óptico debido a cambios en el nervio óptico (Murthi & Madheswaran, 2012).

### **2.3. Algoritmos supervisados**

Los algoritmos de aprendizaje automático supervisados han sido un método dominante en el campo de la minería de datos (Uddin et al., 2019). Los algoritmos de aprendizaje automático emplean una variedad de métodos estadísticos, probabilísticos y de optimización para aprender de la experiencia pasada y detectar patrones útiles a partir de conjuntos de datos grandes, no estructurados y complejos (Van-Leeuwen, 2004). Los algoritmos de aprendizaje supervisado se adaptan bien a dos tipos de problemas: problemas de clasificación y problemas de regresión. En los problemas de clasificación, la variable de salida subyacente es discreta.

#### **Regresión Logística**

Los métodos de regresión se han convertido en una parte integral de cualquier análisis de datos que tenga como objetivo describir la relación entre una variable de respuesta y una o más variables

explicativas. A menudo sucede que la variable resultado es discreta y toma dos o más valores posibles. Durante la última década, el modelo de regresión logística se ha convertido, en muchos países, en el método estándar de análisis en esta situación (Hosmer et al., 2013).

### **Máquina de Soporte Vectorial**

El algoritmo de máquina de vectores de soporte (SVM) puede clasificar datos lineales y no lineales. Primero, mapea cada elemento de datos en un espacio de características n-dimensional, donde n es el número de características. Luego, identifica el hiperplano que separa los elementos de datos en dos clases, mientras maximiza la distancia marginal para ambas clases y minimiza los errores de clasificación. Para realizar la clasificación, se necesita encontrar el hiperplano que diferencia las dos clases por el margen máximo (Joachims, 1998).

### **Árbol de decisión**

El árbol de decisiones (DT) es uno de los primeros y más destacados algoritmos de aprendizaje automático. Un árbol de decisión modela las lógicas de decisión, es decir, prueba y corresponde los resultados para clasificar elementos de datos en una estructura similar a un árbol. Los nodos de un árbol DT, normalmente, tienen varios niveles, donde el primer nodo o el más alto se llama nodo raíz. Todos los nodos internos (es decir, nodos que tienen al menos un hijo) representan pruebas sobre variables o atributos de entrada. Dependiendo del resultado de la prueba, el algoritmo de clasificación se ramifica hacia el nodo hijo apropiado, donde el proceso de prueba y ramificación se repite hasta que alcanza el nodo hoja (Quinlan, 1986).

### **Bosque aleatorio**

Un bosque aleatorio (RF) es un clasificador de conjunto y consta de muchos DT de manera similar a la forma en que un bosque es una colección de muchos árboles. Los DT que crecen muy

profundamente a menudo causan un sobreajuste de los datos de entrenamiento, lo que da como resultado una gran variación en el resultado de clasificación para un pequeño cambio en los datos de entrada. Son muy sensibles a sus datos de entrenamiento, lo que los hace propensos a errores en el conjunto de datos de prueba. Los diferentes DT de una RF se entrenan utilizando las diferentes partes del conjunto de datos de entrenamiento. Para clasificar una nueva muestra, se requiere que el vector de entrada de esa muestra se transmita con cada DT del bosque.

## **2.4. Algoritmos no supervisados**

El algoritmo del vecino más cercano K (KNN) es uno de los algoritmos de clasificación más simples y tempranos. Puede pensarse que es una versión más simple de un clasificador NB. A diferencia de la técnica NB, el algoritmo KNN no requiere considerar valores de probabilidad. La "K" es el algoritmo KNN, que significa el número de vecinos más cercanos que se considera que toman "voto". La selección de diferentes valores para "K" puede generar diferentes resultados de clasificación para el mismo objeto de muestra (Cover & Hart, 1967).

### **Red neuronal artificial**

Las redes neuronales artificiales (ANN) son un conjunto de algoritmos de aprendizaje automático que se inspiran en el funcionamiento de las redes neuronales del cerebro humano. Primero, fueron propuestos por McCulloch y Pitts, y luego popularizados por los trabajos de Rumelhart et al. en la década de 1980. En el cerebro biológico, las neuronas están conectadas entre sí a través de múltiples uniones de axones que forman un gráfico similar en un modelo. Estas interconexiones se pueden volver a cablear (por ejemplo, a través de la neuroplasticidad), lo cual ayuda a adaptar, procesar y almacenar información. Asimismo, los algoritmos ANN se pueden representar como un grupo de nodos interconectados. La salida de un nodo va como entrada a otro nodo para su

posterior procesamiento de acuerdo con la interconexión. Los nodos, normalmente, se agrupan en una matriz llamada capa, según la transformación que realicen. Además de la capa de entrada y salida, puede haber una o más capas ocultas en un marco ANN. Los nodos y los bordes tienen pesos que permiten ajustar la intensidad de la señal de comunicación que puede amplificarse o debilitarse mediante el entrenamiento repetido. Según el entrenamiento y la adaptación posterior de las matrices, los pesos de los nodos y los bordes, las ANN pueden hacer una predicción para los datos de prueba (Uddin et al., 2019).

## CAPÍTULO 3: ESTADO DEL ARTE

En este capítulo, se presenta una revisión de la literatura acerca del diagnóstico del glaucoma utilizando diferentes técnicas de inteligencia artificial. En esta revisión, se identifican técnicas y herramientas que permiten realizar un diagnóstico automatizado y temprano del glaucoma haciendo uso de inteligencia artificial.

### 3.1. Metodología de la investigación

Para diseñar una solución para el diagnóstico del glaucoma usando inteligencia artificial, se ha hecho una revisión sistemática, bajo una adaptación basada en la metodología usada en (Santisteban & Mauricio, 2017), entre otros, este se desarrolla teniendo en cuenta estos tres pasos:

- (a) **Planificación:** En este proceso, se identifican algunas preguntas sobre los objetivos de la investigación y el protocolo de la revisión.
- (b) **Ejecución:** En este proceso, se hace realidad el plan y los estudios principales que siguen los criterios de inclusión y exclusión seleccionados que se mencionan o descartan.
- (c) **Resultados:** En este proceso, se presentan las estadísticas resultantes del análisis de los documentos encontrados y seleccionados.

### 3.2. Planificación de la revisión

Para llevar a cabo la revisión de la literatura sobre un sistema para el diagnóstico del glaucoma, se plantearon las siguientes preguntas de investigación.

**Q1:** ¿Qué herramientas móviles o web que diagnostiquen el glaucoma existen?

**Q2:** ¿Qué técnicas de preprocesamiento para una imagen del fondo de ojo existen?

**Q3:** ¿Qué técnicas para la extracción de características son utilizadas?

**Q4:** ¿Qué técnicas para la selección de características son utilizadas?

**Q5:** ¿Qué modelos de clasificación basado en machine learning existen para el diagnóstico del glaucoma a partir de imágenes del fondo de ojo?

**Q6:** ¿Qué dispositivos son utilizados para tomar una foto del fondo del ojo?

**Q7:** ¿Qué modelos de clasificación basados en aprendizaje profundo existen para el diagnóstico del glaucoma a partir de imágenes del fondo de ojo?

Para poder responder estas preguntas, se hace una búsqueda usando los metabuscaadores SCOPUS, Web of Science y Pubmed. Los informes seleccionados corresponden a cadenas de palabras que fueron aplicadas como filtros al título, resumen y palabras clave, para un período comprendido entre enero de 2017 y octubre de 2019, como se puede visualizar en la Tabla 3.1.

Origen	Cadena de búsqueda
Web of Science	glaucoma and (diagnosis or processing or prediction)
Scopus	(Glaucoma and (diagnosis or processing or prediction)) or (fundus AND eye AND phone)
Pubmed	glaucoma and (diagnosis or processing or prediction) AND ("artificial intelligence" OR "machine learning" OR "computer science")

Tabla 3.1. Cadenas de búsqueda utilizadas en las fuentes

Además, se consideraron los criterios de inclusión y exclusión que se establecen en la Tabla 3.2.

Criterios de inclusión	Criterios de exclusión
<ul style="list-style-type: none"> <li>Modelos, métodos y técnicas para el diagnóstico del glaucoma</li> <li>Variables propuestas para el diagnóstico del glaucoma</li> <li>Artículos en inglés</li> </ul>	<ul style="list-style-type: none"> <li>Libros, actas, carteles, tesis, talleres, conferencias</li> <li>Elementos que no tengan que ver con el contexto de diagnosticar</li> </ul>

<ul style="list-style-type: none"> <li>• Artículos de revistas que cubren el período entre 2017 y 2019</li> <li>• Artículos que responden directamente las preguntas de investigación</li> </ul>	<ul style="list-style-type: none"> <li>• Artículos que mencione cómo diagnosticar el glaucoma haciendo uso de herramientas electrónicas</li> </ul>
--	--

Tabla 3.2. Criterios de inclusión y exclusión

### 3.3. Realización de la revisión

Los posibles estudios primarios identificados durante la búsqueda pasan por un proceso de selección de acuerdo con los criterios de inclusión y exclusión decretados anteriormente. Fue necesaria una revisión del contenido para determinar su relevancia, especialmente, para determinar si estos artículos hacen referencia a soluciones haciendo uso de inteligencia artificial para el diagnóstico del glaucoma y no nuevas herramientas médicas para el diagnóstico. Después de esto, se analizaron los documentos seleccionados, el resumen, la introducción y las conclusiones con el objetivo de dar respuesta a las preguntas de la investigación. En la Figura 3.1, se ve representado el proceso de revisión de la literatura.

La revisión sistemática dio muestra de 301 documentos, de los cuales, luego de aplicar los criterios de inclusión y exclusión, salieron seleccionados 30 documentos, descritos por motor de búsqueda en la Tabla 3.3.



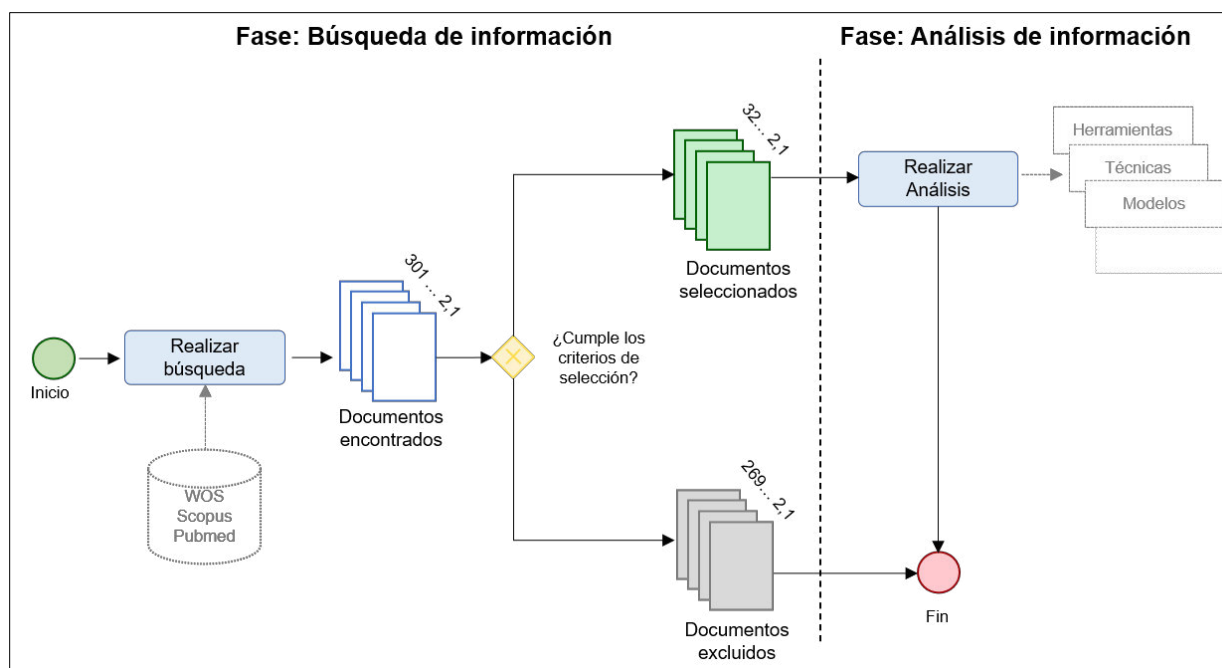


Figura 3.1. Proceso de revisión de la literatura

Fuente: Elaboración propia.

Fuente	Estudios potencialmente elegibles	Estudios seleccionados
Wos	37	12
Scopus	176	13
Pubmed	88	7
<b>TOTAL</b>	<b>301</b>	<b>32</b>

Tabla 3.3. Cantidad de documentos por motor de búsqueda

### 3.3.1. Documentos seleccionados

Después de la planificación, se muestran los documentos obtenidos en la Tabla 3.4.

<b>ID</b>	<b>Título</b>	<b>Autor</b>	<b>Revista</b>
A01	Machine learning models based on the dimensionality reduction of standard automated perimetry data for glaucoma diagnosis	(Lee et al., 2019)	Artificial Intelligence in Medicine (Q1)
A02	Automated glaucoma diagnosis using bit-plane slicing and local binary pattern techniques	(Maheshwari et al., 2019)	Computers in Biology and Medicine (Q2)
A03	Automatic methods for diagnosis of glaucoma using texture descriptors based on phylogenetic diversity	(de Carvalho et al., 2018)	Computers and Electrical Engineering (Q1)
A04	Texture based on geostatistic for glaucoma diagnosis from fundus eye image	(de Sousa et al., 2017)	Multimedia Tools and Applications (Q2)
A05	Diagnosis of retinal health in digital fundus images using continuous wavelet transform (CWT) and entropies	(Koh et al., 2017)	Computers in Biology and Medicine (Q2)
A06	Automated Diagnosis of Glaucoma Using Empirical Wavelet Transform and Correntropy Features Extracted from Fundus Images	(Maheshwari, Pachori, & Acharya, 2017)	IEEE Journal of Biomedical and Health Informatics(Q1)
A07	An automated eye disease prediction system using bag of visual words and support vector machine	(Sundaram & Ravichandran, 2019)	Journal of Intelligent & Fuzzy Systems (Q3)
A08	Automated retinal health diagnosis using pyramid histogram of visual words and Fisher vector techniques	(Koh et al., 2018)	Computers in Biology and Medicine (Q2)
A09	Automated Framework for Screening of Glaucoma Through Cloud Computing	(Soorya et al., 2019)	Journal of Medical Systems (Q2)
A10	Computer-aided diagnosis of glaucoma using fundus images: A review	(Hagiwara et al., 2018)	Computer Methods and Programs in Biomedicine (Q1)
A11	Yanbao: A mobile app using the measurement of clinical parameters for glaucoma screening	(Guo et al., 2018)	IEEE Access (Q1)

A12	Automated retinal nerve fiber layer defect detection using fundus imaging in glaucoma	(Panda et al., 2018)	Computerized Medical Imaging and Graphics (Q1)
A13	A Smartphone-Based Tool for Rapid, Portable, and Automated Wide-Field Retinal Imaging	(Kim et al., 2018)	Translational Vision Science & Technology (Q1)
A14	Smart phone ophthalmoscopy: a potential replacement for the direct ophthalmoscope	(Mamtora et al., 2018)	Eye (Q1)
A15	An Approach to Automatic Hard Exudate Detection in Retina Color Images by a Telemedicine System Based on the d-Eye Sensor and Image Processing Algorithms	(Saeed et al., 2019)	Pattern Recognition Letters (Q2)
A16	Glaucoma Diagnosis with Machine Learning Based on Optical Coherence Tomography and Color Fundus Images	(An et al., 2019)	Journal of Healthcare Engineering (Q3)
A17	Automated glaucoma detection using GIST and pyramid histogram of oriented gradients (PHOG) descriptors	(Gour & Khanna, 2020)	Pattern Recognition Letters (Q2)
A18	Glaucoma diagnosis in fundus eye images using diversity indexes	(Araújo et al., 2019)	Multimedia Tools and Applications (Q2)
A19	Computer aided diagnosis of glaucoma using discrete and empirical wavelet transform from fundus images	(Hagiwara et al., 2018)	IET Image Processing (Q2)
A20	Accurate prediction of glaucoma from colour fundus images with a convolutional neural network that relies on active and transfer learning	(Hemelings et al., 2020)	Acta Ophthalmologica (Q1)
A21	A deep learning model for the detection of both advanced and early glaucoma using fundus photography	(Ahn et al., 2018)	PLOS ONE (Q1)
A22	Deep convolution neural network for accurate diagnosis of glaucoma using digital fundus images	(Raghavendra et al., 2018)	Information Sciences (Q1)
A23	Automated detection of Glaucoma using deep learning convolution network (G-net)	(Juneja et al., 2020)	Multimedia Tools and Applications (Q2)

A24	Glaucoma diagnosis based on both hidden features and domain knowledge through deep learning models	(Chai et al., 2018)	Knowledge-Based Systems (Q1)
A25	A machine-learning graph-based approach for 3D segmentation of Bruch's membrane opening from glaucomatous SD-OCT volumes	(Miri et al., 2017)	Medical Image Analysis (Q1)
A26	Machine Learning in the Detection of the Glaucomatous Disc and Visual Field	(Smits et al., 2019)	Seminars in Ophthalmology (Q2)
A27	Deep learning in ophthalmology: The technical and clinical considerations	(Ting et al., 2019)	Progress in Retinal and Eye Research (Q1)
A28	Artificial intelligence in glaucoma	(Zheng et al., 2019)	Current Opinion in Ophthalmology (Q1)
A29	Automatic determination of vertical cup-to-disc ratio in retinal fundus images for glaucoma screening	(Guo et al., 2019)	IEEE Access (Q1)
A30	An automated glaucoma screening system using cup-to-disc ratio via Simple Linear Iterative Clustering superpixel approach	(Mohamed et al., 2019)	Biomedical Signal Processing and Control (Q2)
A31	Iterative variational mode decomposition based automated detection of glaucoma using fundus images	(Maheshwari, Pachori, Kanhangad, et al., 2017)	Computers in Biology and Medicine (Q2)
A32	CNNs for automatic glaucoma assessment using fundus images: an extensive validation	(Diaz-Pinto et al., 2019)	BioMedical Engineering OnLine (Q2)

Tabla 3.4. Documentos seleccionados para el estudio

### 3.4. Análisis

En esta sección, se responden a las preguntas de investigación que fueron propuestas en la planificación.

### 3.4.1. ¿Qué aplicaciones móviles o web que diagnostiquen el glaucoma existen?

En la literatura, fueron encontrados múltiples modelos para el diagnóstico del glaucoma, sin embargo, solo dos de estos fueron implementados en una plataforma móvil o web. La Tabla 3.5 resume los artículos encontrados.

Herramientas móviles o web que diagnostican el glaucoma	Descripción	Fuente
Yanbao	Aplicación móvil que busca mejorar la eficiencia y los recursos de los oftalmólogos, logra un 76% de precisión	(Guo et al., 2018)
Glaucoma Detection Tool	Web basada en la computación en la nube la cual puede ser utilizada para detectar pacientes con glaucoma con 92% de precisión	(Soorya et al., 2019)

Tabla 3.5. Herramientas web o móvil que diagnostican el glaucoma

### 3.4.2. ¿Qué técnicas de preprocesamiento para una imagen del fondo de ojo existen?

De la revisión de los artículos, se encontraron un total de 11 métodos de preprocesamiento.

ID	Método de preprocesamiento	Descripción	Fuente
P1	Light Random Sprays Retinex	Algoritmo de mejora de imagen basado en la capacidad del sistema visual humano para percibir el color de objetos bajo diferentes condiciones de iluminación	(Araújo et al., 2019)
P2	Ecualización de histograma	Es una transformación que, al ser aplicada a una imagen, permite obtener una imagen con una distribución uniforme.	(Araújo et al., 2019)
P3	Filtro de la mediana	Es una transformación que, al ser aplicada a una imagen, permite reemplazar el valor de un pixel, por el valor central que tiene en una vecindad definida.	(Araújo et al., 2019)

P4	Filtro Gaussiano	Es una transformación utilizada para eliminar el ruido de una imagen.	(Araújo et al., 2019)
P5	División RGB	Consiste en dividir una imagen en sus canales de rojo, verde y azul.	(Maheshwari, Pachori, & Acharya, 2017; Maheshwari, Pachori, Kanhangad, et al., 2017; Mohamed et al., 2019)
P6	Contrast Limited Adaptive Histogram Equalization (CLAHE)	Técnica que permite la mejora de contraste de las imágenes	(Gour & Khanna, 2020; Koh et al., 2017; Maheshwari et al., 2019)
P7	BIT-Plane slicing	Método para representar una imagen con uno o más bits del byte que es utilizado para cada píxel	(Maheshwari et al., 2019)
P8	Recordar le región de interés (ROI)	Consiste en recortar la imagen en la donde se presume encontrar la mayor cantidad de características.	(de Carvalho et al., 2018)
P9	Redimensionar la imagen	Consiste en estandarizar el tamaño de las imágenes, debido a que, generalmente, provienen de distintas fuentes.	(Guo et al., 2019; Mohamed et al., 2019)
P10	Image flipping	Consiste en realizar giros horizontales y verticales a la imagen.	(Sundaram & Ravichandran, 2019)
P11	Contrast stretching	Método que intenta mejorar la imagen estirando el rango de valores de intensidad	(Sundaram & Ravichandran, 2019)

Tabla 3.6. Métodos de preprocesamiento encontradas en la literatura

### 3.4.3. ¿Qué técnicas para la extracción de características son utilizadas?

En la literatura, fueron encontradas múltiples técnicas para la extracción de características que permitan el diagnóstico del glaucoma. En la Tabla 3.7, se resume las técnicas referenciadas.

ID	Feature extraction	Descripción	Fuente
E1	Índices de diversidad	Técnica que adapta el cálculo de los índices de diversidad de la ecología para la extracción de características	(Araújo et al., 2019)
E2	Renyi entropy, Kapur entropy, Yager entropy	Técnica para capturar el nivel de incertidumbre presente en los píxeles de las imágenes	(Maheshwari, Pachori, Kanhangad, et al., 2017)
E3	Descriptor de GIST y descriptor PHOG	Técnica que permite discriminar las características acumulativas en los píxeles de las imágenes	(Gour & Khanna, 2020)
E4	Statistical pixel-level	Técnica que combina múltiples píxeles y que solo conserva el píxel de salida	(Mohamed et al., 2019)
E5	Semivariogram, semimadogram, covariogram, correlogram	Describen la textura de una imagen dada a través del grado de asociación espacial entre píxeles espacialmente referenciados de la imagen.	(de Sousa et al., 2017)
E6	Local Binary Patterns (LBP)	Es un descriptor visual que permite seleccionar píxeles basados en un modelo de textura.	(Maheshwari et al., 2019)
E7	Phylogenetic diversity indexes.	Técnica que utiliza las propiedades de textura basada en índices de diversidad filogenética	(de Carvalho et al., 2018)
E8	Transformada de wavelet	Enfoque de selección de características basada en la descomposición de señales de una imagen	(Koh et al., 2017; Maheshwari, Pachori, & Acharya, 2017)

E9	Pyramid histogram of visual words (PHOW)	Técnica que considera la característica de información local de la imagen mediante la aplicación de filtros de Gabor	(Koh et al., 2018)
E10	Speeded Up Robust Features (SURF)	Método que detecta los puntos de interés de una imagen utilizando la aproximación básica de la matriz de Hesse	(Sundaram & Ravichandran, 2019)

Tabla 3.7. Métodos de extracción de características encontradas en la literatura

### 3.4.4. ¿Qué técnicas para la selección de características son utilizadas?

En la literatura, fueron encontradas múltiples técnicas para la selección de características que permitan el diagnóstico del glaucoma. En la Tabla 3.8, se resume las técnicas referenciadas.

<b>Id</b>	<b>Feature selection</b>	<b>Descripción</b>	<b>Fuente</b>
S1	Algoritmo genético	Técnica que simula el mecanismo de evolución, en el cual, en cada generación, mantiene los mejores genes de la generación anterior	(Araújo et al., 2019; de Sousa et al., 2017)
S2	Algoritmo de Relief	Enfoque que adopta un método de filtro para la selección de características que es notablemente sensible a las interacciones existentes entre características	(Maheshwari, Pachori, Kanhangad, et al., 2017)
S3	Análisis de componentes principales	Método estadístico para describir variables correlacionadas	(Gour & Khanna, 2020; Maheshwari, Pachori, & Acharya, 2017)
S4	Student's t-test	Método que considera el estadístico utilizado en la distribución si la hipótesis nula es cierta	(Maheshwari et al., 2019)
S5	Particle Swarm Optimization (PSO)	Método que referencia al comportamiento de las partículas en la naturaleza, de tal manera que selecciona la distribución óptima	(Koh et al., 2017)

Tabla 3.8. Métodos de selección de características encontradas en la literatura



### 3.4.5. ¿Qué modelos de clasificación basado en machine learning existen para el diagnóstico del glaucoma a partir de imágenes del fondo de ojo?

En la literatura, se encontraron 3 distintos modelos de clasificación. La Tabla 3.9 contiene los modelos referenciados.

ID	Clasificación	Detalle	Resultado	Fuente
C1	Modelo basado en reducción de dimensionalidad	Modelo entrenado con 375 imágenes de ojo sanas y 257 glaucomatosas. Se realizan varios métodos de SVM, Coeficientes de correlación, redes neuronales y 4 tipos de reducción de dimensionalidad, siendo esta la de mejor rendimiento	AUC: 0.912	(Lee et al., 2019)
C2	Modelo basado de clasificación basado en algoritmos genéticos y máquina de soporte vectorial	Modelo entrenado con 455 imágenes. Se extrajeron las características mediante semivariogramas, covariogramas y correlogramas. Donde se seleccionaron las características por algoritmos genéticos y se clasificó por SVM.	Sensitivity: 0.95 Accuracy: 0.91 Specificity: 0.88	(de Sousa et al., 2017)
C3	Modelo de clasificación basado en random forest	Modelo entrenado con 1486 imágenes, se extrajeron las características mediante AdaSyn, se seleccionaron las características mediante random forest	Sensitivity: 0.9248 Accuracy: 0.8937 Specificity: 0.9558	(Koh et al., 2017)
C4	Máquina de Soporte Vectorial y PCA	Modelo entrenado con 505 imágenes, donde se extrajeron 14 características utilizando transformadas de wavelet para extraer las características.	Sensitivity: 0.8640 Accuracy: 0.8357 Specificity: 0.8080	(Hagiwara et al., 2018)

Tabla 3.9. Modelos de machine learning entrenados para clasificar el glaucoma a partir de imágenes del fondo de ojo encontrados en la literatura

### 3.4.6. ¿Qué dispositivos son utilizados para tomar una foto del fondo de ojo?

En la literatura, se encontraron 5 dispositivos distintos utilizados para la captura de imágenes del fondo de ojo. La Tabla 3.10 contiene los dispositivos referenciados.

ID	Dispositivo	Descripción	Fuente
D1	Zeiss FF450 plus	Las imágenes tomadas tienen una resolución de 2588 x 1958 píxeles y estaban formateadas en JPEG.	(Hagiwara et al., 2018; Mamtora et al., 2018; Smits et al., 2019)
D2	Visupac versión 4.4.4	Con un aumento de 5X y un campo de visión de 200, 300 y 500 (FOV)	(An et al., 2019)
D3	D-EYE oftalmoscopio	Oftalmoscopio indirecto portable que se puede utilizar con iPhone y Android	(Araújo et al., 2019)
D4	Kowa VX-10	Kowa es el pionero en la combinación de cámaras retinianas no midriáticas y midriáticas.	(Hagiwara et al., 2018)
D5	CellScope Retina	Pesa aproximadamente 310 g y consta de un teléfono inteligente y una carcasa de plástico impresa tridimensional (3D).	(Gour & Khanna, 2020)

Tabla 3.10. Dispositivos que capturan una imagen del fondo de ojo encontrados en la literatura

### 3.4.7. ¿Qué modelos de clasificación basado en aprendizaje profundo existen para el diagnóstico del glaucoma a partir de imágenes del fondo de ojo?

En la literatura, se encontraron 5 distintos modelos de aprendizaje profundo que permiten el diagnóstico del glaucoma a partir de imágenes del fondo de ojo. La Tabla 3.11 contiene los modelos referenciados.

ID	Modelos	Detalle	Resultados	Fuente
M1	Transfer learning Inception v3	Método que aprovecha los pesos de InceptionV3 para aplicarlo en el diagnóstico del glaucoma	Accuracy: 84.5% AUC: 0.93	(Ahn et al., 2018)
M2	CNN de 18 capas	Modelo propuesto compuesto por 18 capas	Accuracy: 98.13% Sensitivity: 98.0% Specificity: 98.30%	(Raghavendra et al., 2018)

M3	Multi-branch neural network	Propone 3 modelos distintos en el cual sus salidas están concatenadas para mostrar un resultado único.	Accuracy: 91.51% Sensitivity: 92.33% Specificity: 90.90%	(Chai et al., 2018)
M4	Transfer learning ResNet50	Método que aprovecha los pesos de ResNet50 para aplicarlo en el diagnóstico del glaucoma	Sensitivity: 95.6% Specificity: 92.0% AUC: 0.986	(Hemelings et al., 2020)
M5	Fine tuning VGG19	Método donde se realiza el proceso de Fine tuning al modelo VGG19 entrenado en ImageNet	Accuracy: 90.69% Sensitivity: 92.40% Specificity: 88.46%	(Diaz-Pinto et al., 2019)

Tabla 3.11. Modelos de aprendizaje profundo entrenados para clasificar el glaucoma a partir de imágenes del fondo de ojo encontrados en la literatura

Según la revisión se visualiza que los modelos de aprendizaje profundo tienen un mejor rendimiento para en la clasificación de ojos con glaucoma y sin glaucoma. Además, siendo la facilidad de implementación uno de los factores más importantes, en el punto **4.1**, justificamos a detalle la selección del aprendizaje profundo para la solución del problema planteado en la tesis.

# **CAPÍTULO 4: MODELO DE APRENDIZAJE PROFUNDO PARA EL DIAGNÓSTICO DEL GLAUCOMA**

En el presente capítulo, se propone un modelo de clasificación basado en aprendizaje profundo para diagnóstico automático del glaucoma. Asimismo, se justifica el modelo y se describe todos los pasos para su construcción.

## **4.1. Justificación del modelo**

Dentro de la Inteligencia Artificial (IA), se encuentra el campo del Machine Learning (ML) que se dedica al desarrollo de sistemas informáticos que puedan aprender a realizar o predecir un resultado a partir de patrones obtenidos de los datos de entrada sin ser programados explícitamente en la tarea (Smits et al., 2019).

La mayoría de los modelos de ML para la clasificación del glaucoma siguen el esquema de preprocesamiento, extracción de características, selección de características y clasificación (Araújo et al., 2019; de Carvalho et al., 2018; de Sousa et al., 2017; Gour & Khanna, 2020; Koh et al., 2017, 2018; Maheshwari et al., 2019; Maheshwari, Pachori, & Acharya, 2017; Maheshwari, Pachori, Kanhangad, et al., 2017; Mohamed et al., 2019; Sundaram & Ravichandran, 2019) (ver Figura 4.1); sin embargo, la implementación de los métodos de extracción (Tabla 3.7) y selección de características (Tabla 3.8) resulta tedioso y requiere de mucho tiempo, especialmente, porque se requiere de la pericia del especialista y del conocimiento que existe en la literatura (Raghavendra et al., 2018), lo cual limita su alcance.

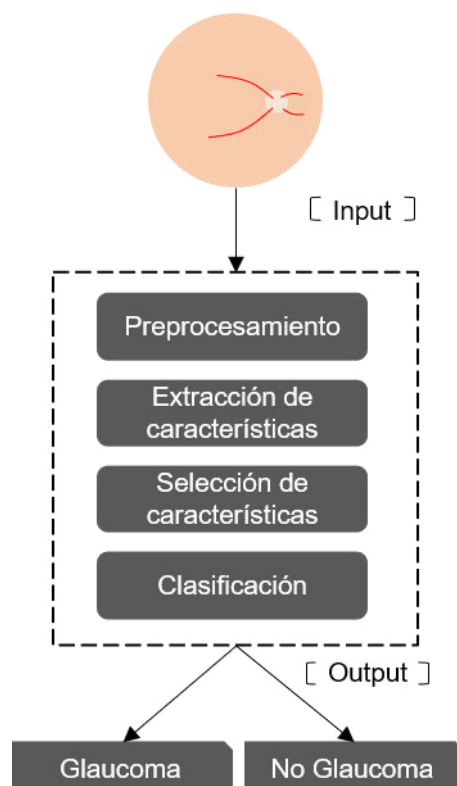


Figura 4.1. Proceso de ML para el diagnóstico del glaucoma

Fuente: Elaboración propia.

El Aprendizaje Profundo (DL, por sus siglas en inglés) es una rama del Machine Learning que incorpora algoritmos computacionales que imitan la estructura biológica del cerebro (LeCun et al., 2015). Un tipo particular de DL es la red neuronal convolucional (CNN, por sus siglas en inglés) (Zheng et al., 2019), que consta de un conjunto de capas de procesamiento que se asemejan a los procesos electrofisiológicos de la corteza visual animal, donde cada neurona cortical responde a un parte particular del campo receptivo visual, de forma similar, una neurona o nodo artificial responderá a un elemento específico de los datos de entrada (Hinton, 2018). Una CNN se puede dividir en capa una de entrada, una capa de salida y varias capas ocultas (Figura 4.2); las capas ocultas están compuestas, generalmente, por capas convolucionales, agrupadas y completamente conectadas, estas capas interiorizan el proceso de extracción de características, selección de

características y clasificación (Ting et al., 2019), lo que permite capturar patrones y características ocultas (Raghavendra et al., 2018). Además, son fáciles y rápidas de implementar, y logran altos niveles de rendimiento en la clasificación del glaucoma (Tabla 3.11.).




Figura 4.2. Esquema general de una CNN: (a) Capa de entrada, especifica el ancho, altura y canales de la imagen de entrada. (b) Capas ocultas, permiten la extracción de características y selección de características. (c) Capa de salida, produce el resultado de la clasificación.

Fuente: Elaboración propia.

## 4.2. Modelo de aprendizaje profundo propuesto

En la Figura 4.3, se presenta el esquema general del modelo de aprendizaje profundo propuesto para lograr el diagnóstico del glaucoma.

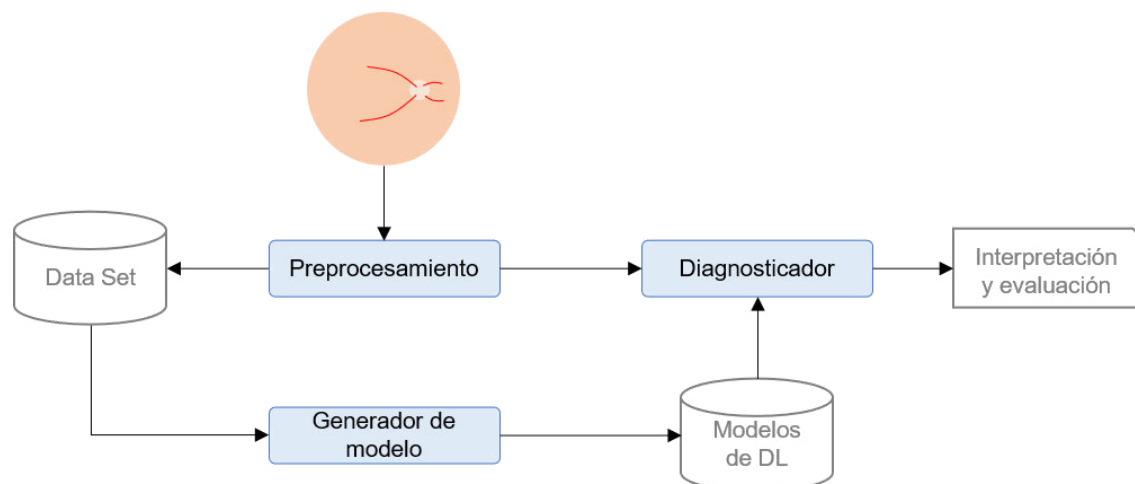


Figura 4.3. Modelos de DL propuesto. Elaboración propia

Fuente: Elaboración propia.

### 4.2.1. Data Set

Un data set es un conjunto de datos, en el caso particular del glaucoma, es dado por un conjunto de imágenes de fondo de ojo de paciente con etiquetas de “normal” y “glaucoma” (Figura 4.4.), es decir el paciente no tiene glaucoma (normal) o tiene glaucoma (glaucoma). Se considera el uso de 5 data sets públicos encontrados en la literatura: HRF (Kohler et al., 2013), Drishti-GS1(Chakravarty & Sivaswamy, 2016), sjchoi86-HRF(Abbas, 2017), RIM-ONE(Medina-Mesa et al., 2016), ACRIMA (Diaz-Pinto et al., 2019).




Figura 4.4. Imágenes del fondo de ojo etiquetadas: (a) normal, (b) glaucoma

Fuente: Elaboración propia.

## 4.2.2. Preprocesamiento

Cuando el data set contiene una gran cantidad imágenes de alta resolución, esta afecta directamente en el tiempo de entrenamiento y en los resultados del modelo (Diaz-Pinto et al., 2019), además imágenes insuficientes para una categoría o imágenes de mala calidad podrían afectar negativamente a la precisión de los resultados. Por ello, es deseable realizar un pre-procesamiento de la data set con el fin de obtener un data set de mejor calidad o un mayor número de imágenes y por consiguiente mejor rendimiento en los resultados del diagnóstico. Algunas de estas técnicas de pre-procesamiento usadas para el diagnóstico del glaucoma se muestran en la Tabla 3.6 del capítulo III y una imagen pre-procesada se muestra en la Figura 4.5. Además, el trabajo de (Orlando et al., 2017) demuestra combinar el redimensionamiento de imágenes con otros métodos de preprocesamiento, como CLAHE y otros filtros, no muestra una mejora significativa respecto a entrenar el modelo solo con las imágenes redimensionadas.




Figura 4.5. Ejemplos de pre-procesamiento: (a) Imagen original, (b) CLAHE, (c) Filtro gaussiano, (d)

Filtro de la mediana

Fuente: Elaboración propia.



### 4.2.3. Generador de modelo

El generador del modelo es considerado como un módulo que permite generar un modelo base a partir de otro modelo base, por distintas técnicas, como el transfer learning y el fine tuning.

El proceso de transfer learning en los modelos de aprendizaje profundo, previamente entrenados, consta de dos partes principales: la construcción o selección de un modelo previamente entrenado, y la fase de ajuste fino (Baykal et al., 2020). El ajuste de los modelos de aprendizaje profundo tiene por objetivo transferir los pesos de modelos previamente entrenados, generalmente con el data set de ImageNet que consta 1.2 millones de imágenes y 1000 categorías (Park et al., 2017), modificando las últimas capas para adaptar la nueva tarea de clasificación (Figura 4.6), en consecuencia, la red se ajustará con precisión a la nueva tarea mediante la retro propagación de errores a través del Descenso de Gradiente Estocástico (SGD, por sus siglas en inglés) (Baykal et al., 2020).

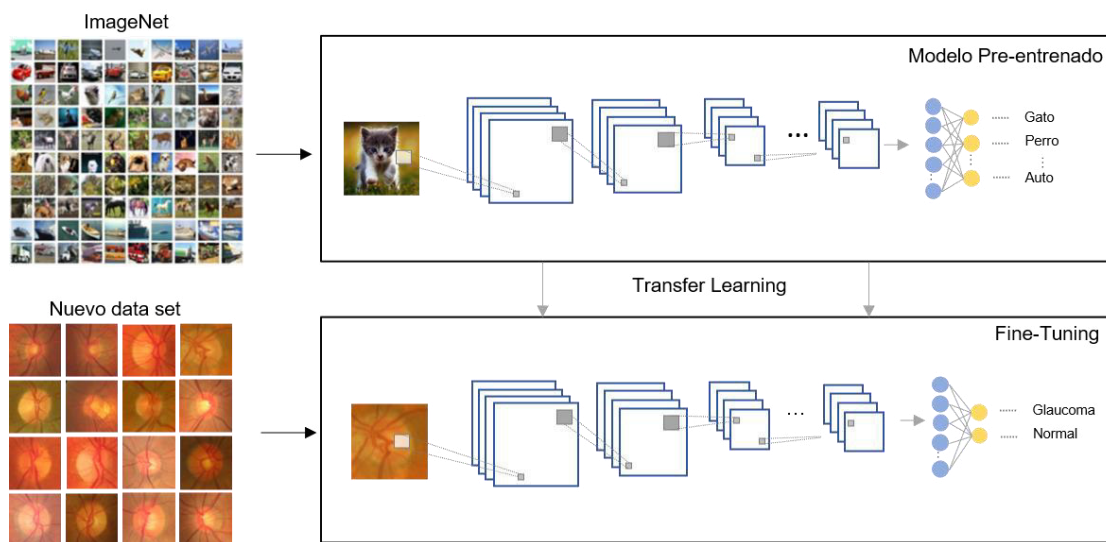


Figura 4.6. Proceso de transferencia de aprendizaje y ajuste fino para un modelo de DL

Fuente: Elaboración propia.

En esta tesis, se contempla el uso de dos tipos de fine tuning, donde se modifican las últimas capas de los modelos originales. En el primer tipo, que, se cambió la capa completamente conectada de cada modelo de DL por una capa de agrupación de promedio global (GlobalAveragePooling2D), seguida de una capa completamente conectada de dos nodos y una función de activación (AF) softmax (Figura 4.7.a). En el segundo tipo, se cambió la capa completamente conectada por una capa Flatten, seguida por una capa Dense de 256 nodos con una AF relu, una capa Dropout, una capa Dense de 128 nodos, otra capa Dropout y una capa completamente conectada de dos nodos, que representan las clases glaucoma y normal, con una AF softmax (Figura 4.7.b). El primer tipo de fine tuning se basa en el trabajo de (Diaz-Pinto et al., 2019) quien realiza una validación extensa de distintas capas y obtiene los mejores resultados con la capa de GlobalAveragePooling2D. El segundo tipo, se basa en el trabajo de (Chollet, 2017) que demuestra el rendimiento de las capas con distintos datasets.




Figura 4.7. Esquema general de los modelos de DL seleccionados: (a) primer tipo de fine tuning, (b) segundo tipo de fine tuning

Fuente: Elaboración propia.

#### 4.2.4. Modelos de DL

Dentro de los modelos de DL, se tiene a AlexNet, que, en el 2012, salió a la luz revolucionando el mundo de la clasificación de imágenes, consta de 5 capas convolucionales (Krizhevsky et al., 2012) y fue el primer modelo en obtener un rendimiento considerable al ser entrenado con ImageNet. Por otro lado, otros modelos de DL más recientes y que también presentan buenos resultados son: VGGnet (16 o 19 capas convolucionales), Inception V1 a V4 (27 capas convolucionales), ResNet (18,50, 125 capas convolucionales), DenseNet (40, 100, 121, 169 capas convolucionales) (Ting et al., 2019). Comparados con AlexNet, los modelos de DL recientes tienen un mayor rendimiento debido a que tienen características únicas, como la adición de más capas, filtros convolucionales más pequeños, omisión de conexiones y filtros más complejos (Keras Team, 2020; Ting et al., 2019). En la figura 4.8, se muestran los modelos de DL.




Figura 4.8. Modelos de DL: (a) Alex-Net, (b) VGG16, (c) Inception V3, (d) ResNet50

Fuente: (Keras Team, 2020; Krizhevsky et al., 2012; Ting et al., 2019)

Los modelos de DL contemplados se basan en los 3 encontrados en la literatura (ver Tabla 2.11.), y 9 disponibles en la API de Keras (Keras Team, 2020), haciendo un total de 12 modelos (en sus versiones entrenadas en ImageNet) a las cuales se les realiza los 2 tipos de fine tuning mencionados en el punto anterior, haciendo un total de 24 modelos de DL. Las capas de Keras para cada modelo y fine tuning se muestran en la Tabla 4.1.

<b>Modelo</b>	<b>Keras Layers</b>	<b>Keras Layers Fine Tuning 1</b>	<b>Keras Layers Fine Tuning 2</b>
DenseNet121	427	429	433
DenseNet169	595	597	601
InceptionV3	311	313	317
MobileNet	86	88	92
MobileNetV2	154	156	160
NASNetMobile	769	771	775
ResNet101	345	347	351
ResNet50	175	177	181
ResNet50V2	190	192	196
VGG16	19	21	25
VGG19	22	24	28
Xception	132	134	138

Tabla 4.1. Modelos de aprendizaje profundo entrenados para clasificar el glaucoma a partir de imágenes del fondo de ojo encontrados en la literatura

Los tamaños por defecto de la capa de entrada para cada modelo se muestran en la Tabla 4.2.

<b>Modelo</b>	<b>Default input shape</b>
DenseNet121	224x224 px
DenseNet169	224x224 px
MobileNet	224x224 px
MobileNetV2	224x224 px
ResNet101	224x224 px
ResNet50	224x224 px
ResNet50V2	224x224 px
VGG16	224x224 px
VGG19	224x224 px
InceptionV3	299x299 px
Xception	299x299 px
NASNetMobile	331x331 px

Tabla 4.2. Tamaño de imágenes de entrada para cada modelo

### 4.2.5. Diagnosticador

El diagnosticador está compuesto por la combinación de múltiples modelos de DL, debido a que se ha demostrado que la combinación de múltiples modelos logra un mejor rendimiento en la clasificación (Ting et al., 2019), por ello, se plantea el uso del criterio de votación, bajo el esquema de la Figura 4.9.

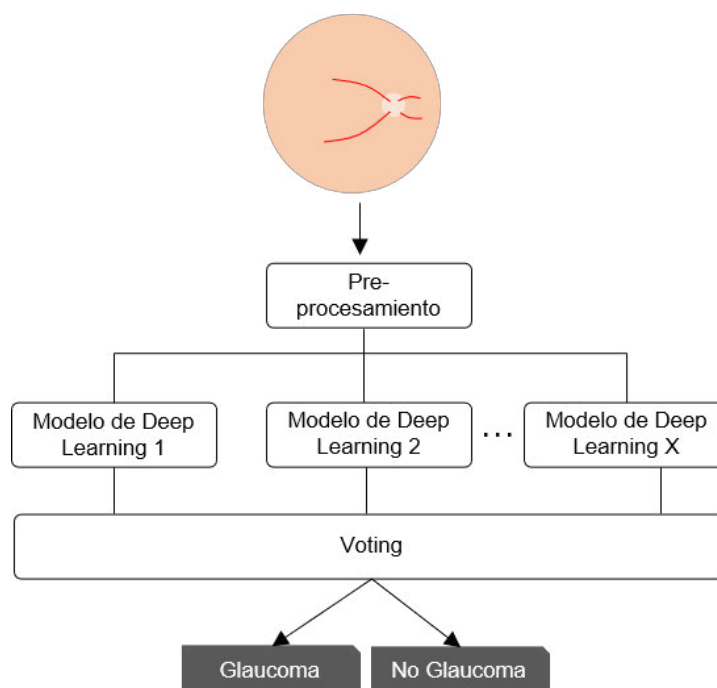


Figura 4.9. Esquema de criterio de votación

Fuente: Elaboración propia.

### 4.2.6. Interpretación y evaluación

En esta etapa, se evaluarán los resultados de los modelos haciendo uso de la matriz de confusión (Deng et al., 2016), considerando, las métricas de rendimiento en cuestión de especificidad, sensibilidad y precisión, que son estadísticas típicamente utilizadas en el análisis de imágenes médicas (Bland, 2015), por lo cual son métricas usadas para el rendimiento de los modelos clasificadores de imágenes de glaucoma (Ahn et al., 2018; Chai et al., 2018; Diaz-Pinto et al.,

2019; Hemelings et al., 2020; Raghavendra et al., 2018) Primero, se construye la matriz de confusión (ver Tabla4.3) basado en lo siguiente:

**VP:** Cuando una imagen con glaucoma se clasifica correctamente, se denomina un verdadero positivo.

**VN:** Una imagen normal clasificada correctamente se denomina un verdadero negativo.

**FN:** Cuando una imagen con glaucoma se clasifica como normal, se denomina falso negativo.

**FP:** Cuando una imagen normal se clasifica como glaucoma, se denomina falso positivo.

Matriz de Confusión		Predicción	
		Glaucoma	Normal
Real	Glaucoma	VP	FN
	Normal	FP	VN

Tabla 4.3. Matriz de confusión para la obtención de métricas

A seguir, se determina el valor de las métricas como sigue:

**La Sensibilidad (Sen)** indica el porcentaje de imágenes de pacientes con glaucoma correctamente clasificadas y se define como:

$$\text{Sensibilidad} = \frac{VP}{VP+FN} \times 100\%$$

**La Especificidad (Esp)** es el porcentaje de imágenes de pacientes normales (sin glaucoma) clasificadas correctamente, y se define como:

$$\text{Especificidad} = \frac{VN}{VN+FP} \times 100\%$$

**La exactitud o accuracy (Acc)** es el porcentaje de imágenes (con y sin glaucoma) correctamente clasificados, calculado por:

$$\text{Accuracy} = \frac{VP+VN}{VP+FP+VN+FN} \times 100\%$$

# **CAPÍTULO 5: DESARROLLO DE LA HERRAMIENTA DE APOYO PARA EL DIAGNÓSTICO DEL GLAUCOMA**

En el presente capítulo, se describirá cómo se ha integrado el modelo de aprendizaje profundo en una herramienta web capaz de funcionar en diferentes dispositivos, en el cual el usuario tendrá un diseño ameno y facilidad de uso. A continuación, será descrita su arquitectura, funcionalidad del sistema y cada rol definido.

## **5.1. Descripción de la herramienta**

Se desarrollará una herramienta denominada Qhaway (que significa visión en quechua) que tendrá como objetivo principal el diagnóstico del glaucoma y como puntos secundarios su funcionamiento en cualquier plataforma y/o dispositivo que cuente con acceso a una cámara o explorador multimedia. En el anexo A se describe un manual de usuario del sistema Qhaway.

El alcance del sistema abarca lo siguiente:

- Disponibilizar la creación de usuarios y entrega de permisos acorde con los diferentes roles
- La subida de imágenes para el diagnóstico del glaucoma utilizando un modelo final pre-entrenado
- Generar vistas para los doctores sobre los pacientes que han sido registrados y diagnosticados en la herramienta.

## 5.2. Arquitectura de la herramienta

De acuerdo con los requerimientos funcionales, los cuales se identificaron acerca del sistema, este será desplegado en un entorno web. Además, este tendrá por arquitectura un esquema Cliente-Servidor. En el backend se utilizará el conocido lenguaje de programación Python siendo utilizado el framework Django. Por el lado del cliente se utilizarán Angular 8 para el diseño, SQLite3 para la base de datos, y la librería Keras que permite la implementación de los modelos de aprendizaje profundo para clasificar el glaucoma. La arquitectura está definida en la Figura 5.1.

Esta arquitectura está definida por la capa de visualización que solicita recursos y es el servidor el encargado de responder inmediatamente a sus solicitudes, esto quiere decir que el cliente se aleja del procesamiento del modelo haciéndolo ligero. La arquitectura del lado del cliente utiliza un patrón de diseño conocido como MVC (Modelo, Vista, Controlador). Este consiste en 3 capas, la lógica de acceso a los servicios, negocio y de presentación. El framework Django el cual hace uso de Python también hace uso de un patrón de diseño conocido como MTV (Model, Template y View) ‘Model’ para los accesos a la base de datos, ‘Template’ para la capa de presentación, este hace referencia a que qué datos son exhibidos o no en una web, y ‘View’ para la capa lógica de negocios, la cual encapsula toda la lógica que necesita el modelo. Para la implementación de esta herramienta, la capa ‘Template’ fue reemplazada por la capa llamada ‘Serializer’ la cual permite a los datos que son caracterizados como complejos, agrupamiento de consultas y modelos, sean transformados en diferentes datos nativos de Python los cuales pueden ser representados fácilmente en un XML, JSON u otro contenido. Estos serializadores brindan deserialización, esto permite que los datos que ya han sido analizados sean convertidos devuelta en complejos, todo esto después de haber validado en primer lugar los datos ingresados.



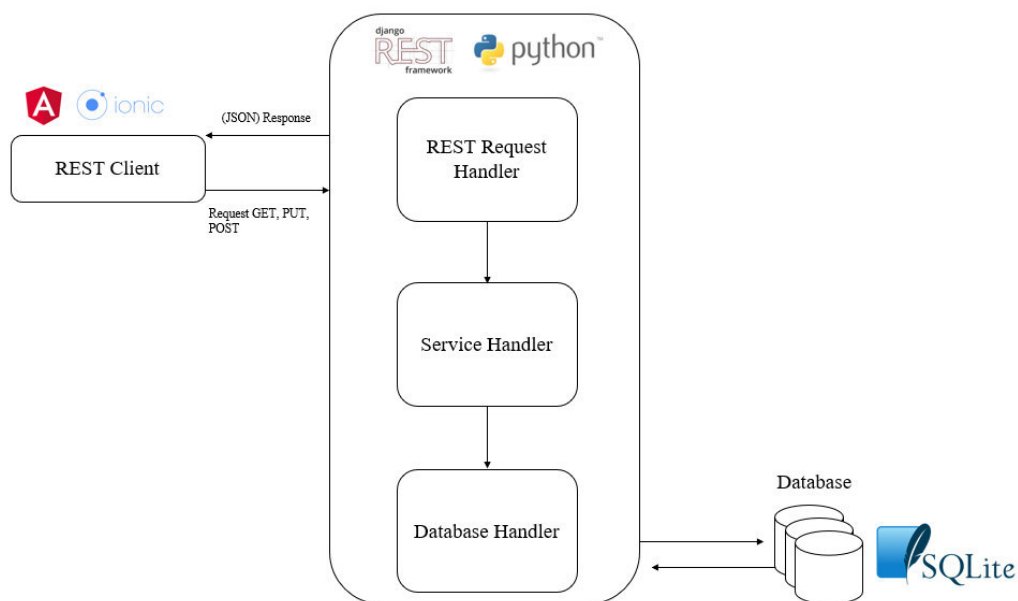


Figura 5.1. Diagrama de la arquitectura de la herramienta web

Fuente: Elaboración propia.

### 5.3. Estructura de datos

En el presente trabajo, se manejaron los datos con el ORM (Object-relational mapping) de Django, la cual es una herramienta poderosa y tal vez el punto más fuerte del framework debido a que facilita todo lo relacionado a las consultas, actualizaciones, eliminación y listas de todo lo almacenado en la base de datos de una forma más simple y compacta. Además, permite migrar con base en las clases creadas en el código en la Figura 5.2.




Figura 5.2. Diagrama Entidad-Relación de la herramienta de apoyo para el diagnóstico del glaucoma

Fuente: Elaboración propia.

Las imágenes utilizadas para el diagnóstico serán guardadas en la carpeta media del servidor de APIs. La imagen será identificada por el código del doctor, el código del paciente, el día, el mes, el año, la hora, el minuto y los segundos en el que comenzó el diagnóstico (Figura 5.3).




Figura 5.3. Estructura de una carpeta media en el servidor de la herramienta

Fuente: Elaboración propia.

## 5.4. Modelado de la herramienta

En esta etapa del modelado de la herramienta son descritos los usuarios del sistema, los casos de uso y las funcionalidades haciendo uso de las descritas interfaces de usuario que se han implementado. En la Figura 5.4, se puede visualizar la pantalla principal de la herramienta.

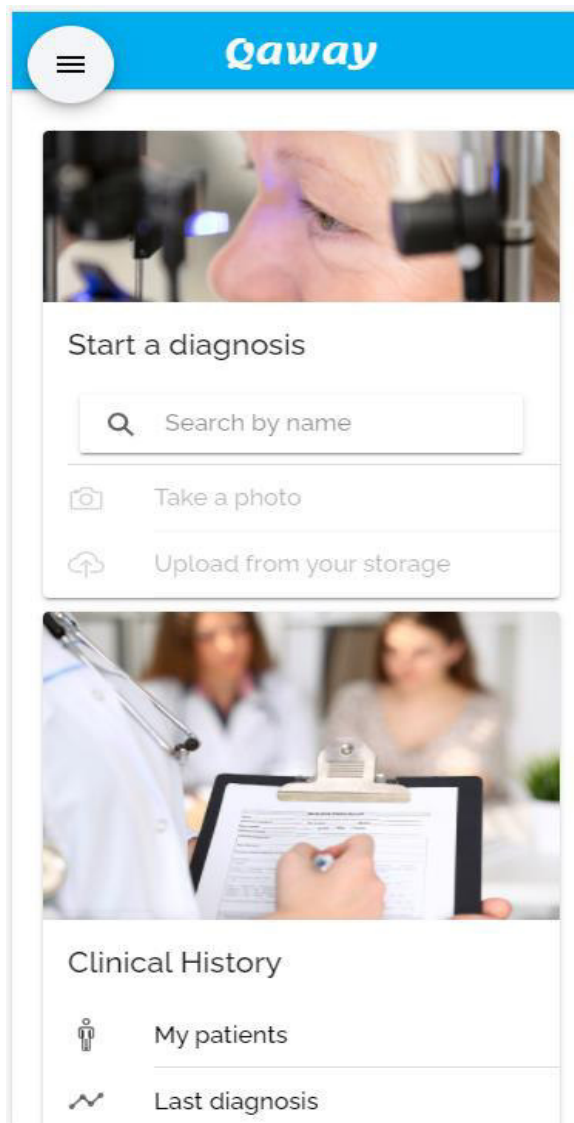


Figura 5.4. Interfaz para el diagnóstico del glaucoma

Fuente: Elaboración propia.

Usuarios de la herramienta

El sistema tendrá dos tipos de roles (Figura 5.5).

Usuario: Administrador

Descripción: Usuario que se encarga de la creación de usuarios para los demás roles, además de la gestión de información necesaria para la construcción de las vistas

Funciones:

- Crear usuarios para los demás roles, llenando los siguientes datos: Nombre, Apellido, Correo, Usuario, Contraseña, Edad, Puesto, Grado de instrucción
- Añadir, modificar y eliminar registros en la información sea Doctores, Usuarios, Pacientes,

Imágenes




Figura 5.5. Interfaz para crear, modificar y eliminar registros en el sistema

Fuente: Elaboración propia.

Usuario: Doctor (oftalmólogo)

Descripción: Usuario encargado de ejecutar el proceso para el diagnóstico del glaucoma, así como la revisión de pacientes y diagnósticos pasados

Funciones:

- Ejecutar flujo para el diagnóstico del glaucoma cargando una imagen al sistema para su procesamiento, por el modelo pre-entrenado y validado, el sistema, finalmente, mostrará el resultado y lo registrará para ser consultado más adelante (Figura 5.6).




Figura 5.6. Interfaz de resultado del diagnóstico

Fuente: Elaboración propia.

### 5.4.1. Requerimientos funcionales

Los requerimientos funcionales son prestaciones básicas que debe ofrecer el sistema alineados a la estrategia planteada en los casos de uso. A continuación, se encuentra la lista de requerimientos funcionales definidos por las necesidades del Usuario.

Código	Nombre	Descripción
RF001	Tomar o subir una foto de fondo de ojo.	El usuario con el perfil Doctor podrá acceder a la cámara de su dispositivo para poder tomar una foto. Además, podrá subir una foto que se encuentre en el dispositivo.
RF002	Mostrar un resultado que represente el diagnóstico de glaucoma basado en una imagen de fondo de ojo.	El usuario con el perfil Doctor podrá tomar o subir una imagen al sistema la cual al instante será procesada por el mismo. Al terminar de procesar el sistema mostrará un resultado Positivo o Negativo acorde su diagnóstico, además de mostrar datos generales del paciente y la probabilidad de predicción.
RF003	Crear usuario con diferentes roles.	El Super Administrador podrá crear usuarios de tipo Administrador para la creación y gestión de otros perfiles de usuario. El Super Administrador y Administrador podrán crear usuarios de tipo Doctor para permitir el uso de la herramienta. Este perfil contará con los siguientes datos: Nombres, Apellidos, Edad, Género y Especialidad. El Super Administrador y Administrador podrán crear usuarios de tipo Paciente para permitir su registro de resultados en la herramienta. Este perfil contará con los

		siguientes datos: Nombres, Apellidos, Edad y Género.
RF004	Registrar resultados del diagnóstico a un Paciente.	El usuario con el perfil Doctor podrá registrar los resultados del diagnóstico a un Paciente en específico guardando así un historial de sus resultados.
RF005	Visualizar histórico de resultados por Paciente.	El usuario con el perfil Doctor podrá visualizar el histórico de resultados de sus pacientes haciendo la búsqueda por Nombres y Apellidos. Este le mostrará datos generales del paciente, así como un histórico de las imágenes y los resultados.

Tabla 5.1. Requerimientos funcionales del sistema

#### 5.4.2. Requerimientos no funcionales

Los requerimientos no funcionales representan las restricciones del diseño y de la operación del sistema, donde se consideran atributos de calidad.

Código	Nombre	Descripción
RNF001	Usabilidad – operabilidad	El sistema deberá ser fácil de ser utilizado por una persona sin o con pocos conocimientos de informática.
RNF002	Eficiencia – comportamiento temporal	El sistema debe generar un diagnóstico de glaucoma en menos de 30 segundos, en tiempo real.
RNF003	Privacidad	El sistema no deberá capturar datos personales del usuario que superé los ya aceptados por el usuario en los términos y condiciones del uso de la herramienta.
RNF004	Procesamiento asíncrono	El proceso de entramiento y despliegue del modelo debe hacerse una sola vez, en modo fuera de línea y de manera asíncrona.
RNF005	Usabilidad – legibilidad	El sistema debe estar en idioma inglés.
RNF006	Usabilidad – operabilidad	El sistema debe ser accesible a través de cualquier tipo de dispositivo que

		tenga acceso a internet y un navegador web.
RNF007	Funcionalidad – seguridad de acceso	El acceso al sistema debe ser controlado usando usuario y contraseña.
RNF008	Funcionalidad – seguridad de acceso	El super administrador y administrador son los responsables y únicos autorizado para crear usuarios además de tener accesos totales al sistema.

Tabla 5.2. Requerimientos no funcionales del sistema

### 5.4.3. Lista de servicios

A continuación, se representa las componentes de tipo servicios que fueron implementadas del lado servidor de la herramienta las cuales contienen toda la lógica del negocio (Figura 5.7).

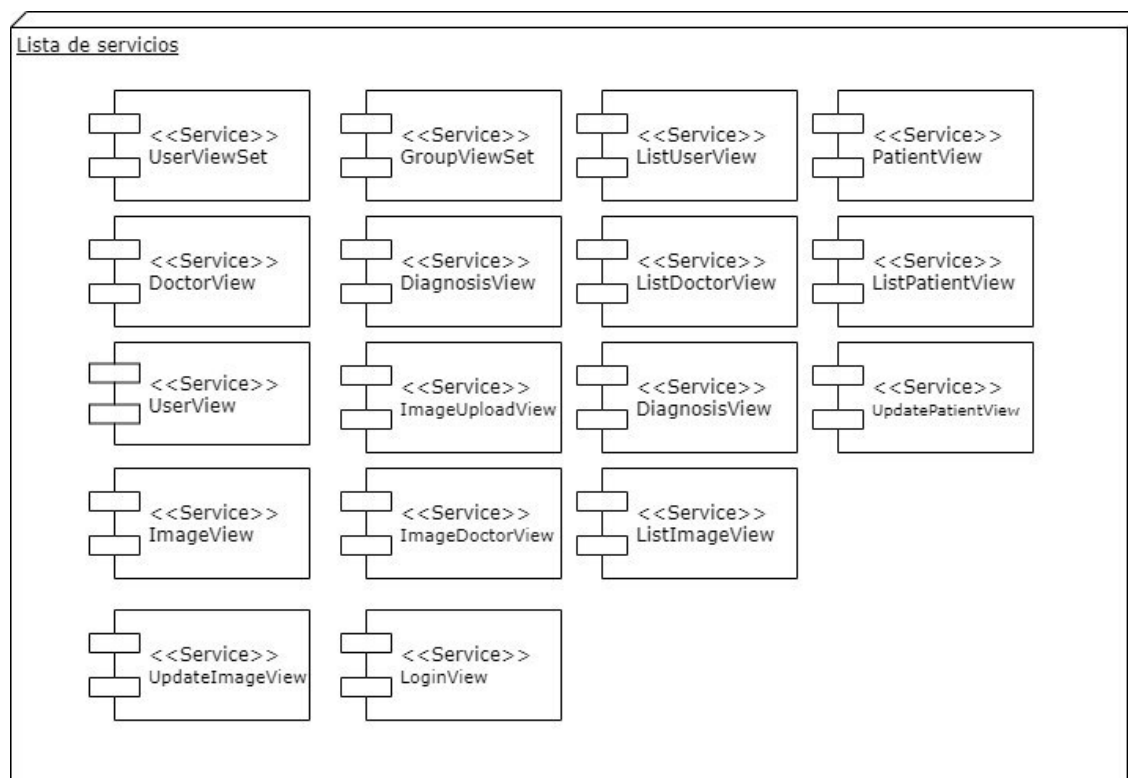


Figura 5.7. Diagrama de componentes de servicios de la herramienta

Fuente: Elaboración propia.



- UserViewSet

Este servicio se encarga de gestionar la creación de usuarios, así como de obtener como resultado la lista de estos. Permite crear usuarios al administrador de la herramienta.

Método GET: Permite obtener la lista de usuarios.

Método POST: Permite crear un usuario.

- GroupViewSet

Este servicio se encarga de gestionar la creación de grupos, así como de obtener como resultado la lista de estos. Permite crear grupos al administrador de la herramienta.

Método GET: Permite obtener la lista de grupos.

Método POST: Permite crear un grupo.

- ListUserView

Este servicio se encarga de obtener como resultado la lista de usuarios con todos sus datos.

Método GET: Permite obtener la lista de usuarios.

- PatientView

Este servicio se encarga de obtener como resultado la lista de pacientes con todos sus datos.

Permite a la herramienta obtener toda la lista de pacientes para poder ser seleccionado.

Método GET: Permite obtener un paciente en específico.

- DoctorView

Este servicio se encarga de obtener como resultado al doctor y sus datos. Permite a la herramienta obtener toda la información del doctor y mostrarla en su perfil.

Método GET: Permite obtener a un doctor en específico.

- `DiagnosisView`

Este servicio permite crear un diagnóstico y obtener la lista de diagnósticos. Para diagnosticar, se hace uso de los modelos pre-entrenados: DenseNet121, DenseNet169, ResNet50. Permite a la herramienta mostrar el diagnóstico de la imagen cargada al doctor. Este resultado del diagnóstico será un porcentaje de probabilidad.

Método GET: Permite obtener la lista de diagnósticos.

Método POST: Permite crear un diagnóstico.

- `ListDoctorView`

Este servicio se encarga de gestionar la creación de doctores, así como de obtener como resultado la lista de estos. Permite crear doctores al administrador de la herramienta.

Método GET: Permite obtener la lista de doctores.

Método POST: Permite crear un doctor.

- `ListPatientView`

Este servicio se encarga de gestionar la creación de doctores, así como de obtener como resultado la lista de estos. Permite crear doctores al administrador de la herramienta.

Método GET: Permite obtener la lista de pacientes.

Método POST: Permite crear un paciente.

- `UIView`

Este servicio se encarga de obtener como resultado al usuario y sus datos. Permite a la herramienta obtener toda la información del usuario y relacionarla con el doctor.

Método GET: Permite obtener a un usuario en específico.

- `ImageUploadView`

Este servicio se encarga de obtener como resultado todas las imágenes. Permite a la herramienta obtener toda la información de la imagen y relacionarla con el diagnóstico. Además, permite crear una imagen y guardarla en la media de la herramienta.

Método GET: Permite obtener la lista de imágenes.

Método POST: Permite crear una imagen.

- `DiagnosisView`

Este servicio se encarga de obtener como resultado todos los diagnósticos. Permite a la herramienta obtener toda la información de la imagen y relacionarla con el diagnóstico.

Método GET: Permite obtener la lista de diagnósticos.

Método POST: Permite crear un diagnóstico.

- `UpdatePatientView`

Este servicio se encarga de actualizar la fecha del último diagnóstico del paciente. Además, se lanza al momento del diagnóstico.

Método PATCH: Permite actualizar los datos del paciente.

- `ImageView`

Este servicio se encarga de obtener la lista de imágenes en específico por paciente.

Método GET: Permite obtener la lista de imágenes en específico por paciente.

- `ImageDoctorView`

Este servicio se encarga de obtener la lista de imágenes en específico por doctor.

Método GET: Permite obtener la lista de imágenes en específico por doctor.

- `ListImageView`

Este servicio se encarga de obtener la lista de imágenes sin ningún filtro.

Método GET: Permite obtener todas las imágenes.

- `UpdateImageView`

Este servicio se encarga de actualizar el diagnóstico de la imagen asociado al diagnóstico del paciente que fue tomado por un doctor en específico.

Método GET: Permite actualizar el diagnóstico asociado a una imagen.

- `LoginView`

Este servicio permite identificar si el usuario está correctamente autenticado en la herramienta.

Da como respuesta el id y el usuario del usuario que realizó la consulta.

Método GET: Permite obtener el id y el usuario que hace la consulta.

## **5.5. Implementación**

A continuación, se indica el lenguaje y el ambiente de entrenamiento que fueron utilizados para la construcción de la herramienta de apoyo para el diagnóstico del glaucoma.

### **5.5.1. Metodología de desarrollo**

Para el desarrollo de este proyecto se utilizó la metodología ágil Kanban. La metodología Kanban está descrita por un desarrollo visual el cual es utilizado para controlar tareas a través de una división por etapas hasta que esta culmine (Zayat & Senvar, 2020). Actualmente, este método de trabajo se ha convertido en una de las más conocidas dentro de las diferentes metodologías ágiles, las cuales tratan de administrar correctamente el trabajo y ajustarlo a las condiciones de cada proyecto.

Escogida para el desarrollo del proyecto, lo primero que se realiza es escribir las historias de usuario que se verán reflejadas en el Product Backlog de las cuales se determinan las principales historias que formarán parte de las siguientes iteraciones hasta completar todas las historias. Para visualizar estas historias se utilizó como herramienta de trabajo Trello la cual permite una implementación rápida de la estrategia de trabajo dentro de un tablero Kanban.

Fueron necesarias 4 iteraciones para cubrir la completitud de todas las tareas. Estas fueron revisadas en iteraciones de 2 semanas cada una. Se puede visualizar el detalle de cada tarea e iteración en la Figura 5.8.



Figura 5.8. Tareas del tablero Kanban

Fuente: Elaboración propia.

## 5.5.2. Lenguajes de programación

### 5.5.2.1. Python

Python es un lenguaje de programación orientado a objetos, interpretado y de alto nivel con semántica dinámica. Las estructuras de datos incorporadas de alto nivel, combinadas con la vinculación e importación dinámicas, lo hacen muy atractivo para rápido desarrollo de

aplicaciones, además de usarse como lenguaje de secuencias de comandos para integrar diferentes componentes. La sintaxis simple y fácil de aprender ayuda en la legibilidad y reduce el costo de mantenimiento del programa. Python además permite el uso de paquetes y módulos, fomentando la reutilización del código y la modularidad del programa. El intérprete de Python y la extensa biblioteca estándar están disponibles gratuitamente en formato fuente o binario para todas las plataformas.

### **5.5.2.2. TypeScript**

TypeScript es un lenguaje de código abierto construido sobre JavaScript, la cual se ha convertido en una herramienta de las más utilizadas. Se hizo famosa puesto que, al añadir definiciones de tipos estáticos, los cuales describen la forma de un objeto, brinda una mejor documentación y permite que TypeScript verifique antes de ser ejecutado que el código funcione de forma correcta.

## **5.6. Requisitos para el uso de la herramienta**

A continuación, se indica los requisitos tanto a nivel de Hardware y Software, estos son requisitos mínimos que permiten el correcto funcionamiento de la herramienta de apoyo para el diagnóstico del glaucoma.

### **5.6.1. Requisitos mínimos a nivel de hardware**

Debido al uso de modelos de aprendizaje profundo, para el despliegue de la herramienta se consideraron como mínimos los siguientes componentes:

- Capacidad de memoria RAM: 8 GB
- Procesador: AMD Ryzen 5 2400G 3.6 GHz
- Capacidad Disco Duro: 500 GB
- Tarjeta de video: RX560 4GB

### 5.6.2. Requisitos mínimos a nivel de software

En la implementación, fue decidido hacer uso, del lado del backend, el lenguaje de programación Python, esto puesto que es un lenguaje fácil de aprender y de utilizar, además este es multiplataforma por lo cual se puede usar tanto en máquinas que tengan el sistema operativo de Windows y Linux. Además, un factor muy importante es que este es Open Source.

Esta tecnología provee de muchas ventajas para un desarrollador de software, sobre cuando es utilizado con Django:

- Multiplataforma.
- Framework Modelo, Vista y Controlador
- ORM y QuerySets para manejar los datos

Por el lado de la interfaz del usuario, se decidió utilizar AngularJS e Ionic, las cuales contienen diversos componentes preconstruídos que permiten una fácil implementación de las diferentes interfaces de usuario.

Servidor propio para Django y Ionic

Lista de librerías utilizadas en Python:

- Django==3.1
- django-cors-headers==3.4.0
- djangorestframework==3.11.1
- Keras==2.4.3
- Keras-Preprocessing==1.1.2
- matplotlib==3.3.0
- numpy==1.18.5



- opencv-python==4.3.0.38
- pyparsing==2.4.7
- requests==2.24.0
- requests-oauthlib==1.3.0
- rsa==4.6
- scipy==1.4.1
- sqlparse==0.3.1
- tensorboard==2.2.2
- tensorboard-plugin-wit==1.7.0

### **5.6.3. Requisitos mínimos a imágenes de fondo de ojo**

Para un correcto funcionamiento de Qhaway, se recomienda tener los siguientes requisitos mínimos.

- Imagen de densidad mínima de pixeles de 400 DPI.
- Tamaño mínimo de 350 x 350 px

# CAPÍTULO 6: ENTRENAMIENTO Y VALIDACIÓN DEL MODELO DE APRENDIZAJE PROFUNDO PARA EL DIAGNÓSTICO DEL GLAUCOMA

En el presente capítulo, se muestra la validación de los 24 modelos propuestos, mediante los data sets de HRF (Kohler et al., 2013), Drishti-GS1 (Chakravarty & Sivaswamy, 2016), sjchoi86-HRF (Abbas, 2017), RIM-ONE (Medina-Mesa et al., 2016), ACRIMA (Diaz-Pinto et al., 2019), además de la aplicación 5 modelos híbridos generados bajo el criterio de votación.

## 6.1. Diseño de validación

La validación considera tres escenarios que se diferencian en el incremento del data set de entrenamiento, con el fin de mostrar el comportamiento de los resultados cuando esto se incrementa, además los modelos de DL necesitan grandes conjuntos de datos como muchos autores afirman (Zheng et al., 2019):

- **Primer escenario**, se contempla entrenar los modelos con cada data set por separado (Figura 6a) con el fin de reproducir resultados antes obtenidos en la literatura.
- **Segundo escenario**, se entrenan los modelos con los data sets de HRF y sjchoi86-HRF unificados, los pesos obtenidos se utilizan para entrenar el modelo con el dataset de resultado de la unión de Drishti-GS1 y RIM-ONE, para, usar estos pesos en el entrenamiento del modelo con el data set de ACRIMA (Figura 6b), esto para mostrar que al incrementar los datos en el proceso de aprendizaje se mejorarán los resultados.

- **Tercer escenario**, se entrena los modelos con todos los data sets unificados (Figura 6c), con la finalidad de mostrar que al incrementar los datos en el proceso de aprendizaje de mejorarán los resultados, es decir debemos obtener mejores resultados que en los escenarios 1 y 2.

Los tres escenarios se pueden visualizar en la Figura 6.1

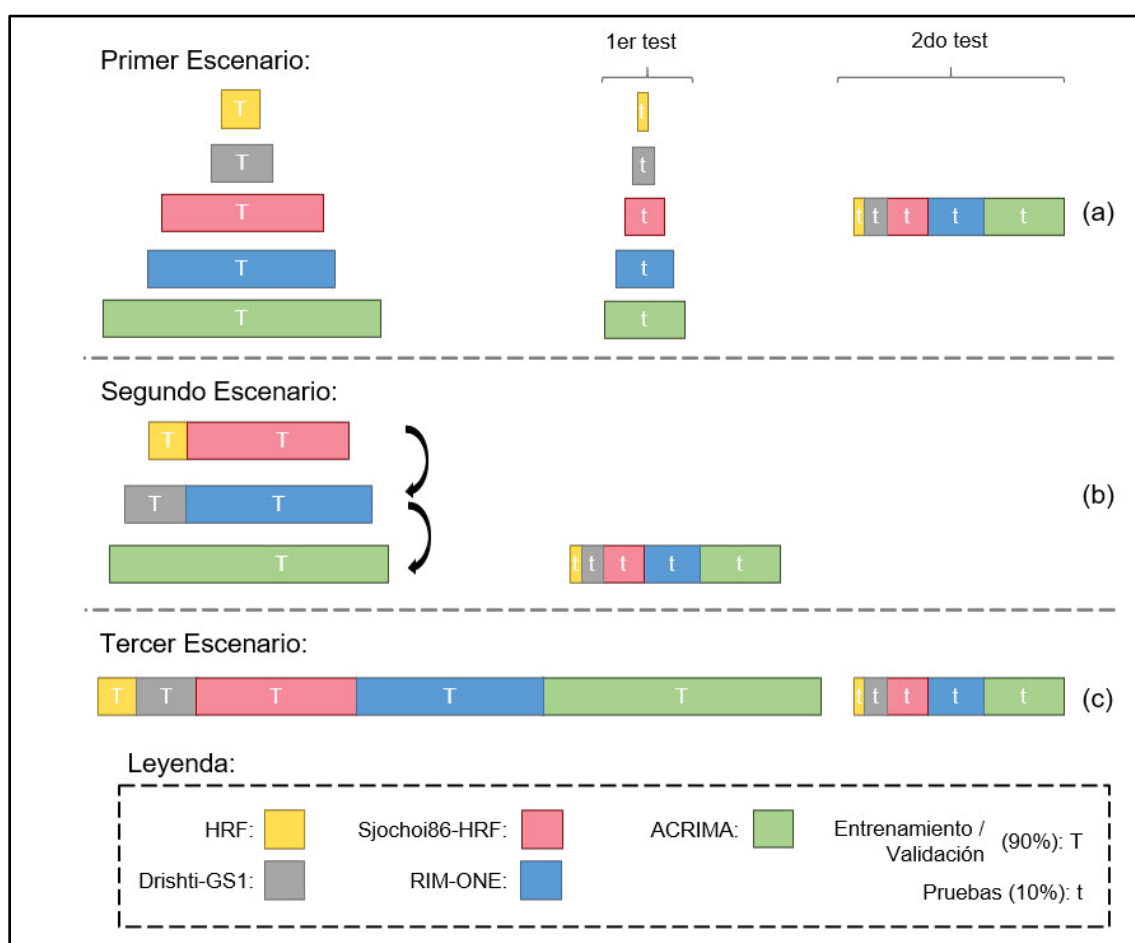


Figura 6.1. Esquema de entrenamiento del generador de modelos

Fuente: Elaboración propia.

Además, para el entrenamiento de los modelos de DL, se contempla un conjunto de experimentos, que parten del planteamiento de los escenarios que se ejecutan de manera secuencial siguiendo el esquema de la Figura 6.2. Estos experimentos consideran la calibración de parámetros y el entrenamiento secuencial de cada uno de los 24 modelos tomando en cuenta la técnica de validación cruzada de 10 folds (Figura 6.3).

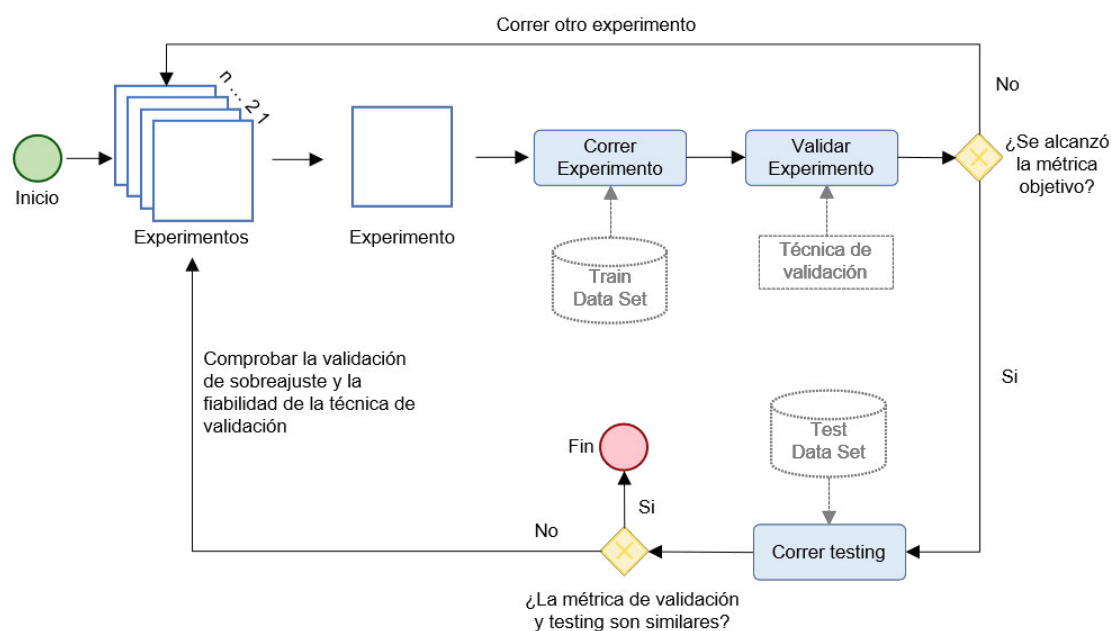


Figura 6.2. Esquema de entrenamiento del generador de modelos

Fuente: Elaboración propia.

Fuente: Elaboración propia.




Figura 6.3. Esquema de validación cruzada de 10 folds

Fuente: Elaboración propia.

## 6.2. Ambiente de entrenamiento y validación

### 6.2.1. Ambiente de entrenamiento

- RAM: 25 GB
- CPU Xeon 2.3 GHz
- GPU Nvidia Tesla V100 16GB
- Disco duro: 100 GB
- Python 3.6
- TensorFlow 2.4.0

### 6.2.2. Ambiente de validación

- RAM: 8 GB
- CPU Ryzen 1700x 3.4 GHz
- GPU Nvidia Gtx 1050 ti 4GB
- Disco duro 500 GB
- Python 3.6
- TensorFlow 2.4.0

### 6.3. Instancias de pruebas

Se tiene un total de 1707 imágenes del fondo de ojo conformados por 5 data sets (Tabla 6.1), tales como HRF (Kohler et al., 2013), Drishti-GS1 (Chakravarty & Sivaswamy, 2016), sjchoi86-HRF (Abbas, 2017), RIM-ONE (Medina-Mesa et al., 2016), ACRIMA (Diaz-Pinto et al., 2019).

Data Set	Imágenes	Resolución
HRF	45 (27 glaucoma y 18 normal)	3504x2336 px
Drishti-GS1	101 (70 glaucoma y 31 normal)	2896x1944 px
sjchoi86-HRF	401 (101 glaucoma y 300 normal)	2592x1728, 2464x1632 or 1848x1224 px
RIM-ONE	455 (194 glaucoma y 261 normal)	478 x 436 or 2144x1424 px
ACRIMA	705 (396 glaucoma y 309 normal)	2048x1536 px

Tabla 6.1. Data sets encontrados en la literatura

Para poder ver los atributos completos de cada data, se puede acceder a los enlaces presentes en la Tabla 6.2.

Data Set	URL
HRF	<a href="https://www5.cs.fau.de/research/data/fundus-images/">https://www5.cs.fau.de/research/data/fundus-images/</a>
Drishti-GS1	<a href="https://cvit.iiit.ac.in/projects/mip/drishti-gs/mip-dataset2/Home.php">https://cvit.iiit.ac.in/projects/mip/drishti-gs/mip-dataset2/Home.php</a>
sjchoi86-HRF	<a href="https://github.com/yiweichen04/retina_dataset/tree/master/dataset">https://github.com/yiweichen04/retina_dataset/tree/master/dataset</a>
RIM-ONE	<a href="http://medimrg.webs.ull.es/research/retinal-imaging/rim-one/">http://medimrg.webs.ull.es/research/retinal-imaging/rim-one/</a>
ACRIMA	<a href="https://figshare.com/authors/Andres_Diaz-Pinto/5959346">https://figshare.com/authors/Andres_Diaz-Pinto/5959346</a>

Tabla 6.2. Información de origen de cada conjunto de datos

### 6.3.1. Preparación de datos

Se consideró, para los datos de entrenamiento, validación y pruebas para cada escenario, las proporciones son detalladas en la Tabla 6.3, donde cada imagen será redimensionada según el tamaño por defecto de la capa de entrada de cada modelo (ver Tabla 4.2)

Escenario	Data Set	Entrenamiento (81%)	Validación (9%)	Pruebas (10%)
1	HRF	36	4	5
	Drishti-GS1	82	9	10
	sjchoi86-HRF	325	36	40
	RIM-ONE	369	41	46
	ACRIMA	571	63	71
2	HRF + sjchoi86-HRF	361	40	45
	Drishti-GS1 + RIM-ONE	450	50	56
	ACRIMA	571	63	71
3	Todos los data sets	1383	154	171

Tabla 6.3. Tabla de división de datos para cada escenario

### 6.3.2. Instancias de pruebas para el entrenamiento, validación y pruebas

La Tabla 6.4 muestra la cantidad de instancias (imágenes del fondo de ojo) para el entrenamiento, validación y prueba, considerando imágenes etiquetadas como “glaucoma” y “normal”.

Escenario	Data Set	Entrenamiento (81%)		Validación (9%)		Pruebas (10%)	
		Glaucoma	Normal	Glaucoma	Normal	Glaucoma	Normal
1	HRF	22	15	2	2	3	2
	Drishti-GS1	57	25	6	3	7	3
	sjchoi86-HRF	82	243	9	27	10	30
	RIM-ONE	157	211	17	23	19	26
	ACRIMA	321	250	36	28	40	31
2	HRF + sjchoi86-HRF	104	258	12	29	13	32
	Drishti-GS1 + RIM-ONE	214	237	24	26	26	29
	ACRIMA	321	250	36	28	40	31
3	Todos los data sets	638	744	71	82	79	92

Tabla 6.4. Instancias para el entrenamiento, validación y pruebas

## 6.4. Métricas

Para medir el rendimiento de la clasificación entre imágenes del fondo de ojo con glaucoma y sin glaucoma, se usan las métricas de rendimiento en términos de sensibilidad, especificidad y precisión, que son estadísticas típicamente utilizadas en el análisis de imágenes médicas (Bland, 2015), cuya definición y cálculo se encuentran en la sección 4.2.6.

## 6.5. Entrenamiento de los modelos de aprendizaje profundo

Se presentan los experimentos contemplados para la validación de los 24 modelos de aprendizaje profundo. Para identificar cada modelo, se usa la nomenclatura “NombreModelo\_m1”, si se trata del primer tipo de fine tuning (Figura 4.7.a), y NombreModelo\_m2”, si se trata del segundo tipo de fine tuning (Figura 4.7.b).

### 6.5.1. Definir configuración de experimentos

Se definen la configuración de los experimentos, es decir la configuración (bach size, learning rate, épocas) para cada uno de los 24 modelo definidos en la sección 6.5 y en cada uno de los tres escenarios, con el objetivo de obtener los modelos con el mejor rendimiento. Los experimentos y parámetros para el primer, segundo y tercer escenario se pueden ver en la Tabla 6.6, Tabla 6.7 y Tabla 6.8, respectivamente. El número total de experimentos es de 72, que se obtiene de 24 modelos en 3 escenarios.

Modelo	HRF & Drishti			Sjchoi86-HRF & RIM & ACRIMA		
	Bach size	Learning rate	Épocas	Bach size	Learning rate	Épocas
DenseNet121_m1	1	1e-4	100	8	1e-4	100
DenseNet121_m2	1	1e-4	100	8	1e-4	100
DenseNet169_m1	1	1e-4	100	8	1e-4	100
DenseNet169_m2	1	1e-4	100	8	1e-4	100



InceptionV3_m1	1	1e-4	100	8	1e-4	100
InceptionV3_m2	1	1e-4	100	8	1e-4	100
MobileNet_m1	1	1e-4	100	8	1e-4	100
MobileNet_m2	1	1e-4	100	8	1e-4	100
MobileNetV2_m1	1	1e-4	100	8	1e-4	100
MobileNetV2_m2	1	1e-4	100	8	1e-4	100
NASNetMobile_m1	1	1e-4	100	8	1e-4	100
NASNetMobile_m2	1	1e-4	100	8	1e-4	100
ResNet101_m1	1	1e-4	100	8	1e-4	100
ResNet101_m2	1	1e-4	100	8	1e-4	100
ResNet50_m1	1	1e-4	100	8	1e-4	100
ResNet50_m2	1	1e-4	100	8	1e-4	100
ResNet50V2_m1	1	1e-4	100	8	1e-4	100
ResNet50V2_m2	1	1e-4	100	8	1e-4	100
VGG16_m1	1	1e-4	100	8	1e-4	100
VGG16_m2	1	1e-4	100	8	1e-4	100
VGG19_m1	1	1e-4	100	8	1e-4	100
VGG19_m2	1	1e-4	100	8	1e-4	100
Xception_m1	1	1e-4	100	8	1e-4	100
Xception_m2	1	1e-4	100	8	1e-4	100

Tabla 6.5. Experimentos definidos en para el primer escenario

Data Set	Modelo	Bach size	Learning rate	Épocas
HRF + Sjchoi86-HRF & Drishti + RIM & ACRIMA	DenseNet121_m1	8	1e-4	100
	DenseNet121_m2	8	1e-4	100
	DenseNet169_m1	8	1e-4	100
	DenseNet169_m2	8	1e-4	100
	InceptionV3_m1	8	1e-4	100
	InceptionV3_m2	8	1e-4	100
	MobileNet_m1	8	1e-4	100
	MobileNet_m2	8	1e-4	100
	MobileNetV2_m1	8	1e-4	100
	MobileNetV2_m2	8	1e-4	100
	NASNetMobile_m1	8	1e-4	100
	NASNetMobile_m2	8	1e-4	100
	ResNet101_m1	8	1e-4	100
	ResNet101_m2	8	1e-4	100
	ResNet50_m1	8	1e-4	100
	ResNet50_m2	8	1e-4	100
	ResNet50V2_m1	8	1e-4	100
	ResNet50V2_m2	8	1e-4	100
	VGG16_m1	8	1e-4	100
	VGG16_m2	8	1e-4	100
VGG19_m1	8	1e-4	100	
VGG19_m2	8	1e-4	100	
Xception_m1	8	1e-4	100	
Xception_m2	8	1e-4	100	

Tabla 6.6. Experimentos definidos en para el segundo escenario

Data Set	Modelo	Bach size	Learning rate	Épocas
HRF + Sjchoi86-HRF + Drishti + RIM + ACRIMA	DenseNet121_m1	8	1e-4	200
	DenseNet121_m2	8	1e-4	200
	DenseNet169_m1	8	1e-4	200
	DenseNet169_m2	8	1e-4	200
	InceptionV3_m1	8	1e-4	200
	InceptionV3_m2	8	1e-4	200
	MobileNet_m1	8	1e-4	200
	MobileNet_m2	8	1e-4	200
	MobileNetV2_m1	8	1e-4	200
	MobileNetV2_m2	8	1e-4	200
	NASNetMobile_m1	8	1e-4	200
	NASNetMobile_m2	8	1e-4	200
	ResNet101_m1	8	1e-4	200
	ResNet101_m2	8	1e-4	200
	ResNet50_m1	8	1e-4	200
	ResNet50_m2	8	1e-4	200
	ResNet50V2_m1	8	1e-4	200
	ResNet50V2_m2	8	1e-4	200
	VGG16_m1	8	1e-4	200
	VGG16_m2	8	1e-4	200
VGG19_m1	8	1e-4	200	
VGG19_m2	8	1e-4	200	
Xception_m1	8	1e-4	200	
Xception_m2	8	1e-4	200	

Tabla 6.7. Experimentos definidos en para el tercer escenario

### 6.5.2. Ejecutar experimento

Los experimentos se ejecutan de acuerdo con la configuración de los experimentos dados en 6.5.1. Considerando que existen 3 escenarios, con 24 modelos de aprendizaje profundo y cada uno contempla una validación cruzada de 10 folds (significa ejecutar el entrenamiento 10 veces por cada modelo), lo cual hace un total de 720 ejecuciones. El total de los modelos de aprendizaje profundo planteados en esta tesis se entrenaron en Google Colaboratory (Carneiro et al., 2018). Además, se han considerado 5 modelos híbridos de acuerdo a los señalado en la sección 4.2.5, estos corresponden a criterio de Voting sobre los modelos que presentan mejores rendimientos, denotándose como Voting-3, Voting-5, Voting-7, Voting-9 y Voting-11 que corresponden al criterio Voting sobre los 3, 5, 7, 9, y 11 modelos con mejores resultados respectivamente.

## 6.6. Resultados

### 6.6.1. Escenario 1

A seguir se muestran los resultados del escenario 1, es decir los resultados para cada uno de los data set.

#### 6.6.1.1. HRF

Los resultados de los 24 modelos y los 5 modelos híbridos entrenados con el dataset de HRF se muestran en la Tabla 6.8.

N°	Model	Escenario 1 - Test HRF		
		Acc	Sens	Esp
1	DenseNet121_m1	80.00%	100.00%	66.67%
2	DenseNet121_m2	60.00%	100.00%	33.33%
3	DenseNet169_m1	60.00%	50.00%	66.67%
4	DenseNet169_m2	60.00%	100.00%	33.33%
5	InceptionV3_m1	60.00%	50.00%	66.67%
6	InceptionV3_m2	60.00%	100.00%	33.33%
7	MobileNet_m1	60.00%	100.00%	33.33%
8	MobileNet_m2	60.00%	100.00%	33.33%
9	MobileNetV2_m1	60.00%	0.00%	100.00%
10	MobileNetV2_m2	60.00%	50.00%	66.67%
11	NASNetMobile_m1	60.00%	100.00%	33.33%
12	NASNetMobile_m2	60.00%	0.00%	100.00%
13	ResNet101_m1	80.00%	50.00%	100.00%
14	ResNet101_m2	60.00%	100.00%	33.33%
15	ResNet50_m1	80.00%	50.00%	100.00%
16	ResNet50_m2	60.00%	100.00%	33.33%
17	ResNet50V2_m1	80.00%	100.00%	66.67%
18	ResNet50V2_m2	80.00%	100.00%	66.67%
19	VGG16_m1	60.00%	0.00%	100.00%
20	VGG16_m2	40.00%	100.00%	0.00%
21	VGG19_m1	60.00%	50.00%	66.67%
22	VGG19_m2	40.00%	100.00%	0.00%
23	Xception_m1	60.00%	50.00%	66.67%
24	Xception_m2	60.00%	50.00%	66.67%
25	Voting 3	100.00%	100.00%	100.00%
26	Voting 5	80.00%	100.00%	66.67%
27	Voting 7	80.00%	100.00%	66.67%
28	Voting 9	80.00%	100.00%	66.67%
29	Voting 11	80.00%	100.00%	66.67%

Tabla 6.8. Resultados del test del primer escenario de los modelos entrenados con HRF

Uno de los mejores resultados se obtiene con el modelo ResNet50V2\_m2 que con el data set HRF obtiene 80% de accuracy y 100% de sensibilidad, pero es superado ampliamente por el modelo híbrido formado a partir de DenseNet121\_m1, ResNet101\_m1 y ResNet50\_m1. En la Figura 6.4. se observa la comparación de los rendimientos de los 24 modelos y los 5 modelos híbridos.




Figura 6.4. Comparación de resultados del test de HRF

Fuente: Elaboración propia.

Además, se realizó el test de estos modelos sobre los datos de prueba del tercer escenario, de donde se obtuvo los resultados de la Tabla 6.9.

		<b>Escenario 1 HRF - Test All Data Set</b>		
<b>N°</b>	<b>Model</b>	<b>Acc</b>	<b>Sens</b>	<b>Esp</b>
1	DenseNet121_m1	58.62%	70.93%	46.59%
2	DenseNet121_m2	68.39%	59.30%	77.27%
3	DenseNet169_m1	49.43%	91.86%	7.95%
4	DenseNet169_m2	71.84%	82.56%	61.36%
5	InceptionV3_m1	50.57%	23.26%	77.27%
6	InceptionV3_m2	51.15%	19.77%	81.82%
7	MobileNet_m1	49.43%	98.84%	1.14%
8	MobileNet_m2	64.37%	74.42%	54.55%
9	MobileNetV2_m1	51.72%	5.81%	96.59%
10	MobileNetV2_m2	59.77%	44.19%	75.00%

11	NASNetMobile_m1	47.70%	87.21%	9.09%
12	NASNetMobile_m2	49.43%	100.00%	0.00%
13	ResNet101_m1	51.15%	1.16%	100.00%
14	ResNet101_m2	57.47%	30.23%	84.09%
15	ResNet50_m1	58.62%	37.21%	79.55%
16	ResNet50_m2	58.62%	44.19%	72.73%
17	ResNet50V2_m1	50.00%	63.95%	36.36%
18	ResNet50V2_m2	57.47%	70.93%	44.32%
19	VGG16_m1	55.17%	9.30%	100.00%
20	VGG16_m2	49.43%	100.00%	0.00%
21	VGG19_m1	60.92%	67.44%	54.55%
22	VGG19_m2	49.43%	100.00%	0.00%
23	Xception_m1	50.00%	98.84%	2.27%
24	Xception_m2	48.28%	19.77%	76.14%
25	Voting 3	59.20%	27.91%	89.77%
26	Voting 5	57.47%	48.84%	65.91%
27	Voting 7	63.22%	69.77%	56.82%
28	Voting 9	62.07%	51.16%	72.73%
29	Voting 11	61.49%	38.37%	84.09%

Tabla 6.9. Resultados del test del tercer escenario de los modelos entrenados con HRF

Los resultados disminuyen considerablemente, en comparación con los datos de la Tabla 6.8. Se observa que los mejores modelos, MobileNet\_m2, ahora presenta un accuracy de 64.37% y una sensibilidad de 74.42%. En la Figura 6.5, se muestra la comparación de los rendimientos.

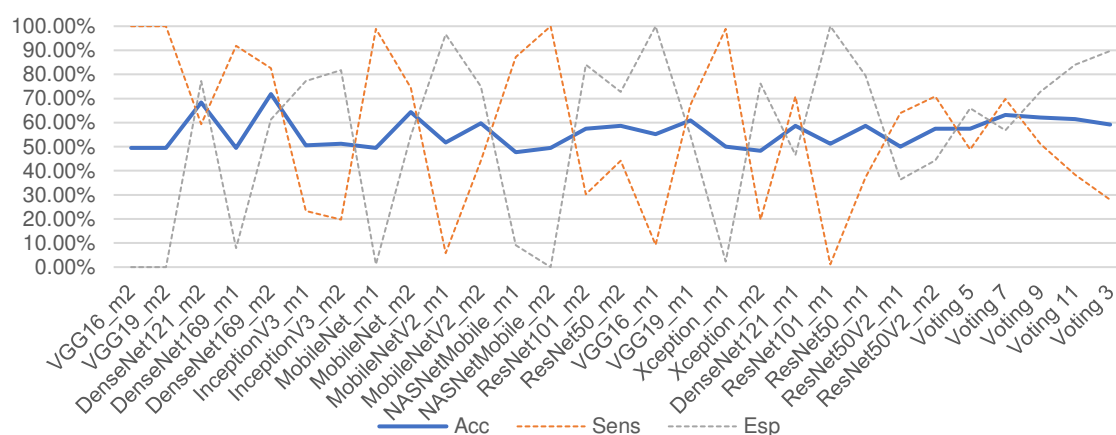


Figura 6.5. Resultados de test del tercer escenario para los modelos entrenados con HRF

Fuente: Elaboración propia.

### 6.6.1.2. Drishti

Los resultados de los 24 modelos y 5 modelos híbridos entrenados con el data set Drishti se muestran en la Tabla 6.10.

N°	Model	Escenario 1 - Test Drishti		
		Acc	Sens	Esp
1	DenseNet121_m1	72.73%	100.00%	0.00%
2	DenseNet121_m2	72.73%	100.00%	0.00%
3	DenseNet169_m1	54.55%	62.50%	33.33%
4	DenseNet169_m2	72.73%	87.50%	33.33%
5	InceptionV3_m1	72.73%	87.50%	33.33%
6	InceptionV3_m2	72.73%	75.00%	66.67%
7	MobileNet_m1	63.64%	62.50%	66.67%
8	MobileNet_m2	90.91%	100.00%	66.67%
9	MobileNetV2_m1	54.55%	37.50%	100.00%
10	MobileNetV2_m2	72.73%	100.00%	0.00%
11	NASNetMobile_m1	54.55%	75.00%	0.00%
12	NASNetMobile_m2	72.73%	87.50%	33.33%
13	ResNet101_m1	54.55%	50.00%	66.67%
14	ResNet101_m2	72.73%	75.00%	66.67%
15	ResNet50_m1	54.55%	50.00%	66.67%
16	ResNet50_m2	72.73%	75.00%	66.67%
17	ResNet50V2_m1	54.55%	62.50%	33.33%
18	ResNet50V2_m2	63.64%	75.00%	33.33%
19	VGG16_m1	81.82%	100.00%	33.33%
20	VGG16_m2	72.73%	100.00%	0.00%
21	VGG19_m1	72.73%	100.00%	0.00%
22	VGG19_m2	72.73%	100.00%	0.00%
23	Xception_m1	72.73%	100.00%	0.00%
24	Xception_m2	81.82%	87.50%	66.67%
25	Voting 3	90.91%	100.00%	66.67%
26	Voting 5	81.82%	100.00%	33.33%
27	Voting 7	81.82%	100.00%	33.33%
28	Voting 9	81.82%	100.00%	33.33%
29	Voting 11	81.82%	100.00%	33.33%

Tabla 6.10. Resultados del test del primer escenario de los modelos entrenados con Drishti

Uno de los mejores resultados se obtiene con el modelo MobileNet\_m2 y el modelo híbrido compuesto por Xception\_m2, Xception\_m1 y VGG16\_M1. En la Figura 6.6, se observa la comparación de los rendimientos de los 24 modelos y los 5 modelos híbridos.

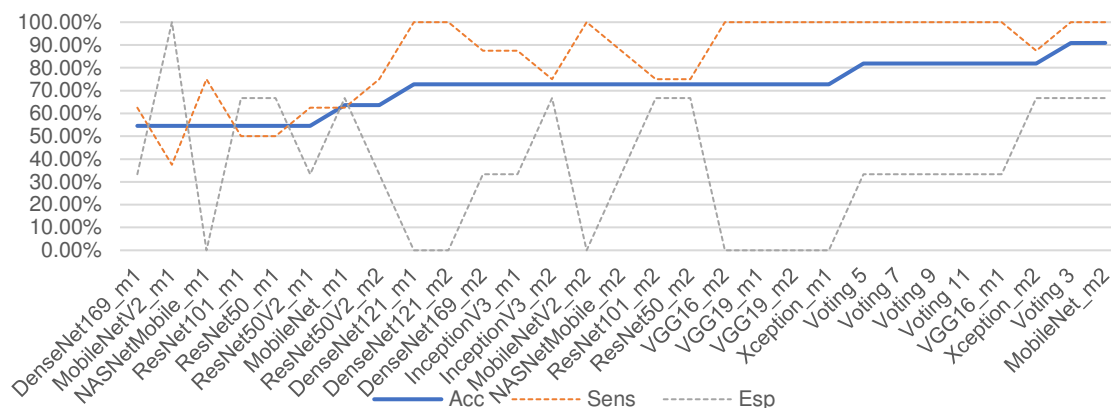


Figura 6.6. Comparación de resultados del test de Drishti

Fuente: Elaboración propia.

Además, se realizó el test de estos modelos sobre los datos de prueba del tercer escenario, de donde se obtuvieron los resultados de la Tabla 6.11.

		<b>Escenario 1 Drishti - Test All Data Set</b>		
<b>N°</b>	<b>Model</b>	<b>Acc</b>	<b>Sens</b>	<b>Esp</b>
1	DenseNet121_m1	54.02%	91.86%	17.05%
2	DenseNet121_m2	50.00%	97.67%	3.41%
3	DenseNet169_m1	58.05%	24.42%	90.91%
4	DenseNet169_m2	59.20%	65.12%	53.41%
5	InceptionV3_m1	55.75%	59.30%	52.27%
6	InceptionV3_m2	58.62%	79.07%	38.64%
7	MobileNet_m1	52.87%	37.21%	68.18%
8	MobileNet_m2	62.64%	53.49%	71.59%
9	MobileNetV2_m1	52.87%	4.65%	100.00%
10	MobileNetV2_m2	52.30%	95.35%	10.23%
11	NASNetMobile_m1	52.87%	75.58%	30.68%
12	NASNetMobile_m2	57.47%	19.77%	94.32%
13	ResNet101_m1	52.87%	13.95%	90.91%
14	ResNet101_m2	64.37%	84.88%	44.32%
15	ResNet50_m1	55.75%	11.63%	98.86%
16	ResNet50_m2	68.97%	55.81%	81.82%
17	ResNet50V2_m1	56.32%	37.21%	75.00%
18	ResNet50V2_m2	70.69%	60.47%	80.68%
19	VGG16_m1	70.69%	48.84%	92.05%
20	VGG16_m2	49.43%	100.00%	0.00%
21	VGG19_m1	69.54%	63.95%	75.00%

22	VGG19_m2	49.43%	100.00%	0.00%
23	Xception_m1	50.00%	100.00%	1.14%
24	Xception_m2	63.79%	56.98%	70.45%
25	Voting 3	68.39%	55.81%	80.68%
26	Voting 5	67.82%	79.07%	56.82%
27	Voting 7	67.24%	67.44%	67.05%
28	Voting 9	65.52%	81.40%	50.00%
29	Voting 11	68.39%	80.23%	56.82%

Tabla 6.11. Resultados del test del tercer escenario de los modelos entrenados con Drishti

Los resultados disminuyen considerablemente, en comparación con los datos de la Tabla 6.10. En la Figura 6.7, se muestra la comparación de los rendimientos.

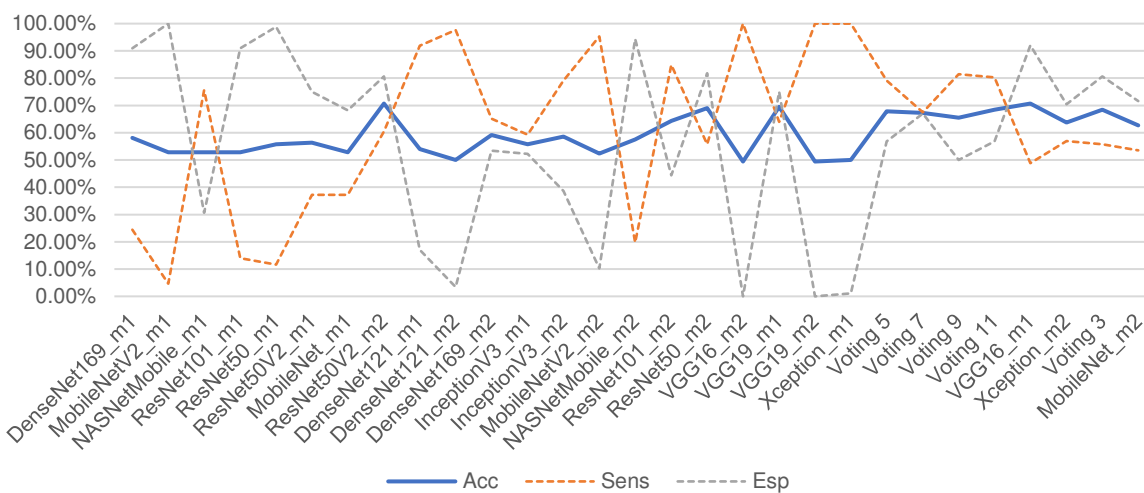


Figura 6.7. Resultados de test del tercer escenario de los modelos entrenados con Drishti

Fuente: Elaboración propia.



### 6.6.1.3. Sjchoi86-HRF

Los resultados de los 24 modelos y 5 modelos híbridos entrenados con el data set Sjchoi86-HRF se muestran en la Tabla 6.12.

N°	Model	Escenario 1 - Test Sjchoi86-HRF		
		Acc	Sens	Esp
1	DenseNet121_m1	85.37%	80.00%	87.10%
2	DenseNet121_m2	90.24%	90.00%	90.32%
3	DenseNet169_m1	80.49%	90.00%	77.42%
4	DenseNet169_m2	87.80%	70.00%	93.55%
5	InceptionV3_m1	90.24%	80.00%	93.55%
6	InceptionV3_m2	90.24%	70.00%	96.77%
7	MobileNet_m1	90.24%	80.00%	93.55%
8	MobileNet_m2	85.37%	70.00%	90.32%
9	MobileNetV2_m1	82.93%	70.00%	87.10%
10	MobileNetV2_m2	85.37%	90.00%	83.87%
11	NASNetMobile_m1	80.49%	40.00%	93.55%
12	NASNetMobile_m2	82.93%	40.00%	96.77%
13	ResNet101_m1	85.37%	90.00%	83.87%
14	ResNet101_m2	82.93%	80.00%	83.87%
15	ResNet50_m1	87.80%	70.00%	93.55%
16	ResNet50_m2	85.37%	50.00%	96.77%
17	ResNet50V2_m1	78.05%	60.00%	83.87%
18	ResNet50V2_m2	85.37%	70.00%	90.32%
19	VGG16_m1	90.24%	90.00%	90.32%
20	VGG16_m2	90.24%	90.00%	90.32%
21	VGG19_m1	87.80%	70.00%	93.55%
22	VGG19_m2	90.24%	70.00%	96.77%
23	Xception_m1	90.24%	70.00%	96.77%
24	Xception_m2	87.80%	70.00%	93.55%
25	Voting 3	87.80%	70.00%	93.55%
26	Voting 5	90.24%	80.00%	93.55%
27	Voting 7	87.80%	70.00%	93.55%
28	Voting 9	87.80%	70.00%	93.55%
29	Voting 11	90.24%	70.00%	96.77%

Tabla 6.12. Resultados del test del primer escenario de los modelos entrenados con Sjchoi86-HRF

Uno de los mejores resultados se obtiene con el modelo Xception\_m1 y los modelos híbridos compuestos por los 5 y 7 modelos con mayor rendimiento. En la Figura 6.8, se observa la comparación de los rendimientos de los 24 modelos y los 5 modelos híbridos.

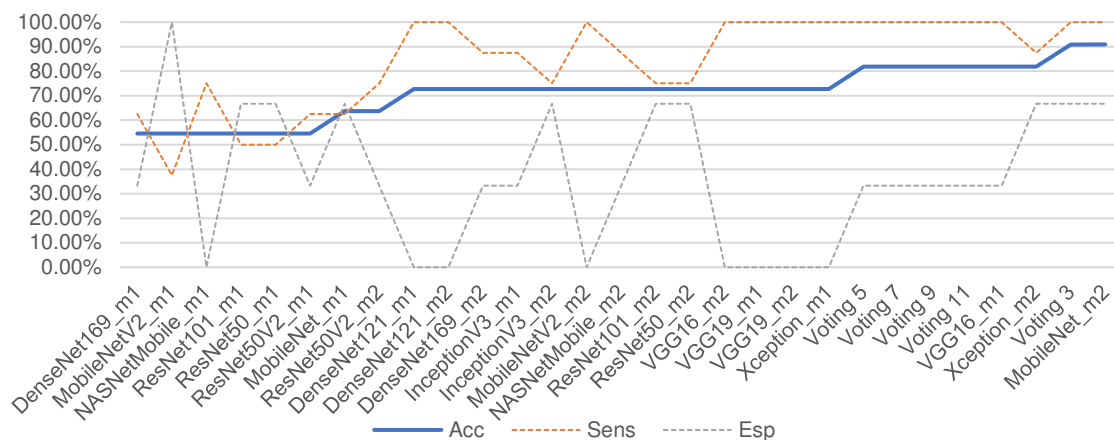


Figura 6.8. Comparación de resultados del test de Sjchoi86-HRF

Fuente: Elaboración propia.

Además, se realizó el test de estos modelos sobre los datos de prueba del tercer escenario, de donde se obtuvieron los resultados de la Tabla 6.13.

		<b>Escenario 1 Sjchoi86-HRF - Test All Data Set</b>		
<b>N°</b>	<b>Model</b>	<b>Acc</b>	<b>Sens</b>	<b>Esp</b>
1	DenseNet121_m1	54.02%	91.86%	17.05%
2	DenseNet121_m2	50.00%	97.67%	3.41%
3	DenseNet169_m1	58.05%	24.42%	90.91%
4	DenseNet169_m2	59.20%	65.12%	53.41%
5	InceptionV3_m1	55.75%	59.30%	52.27%
6	InceptionV3_m2	58.62%	79.07%	38.64%
7	MobileNet_m1	52.87%	37.21%	68.18%
8	MobileNet_m2	62.64%	53.49%	71.59%
9	MobileNetV2_m1	52.87%	4.65%	100.00%
10	MobileNetV2_m2	52.30%	95.35%	10.23%
11	NASNetMobile_m1	52.87%	75.58%	30.68%
12	NASNetMobile_m2	57.47%	19.77%	94.32%
13	ResNet101_m1	52.87%	13.95%	90.91%
14	ResNet101_m2	64.37%	84.88%	44.32%
15	ResNet50_m1	55.75%	11.63%	98.86%
16	ResNet50_m2	68.97%	55.81%	81.82%
17	ResNet50V2_m1	56.32%	37.21%	75.00%
18	ResNet50V2_m2	70.69%	60.47%	80.68%
19	VGG16_m1	70.69%	48.84%	92.05%
20	VGG16_m2	49.43%	100.00%	0.00%

21	VGG19_m1	69.54%	63.95%	75.00%
22	VGG19_m2	49.43%	100.00%	0.00%
23	Xception_m1	50.00%	100.00%	1.14%
24	Xception_m2	63.79%	56.98%	70.45%
25	Voting 3	68.39%	55.81%	80.68%
26	Voting 5	67.82%	79.07%	56.82%
27	Voting 7	67.24%	67.44%	67.05%
28	Voting 9	65.52%	81.40%	50.00%
29	Voting 11	68.39%	80.23%	56.82%

Tabla 6.13. Resultados del test del tercer escenario de los modelos entrenados con Sjchoi86-HRF

Los resultados disminuyen considerablemente en comparación con los datos de la Tabla 6.12. En la Figura 6.9, se muestra la comparación de los rendimientos.

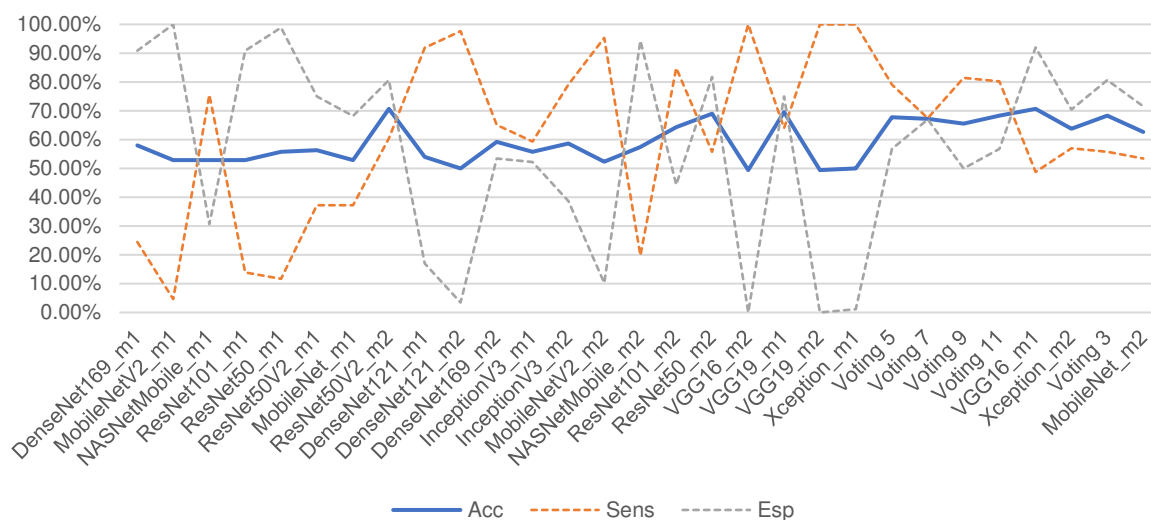


Figura 6.9. Resultados de test del tercer escenario de los modelos entrenados con Sjchoi86-HRF

Fuente: Elaboración propia.

### 6.6.1.4. RIM ONE

Los resultados de los 24 modelos y 5 modelos híbridos entrenados con el data set RIM ONE se muestran en la Tabla 6.14.

N°	Model	Escenario 1 - Test RIM ONE		
		Acc	Sens	Esp
1	DenseNet121_m1	84.78%	95.65%	73.91%
2	DenseNet121_m2	89.13%	91.30%	86.96%
3	DenseNet169_m1	91.30%	95.65%	86.96%
4	DenseNet169_m2	93.48%	91.30%	95.65%
5	InceptionV3_m1	86.96%	91.30%	82.61%
6	InceptionV3_m2	93.48%	95.65%	91.30%
7	MobileNet_m1	89.13%	86.96%	91.30%
8	MobileNet_m2	93.48%	95.65%	91.30%
9	MobileNetV2_m1	95.65%	95.65%	95.65%
10	MobileNetV2_m2	91.30%	95.65%	86.96%
11	NASNetMobile_m1	71.74%	91.30%	52.17%
12	NASNetMobile_m2	76.09%	60.87%	91.30%
13	ResNet101_m1	82.61%	82.61%	82.61%
14	ResNet101_m2	91.30%	91.30%	91.30%
15	ResNet50_m1	95.65%	95.65%	95.65%
16	ResNet50_m2	95.65%	95.65%	95.65%
17	ResNet50V2_m1	84.78%	86.96%	82.61%
18	ResNet50V2_m2	89.13%	91.30%	86.96%
19	VGG16_m1	82.61%	95.65%	69.57%
20	VGG16_m2	91.30%	91.30%	91.30%
21	VGG19_m1	89.13%	91.30%	86.96%
22	VGG19_m2	93.48%	95.65%	91.30%
23	Xception_m1	93.48%	91.30%	95.65%
24	Xception_m2	89.13%	95.65%	82.61%
25	Voting 3	97.83%	95.65%	100.00%
26	Voting 5	95.65%	95.65%	95.65%
27	Voting 7	95.65%	95.65%	95.65%
28	Voting 9	95.65%	95.65%	95.65%
29	Voting 11	93.48%	95.65%	91.30%

Tabla 6.14. Resultados del test del primer escenario de los modelos entrenados con RIM ONE

Uno de los mejores resultados se obtiene con el modelo ResNet50\_m2 y el modelo híbrido compuesto por los 3 con mayor rendimiento. En la Figura 6.10, se muestra la comparación de los rendimientos de los 24 modelos y los 5 modelos híbridos.

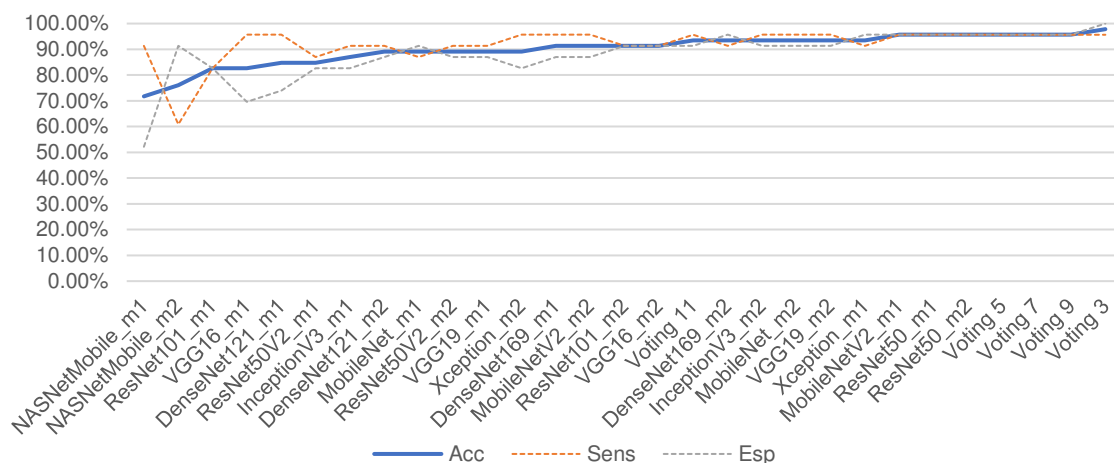


Figura 6.10. Comparación de resultados del test de RIM ONE

Fuente: Elaboración propia.

Además, se realizó el test de estos modelos sobre los datos de prueba del tercer escenario, de donde se obtuvieron los resultados de la Tabla 6.15.

		Escenario 1 RIM ONE – Test All Data Sets		
Nº	Model	Acc	Sens	Esp
1	DenseNet121_m1	66.09%	98.84%	34.09%
2	DenseNet121_m2	66.09%	91.86%	40.91%
3	DenseNet169_m1	72.41%	93.02%	52.27%
4	DenseNet169_m2	75.86%	88.37%	63.64%
5	InceptionV3_m1	66.09%	94.19%	38.64%
6	InceptionV3_m2	78.16%	79.07%	77.27%
7	MobileNet_m1	67.24%	66.28%	68.18%
8	MobileNet_m2	72.99%	70.93%	75.00%
9	MobileNetV2_m1	68.39%	59.30%	77.27%
10	MobileNetV2_m2	71.26%	84.88%	57.95%
11	NASNetMobile_m1	65.52%	69.77%	61.36%
12	NASNetMobile_m2	62.07%	72.09%	52.27%
13	ResNet101_m1	59.77%	63.95%	55.68%
14	ResNet101_m2	72.41%	89.53%	55.68%
15	ResNet50_m1	67.24%	75.58%	59.09%
16	ResNet50_m2	66.67%	83.72%	50.00%
17	ResNet50V2_m1	72.99%	81.40%	64.77%
18	ResNet50V2_m2	71.26%	79.07%	63.64%
19	VGG16_m1	64.37%	95.35%	34.09%
20	VGG16_m2	72.41%	86.05%	59.09%
21	VGG19_m1	73.56%	84.88%	62.50%
22	VGG19_m2	64.94%	90.70%	39.77%

23	Xception_m1	67.82%	77.91%	57.95%
24	Xception_m2	60.92%	83.72%	38.64%
25	Voting 3	68.39%	75.58%	61.36%
26	Voting 5	71.84%	82.56%	61.36%
27	Voting 7	73.56%	84.88%	62.50%
28	Voting 9	74.14%	87.21%	61.36%
29	Voting 11	73.56%	88.37%	59.09%

Tabla 6.15. Resultados del test del tercer escenario de los modelos entrenados con Sjchoi86-HRF

Los resultados disminuyen considerablemente en comparación con los datos de la Tabla 6.14. En la Figura 6.11, se muestra la comparación de los rendimientos.




Figura 6.11. Resultados de test del tercer escenario de los modelos entrenados con RIM ONE

Fuente: Elaboración propia.

### 6.6.1.5. ACRIMA

Los resultados de los 24 modelos y 5 modelos híbridos entrenados con el data set ACRIMA se muestran en la Tabla 6.16.

N°	Model	Escenario 1 - Test ACRIMA		
		Acc	Sens	Esp
1	NASNetMobile_m1	63.38%	100.00%	7.14%
2	NASNetMobile_m2	63.38%	72.09%	50.00%
3	MobileNetV2_m2	64.79%	100.00%	10.71%
4	ResNet50V2_m1	76.06%	60.47%	100.00%
5	MobileNetV2_m1	80.28%	100.00%	50.00%
6	ResNet50V2_m2	91.55%	90.70%	92.86%
7	VGG16_m1	91.55%	100.00%	78.57%
8	VGG16_m2	92.96%	95.35%	89.29%
9	Xception_m1	92.96%	90.70%	96.43%
10	DenseNet169_m2	94.37%	90.70%	100.00%
11	ResNet101_m1	94.37%	90.70%	100.00%
12	MobileNet_m2	95.77%	93.02%	100.00%
13	ResNet101_m2	95.77%	97.67%	92.86%
14	ResNet50_m1	95.77%	97.67%	92.86%
15	Xception_m2	95.77%	95.35%	96.43%
16	DenseNet169_m1	97.18%	95.35%	100.00%
17	InceptionV3_m1	97.18%	95.35%	100.00%
18	InceptionV3_m2	97.18%	95.35%	100.00%
19	MobileNet_m1	97.18%	97.67%	96.43%
20	ResNet50_m2	97.18%	97.67%	96.43%
21	VGG19_m1	97.18%	97.67%	96.43%
22	VGG19_m2	97.18%	97.67%	96.43%
23	DenseNet121_m1	98.59%	97.67%	100.00%
24	DenseNet121_m2	98.59%	100.00%	96.43%
25	Voting 3	98.59%	97.67%	100.00%
26	Voting 5	100.00%	100.00%	100.00%
27	Voting 7	98.59%	97.67%	100.00%
28	Voting 9	100.00%	100.00%	100.00%
29	Voting 11	98.59%	97.67%	100.00%

Tabla 6.16. Resultados del test de los modelos usando ACRIMA (primer escenario)

Uno de los mejores resultados se obtiene con el modelo ResNet50\_m2 y el modelo híbrido compuesto por los 3 con mayor rendimiento. En la Figura 6.12, se observa la comparación de los rendimientos de los 24 modelos y los 5 modelos híbridos.

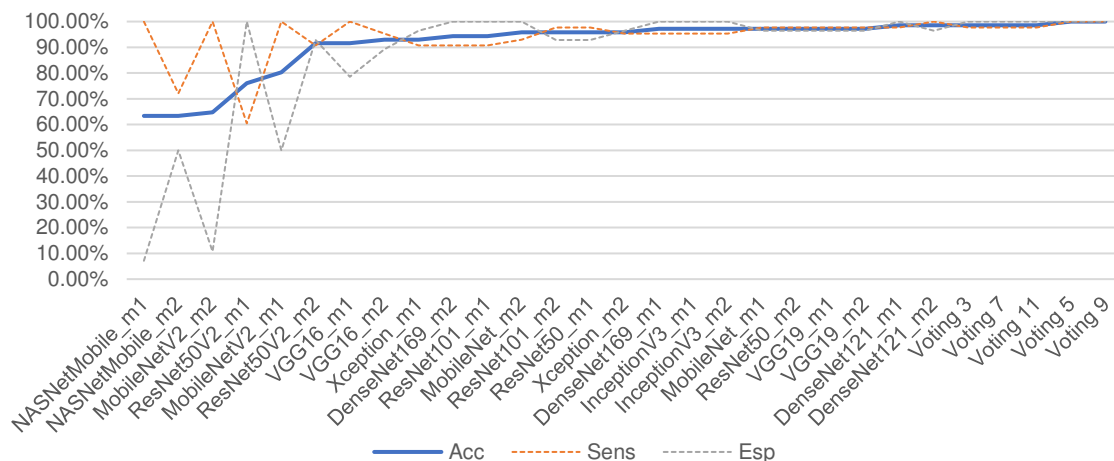


Figura 6.12. Comportamiento de los resultados del Test de los modelos usando ACRIMA (primer escenario)

Fuente: Elaboración propia.

Además, se realizó el test de estos modelos sobre los datos de prueba del tercer escenario, de donde se obtuvieron los resultados de la Tabla 6.17.

		Escenario 1 ACRIMA – Test All Data Sets		
Nº	Model	Acc	Sens	Esp
1	DenseNet121_m1	49.43%	96.51%	3.41%
2	DenseNet121_m2	48.85%	63.95%	34.09%
3	DenseNet169_m1	52.30%	97.67%	7.95%
4	DenseNet169_m2	72.41%	97.67%	47.73%
5	InceptionV3_m1	59.20%	100.00%	19.32%
6	InceptionV3_m2	70.11%	90.70%	50.00%
7	MobileNet_m1	62.07%	100.00%	25.00%
8	MobileNet_m2	62.07%	90.70%	34.09%
9	MobileNetV2_m1	72.41%	90.70%	54.55%
10	MobileNetV2_m2	71.26%	72.09%	70.45%
11	NASNetMobile_m1	64.37%	95.35%	34.09%
12	NASNetMobile_m2	68.39%	94.19%	43.18%
13	ResNet101_m1	67.82%	100.00%	36.36%
14	ResNet101_m2	63.79%	98.84%	29.55%
15	ResNet50_m1	66.09%	91.86%	40.91%
16	ResNet50_m2	71.84%	95.35%	48.86%
17	ResNet50V2_m1	64.37%	97.67%	31.82%
18	ResNet50V2_m2	68.39%	100.00%	37.50%



19	VGG16_m1	66.09%	95.35%	37.50%
20	VGG16_m2	64.94%	97.67%	32.95%
21	VGG19_m1	64.37%	96.51%	32.95%
22	VGG19_m2	64.94%	97.67%	32.95%
23	Xception_m1	70.11%	96.51%	44.32%
24	Xception_m2	75.86%	94.19%	57.95%
25	Voting 3	71.84%	96.51%	47.73%
26	Voting 5	68.39%	100.00%	37.50%
27	Voting 7	65.52%	98.84%	32.95%
28	Voting 9	66.09%	100.00%	32.95%
29	Voting 11	64.94%	98.84%	31.82%

Tabla 6.17. Resultados del Test de todos los dataset para los modelos entrenado con ACRIMA (primer escenario)

Los resultados disminuyen considerablemente en comparación con los datos de la Tabla 6.16. En la Figura 6.13, se muestra la comparación de los rendimientos.




Figura 6.13. Comportamiento de los resultados del Test de todos los dataset para los modelos entrenado con ACRIMA (primer escenario)

Fuente: Elaboración propia.

## 6.6.2. Escenario 2

Los resultados de los 24 modelos y los 5 modelos híbridos entrenados en el escenario 2 se muestran en la Tabla 6.18.

N°	Model	Escenario 2 - Test All Data Set		
		Acc	Sens	Esp
1	DenseNet121_m1	77.01%	100.00%	54.55%
2	DenseNet121_m2	74.14%	96.51%	52.27%
3	DenseNet169_m1	79.31%	95.35%	63.64%
4	DenseNet169_m2	77.01%	97.67%	56.82%
5	InceptionV3_m1	70.69%	96.51%	45.45%
6	InceptionV3_m2	82.76%	95.35%	70.45%
7	MobileNet_m1	75.86%	95.35%	56.82%
8	MobileNet_m2	75.86%	93.02%	59.09%
9	MobileNetV2_m1	72.41%	82.56%	62.50%
10	MobileNetV2_m2	82.18%	75.58%	88.64%
11	NASNetMobile_m1	76.44%	90.70%	62.50%
12	NASNetMobile_m2	62.64%	97.67%	28.41%
13	ResNet101_m1	71.26%	100.00%	43.18%
14	ResNet101_m2	79.31%	93.02%	65.91%
15	ResNet50_m1	68.97%	96.51%	42.05%
16	ResNet50_m2	74.14%	95.35%	53.41%
17	ResNet50V2_m1	83.33%	87.21%	79.55%
18	ResNet50V2_m2	77.59%	97.67%	57.95%
19	VGG16_m1	65.52%	91.86%	39.77%
20	VGG16_m2	66.09%	91.86%	40.91%
21	VGG19_m1	69.54%	96.51%	43.18%
22	VGG19_m2	66.09%	94.19%	38.64%
23	Xception_m1	78.74%	96.51%	61.36%
24	Xception_m2	77.01%	96.51%	57.95%
25	Voting 3	88.51%	90.70%	86.36%
26	Voting 5	84.48%	94.19%	75.00%
27	Voting 7	84.48%	96.51%	72.73%
28	Voting 9	81.61%	98.84%	64.77%
29	Voting 11	82.76%	100.00%	65.91%

Tabla 6.18. Resultados del test de los modelos entrenados con el data set del segundo escenario

Uno de los mejores resultados se obtiene con el modelo ResNet50V2\_m1 con accuracy de 83.33%, sensibilidad del 87.21% y especificidad del 79.55%, y el modelo híbrido compuesto por los 3 modelos con mayor rendimiento que presenta mejores resultados con accuracy de 88.51%,

sensibilidad del 94.19% y especificidad del 86.36%. En la Figura 6.14, se observa la comparación de los rendimientos de los 24 modelos y los 5 modelos híbridos.




Figura 6.14. Resultados de test del tercer escenario de los modelos entrenados con el data set definido en el segundo escenario

Fuente: Elaboración propia.

### 6.6.3. Escenario 3

Los resultados de los 24 modelos y los 5 modelos híbridos entrenados en el tercer escenario se muestran en la Tabla 6.19.

Escenario 3 - Test All Data Set				
N°	Model	Acc	Sens	Esp
1	DenseNet121_m1	90.80%	82.56%	98.86%
2	DenseNet121_m2	93.10%	90.70%	95.45%
3	DenseNet169_m1	92.53%	93.02%	92.05%
4	DenseNet169_m2	93.68%	94.19%	93.18%
5	InceptionV3_m1	92.53%	95.35%	89.77%
6	InceptionV3_m2	93.68%	95.35%	92.05%
7	MobileNet_m1	93.68%	98.84%	88.64%
8	MobileNet_m2	90.23%	90.70%	89.77%
9	MobileNetV2_m1	93.68%	95.35%	92.05%
10	MobileNetV2_m2	91.95%	96.51%	87.50%
11	NASNetMobile_m1	91.95%	93.02%	90.91%
12	NASNetMobile_m2	90.23%	91.86%	88.64%
13	ResNet101_m1	91.38%	95.35%	87.50%

14	ResNet101_m2	92.53%	93.02%	92.05%
15	ResNet50_m1	94.83%	98.84%	90.91%
16	ResNet50_m2	94.25%	96.51%	92.05%
17	ResNet50V2_m1	91.38%	94.19%	88.64%
18	ResNet50V2_m2	94.25%	93.02%	95.45%
19	VGG16_m1	90.23%	87.21%	93.18%
20	VGG16_m2	94.25%	94.19%	94.32%
21	VGG19_m1	91.95%	91.86%	92.05%
22	VGG19_m2	90.80%	91.86%	89.77%
23	Xception_m1	91.95%	93.02%	90.91%
24	Xception_m2	93.10%	93.02%	93.18%
25	Voting 3	<b>96.55%</b>	<b>98.84%</b>	<b>94.32%</b>
26	Voting 5	96.55%	97.67%	95.45%
27	Voting 7	95.98%	97.67%	94.32%
28	Voting 9	95.98%	97.67%	94.32%
29	Voting 11	95.98%	97.67%	94.32%

Tabla 6.19. Resultados del test de los modelos entrenados con el data set del tercer escenario

Uno de los mejores resultados se obtiene con el modelo ResNet50\_m1 con accuracy de 94.83%, sensibilidad del 98.84% y especificidad del 90.91%, y el modelo híbrido compuesto por los 3 y 9 modelos con mayor rendimiento que tienen un accuracy del 96.55%. En la Figura 6.15, se observa la comparación de los rendimientos de los 24 modelos y los 5 modelos híbridos.




Figura 6.15. Resultados de test del tercer escenario de los modelos entrenados con el data set definido en el segundo escenario

Fuente: Elaboración propia.

Por último, en la Figura 6.16, se muestra la comparación de los modelos evaluados con los datos de prueba del tercer escenario, donde se visualiza que en el tercer escenario se obtienen los mejores resultados.

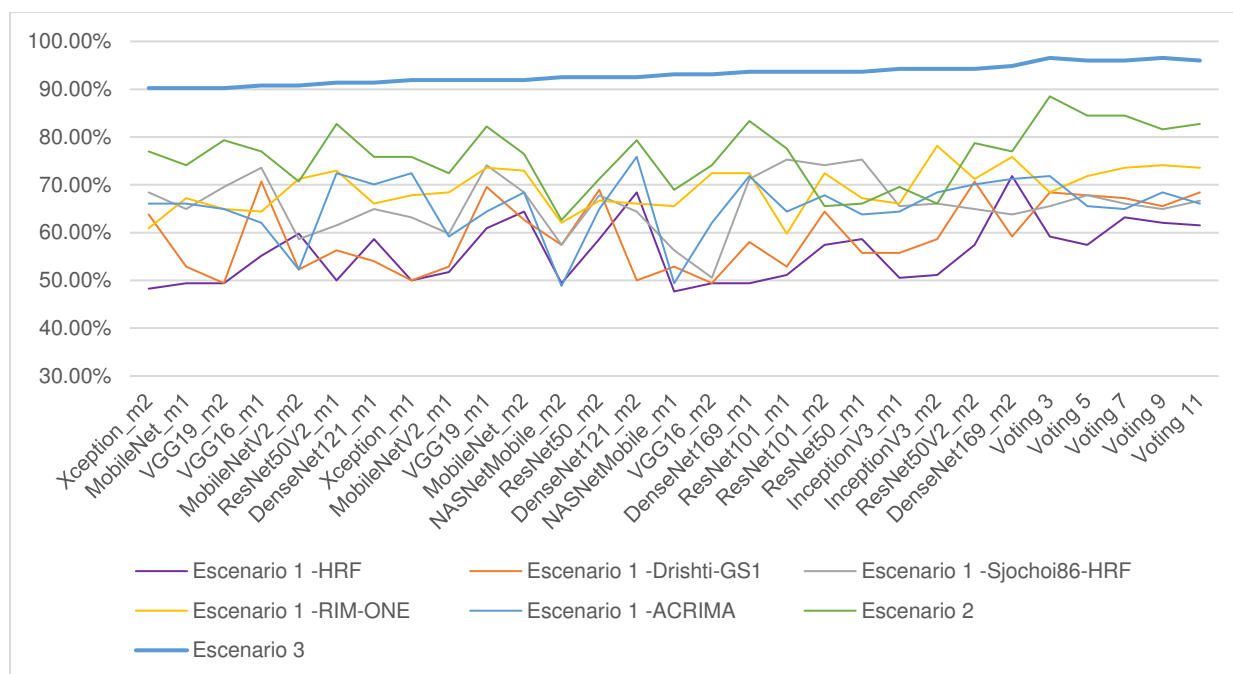


Figura 6.16. Comparación de los resultados (acc) de los modelos para los 3 escenarios con el data set de test del tercer escenario

Fuente: Elaboración propia.

# CAPÍTULO 7: CONCLUSIONES Y TRABAJOS

## FUTUROS

### 7.1. Conclusiones

#### 7.1.1. Conclusión general

Se implementó una herramienta de apoyo utilizando técnicas de aprendizaje profundo: redes neuronales convolucionales y transferencia de aprendizaje, que mediante la extracción, selección y clasificación automática de características permite identificar el glaucoma a partir de una imagen del fondo de ojo que haya sido tomada por un teléfono inteligente o una herramienta especializada.

#### 7.1.2. Conclusiones específicas

##### 7.1.2.1. Objetivo específico 1

Basándonos en el criterio de votación, se generó un modelo híbrido de aprendizaje profundo que combina los mejores resultados de los 24 modelos pre-entrenados utilizando las librerías de Keras y Tensorflow.

##### 7.1.2.2. Objetivo específico 2

Se desarrolló y ejecutó una aplicación web basada en los lenguajes de programación Python y JavaScript utilizando los frameworks Angular, Ionic y Django. Además, de utilizar las librerías Keras y Tensorflow para realizar el entrenamiento y la validación del rendimiento de cada modelo de aprendizaje profundo.

### **7.1.2.3. Objetivo específico 3**

Se ha realizado el entrenamiento y la validación de los modelos para el diagnóstico del glaucoma utilizando data histórica de imágenes del fondo de ojo previamente etiquetadas de 5 datasets encontrados en la literatura. El rendimiento del modelo obtenido luego de la validación es de 96.55%, utilizando 3 de los mejores modelos entrenados, lo cual es una mejor precisión en comparación con la alcanzada por Diaz-Pinto (2018), donde obtuvieron una tasa de 90.69%.

## **7.2. Limitaciones**

El presente trabajo está únicamente orientado a la enfermedad del glaucoma. Para que esta herramienta de apoyo de diagnóstico funcione, se necesita seguir un protocolo médico para la toma de las imágenes del fondo de ojo.

## **7.3. Trabajos futuros**

Futuros estudios podrían considerar utilizar otros modelos pre-entrenados de aprendizaje profundo, así como utilizar otras técnicas de inteligencia artificial, además de realizar el entrenamiento y la validación con más datos que permitan incrementar el espectro de posibles escenarios en una imagen del fondo de ojo.

## Referencias

- Abbas, Q. (2017). Glaucoma-Deep: Detection of Glaucoma Eye Disease on Retinal Fundus Images using Deep Learning. *International Journal of Advanced Computer Science and Applications*, 8(6). <https://doi.org/10.14569/IJACSA.2017.080606>
- Acharya, U. R., Ng, E. Y. K., & Suri, J. (2008). *Image Modeling of the Human Eye*. Artech. <https://ieeexplore.ieee.org/document/9100722/metrics#metrics>
- Ahn, J. M., Kim, S., Ahn, K. S., Cho, S. H., Lee, K. B., & Kim, U. S. (2018). A deep learning model for the detection of both advanced and early glaucoma using fundus photography. *PLOS ONE*, 13(11), e0207982. <https://doi.org/10.1371/journal.pone.0207982>
- An, G., Omodaka, K., Hashimoto, K., Tsuda, S., Shiga, Y., Takada, N., Kikawa, T., Yokota, H., Akiba, M., & Nakazawa, T. (2019). Glaucoma Diagnosis with Machine Learning Based on Optical Coherence Tomography and Color Fundus Images. *Journal of Healthcare Engineering*, 2019, 1–9. <https://doi.org/10.1155/2019/4061313>
- Araújo, J. D., Souza, J. C., Neto, O. P., de Sousa, J. A., de Almeida, J. D., de Paiva, A. C., Silva, A. C., Junior, G. B., & Gattass, M. (2019). Glaucoma diagnosis in fundus eye images using diversity indexes. *Multimedia Tools and Applications*, 78(10), 12987–13004. <https://doi.org/10.1007/s11042-018-6429-z>
- Baykal, E., Dogan, H., Ercin, M. E., Ersoz, S., & Ekinci, M. (2020). Transfer learning with pre-trained deep convolutional neural networks for serous cell classification. *Multimedia Tools and Applications*, 79(21–22), 15593–15611. <https://doi.org/10.1007/s11042-019-07821-9>
- Belduma, G., & Valarezo, L. (2019). *Fondo de ojo mediante oftalmoscopia directa, como método para detección de glaucoma en el adulto*. Repositorio Digital de La UTMACH. <http://repositorio.utmachala.edu.ec/handle/48000/13720>
- Bland, M. (2015). *An introduction to medical statistics*. Oxford medical publications. <https://catalogue.nla.gov.au/Record/1450312>
- Bua, S., & Supuran, C. T. (2019). Diagnostic markers for glaucoma: a patent and literature review (2013-2019). *Expert Opinion on Therapeutic Patents*, 29(10), 829–839. <https://doi.org/10.1080/13543776.2019.1667336>
- Carneiro, T., Medeiros-Nobrega, R. V., Nepomuceno, T., Bian, G., De Albuquerque, V. H. C., & Filho, P. P. R. (2018). Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications. *IEEE Access*, 6, 61677–61685. <https://doi.org/10.1109/ACCESS.2018.2874767>
- Castañeda-Díez, R., Jiménez-Román, J., & Iriarte-Barbosa, M. J. (2014). Concepto de sospecha de glaucoma de ángulo abierto: definición, diagnóstico y tratamiento. *Revista Mexicana de Oftalmología*, 88(4), 153–160. <https://doi.org/10.1016/j.mexoft.2014.02.001>
- Chai, Y., Liu, H., & Xu, J. (2018). Glaucoma diagnosis based on both hidden features and domain knowledge through deep learning models. *Knowledge-Based Systems*, 161, 147–156. <https://doi.org/10.1016/j.knosys.2018.07.043>



- Chakravarty, A., & Sivaswamy, J. (2016). Glaucoma classification with a fusion of segmentation and image-based features. *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, 689–692. <https://doi.org/10.1109/ISBI.2016.7493360>
- Chollet, F. (2017). *Classifier from little data script*. Gist.Github. <https://gist.github.com/fchollet/7eb39b44eb9e16e59632d25fb3119975>
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Crisol-Deza, D. A. (2022). Glaucoma primario de ángulo abierto: una prioridad en la oftalmología. *Revista Científica Estudiantil de Cienfuegos INMEDSUR*, 5.
- de Carvalho, A. S. V., Carvalho, E. D., de Carvalho Filho, A. O., de Sousa, A. D., Corrêa-Silva, A., & Gattass, M. (2018). Automatic methods for diagnosis of glaucoma using texture descriptors based on phylogenetic diversity. *Computers & Electrical Engineering*, 71, 102–114. <https://doi.org/10.1016/j.compeleceng.2018.07.028>
- de Sousa, J. A., de Paiva, A. C., Sousa, J. D., Silva, A. C., Junior, G. B., & Gattass, M. (2017). Texture based on geostatistic for glaucoma diagnosis from fundus eye image. *Multimedia Tools and Applications*, 76(18), 19173–19190. <https://doi.org/10.1007/s11042-017-4608-y>
- Deng, X., Liu, Q., Deng, Y., & Mahadevan, S. (2016). An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences*, 340–341, 250–261. <https://doi.org/10.1016/j.ins.2016.01.033>
- Diaz-Pinto, A., Morales, S., Naranjo, V., Köhler, T., Mossi, J. M., & Navea, A. (2019). CNNs for automatic glaucoma assessment using fundus images: an extensive validation. *BioMedical Engineering OnLine*, 18(1), 29. <https://doi.org/10.1186/s12938-019-0649-y>
- Díaz, J. M. (2010). Prevención y tratamiento actual del glaucoma. *Revista Médica Clínica Las Condes*, 21(6), 891–900. [https://doi.org/10.1016/S0716-8640\(10\)70661-1](https://doi.org/10.1016/S0716-8640(10)70661-1)
- Espinoza-Portilla, E., Gil-Quevedo, W., & Agurto-Távora, E. (2020). Principales problemas en la gestión de establecimientos de salud en el Perú. *Revista Cubana de Salud Pública*, 46(4). <https://www.scielosp.org/pdf/rcsp/2020.v46n4/e2146/es>
- Glaucoma Research Foundation. (2013). *Glaucoma Facts and Stats*. <https://www.glaucoma.org/glaucoma/glaucoma-facts-and-stats.php>
- Glaucoma Research Foundation. (2020). *Five Common Glaucoma Tests*. <https://www.glaucoma.org/glaucoma/diagnostic-tests.php>
- Gour, N., & Khanna, P. (2020). Automated glaucoma detection using GIST and pyramid histogram of oriented gradients (PHOG) descriptors. *Pattern Recognition Letters*, 137, 3–11. <https://doi.org/10.1016/j.patrec.2019.04.004>
- Guo, J., Azzopardi, G., Shi, C., Jansonius, N. M., & Petkov, N. (2019). Automatic Determination of Vertical Cup-to-Disc Ratio in Retinal Fundus Images for Glaucoma Screening. *IEEE Access*, 7, 8527–8541. <https://doi.org/10.1109/ACCESS.2018.2890544>
- Guo, Mai, Y., Zhao, X., Duan, X., Fan, Z., Zou, B., & Xie, B. (2018). Yanbao: A Mobile App

- Using the Measurement of Clinical Parameters for Glaucoma Screening. *IEEE Access*, 6, 77414–77428. <https://doi.org/10.1109/ACCESS.2018.2882946>
- Hagiwara, Y., Koh, J. E. W., Tan, J. H., Bhandary, S. V., Laude, A., Ciaccio, E. J., Tong, L., & Acharya, U. R. (2018). Computer-aided diagnosis of glaucoma using fundus images: A review. *Computer Methods and Programs in Biomedicine*, 165, 1–12. <https://doi.org/10.1016/j.cmpb.2018.07.012>
- Hemelings, R., Elen, B., Barbosa-Breda, J., Lemmens, S., Meire, M., Pourjavan, S., Vandewalle, E., Van de Veire, S., Blaschko, M. B., De Boever, P., & Stalmans, I. (2020). Accurate prediction of glaucoma from colour fundus images with a convolutional neural network that relies on active and transfer learning. *Acta Ophthalmologica*, 98(1). <https://doi.org/10.1111/aos.14193>
- Hinton, G. (2018). Deep Learning—A Technology With the Potential to Transform Health Care. *JAMA*, 320(11), 1101. <https://doi.org/10.1001/jama.2018.11100>
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression*. Wiley. <https://doi.org/10.1002/9781118548387>
- J. Salazar, J., I. Ramírez, A., De Hoz, R., Salobar-Garcia, E., Rojas, P., A. Fernández-Albarral, J., López-Cuenca, I., Rojas, B., Triviño, A., & M. Ramírez, J. (2019). Anatomy of the Human Optic Nerve: Structure and Function. In *Optic Nerve*. IntechOpen. <https://doi.org/10.5772/intechopen.79827>
- Joachims, T. (1998). Making large-scale SVM learning practical. *Technical Reports, SFB 475*, 28, 41–57. [https://www.cs.cornell.edu/people/tj/publications/joachims\\_99a.pdf](https://www.cs.cornell.edu/people/tj/publications/joachims_99a.pdf)
- Juneja, M., Singh, S., Agarwal, N., Bali, S., Gupta, S., Thakur, N., & Jindal, P. (2020). Automated detection of Glaucoma using deep learning convolution network (G-net). *Multimedia Tools and Applications*, 79(21–22), 15531–15553. <https://doi.org/10.1007/s11042-019-7460-4>
- Keras Team. (2020). *Keras Applications*. <https://keras.io/api/applications/>
- Khalid, S., Akram, M. U., Shehryar, T., Ahmed, W., Sadiq, M., Manzoor, M., & Nosheen, N. (2021). Automated diagnosis system for age-related macular degeneration using hybrid features set from fundus images. *International Journal of Imaging Systems and Technology*, 31(1), 236–252. <https://doi.org/10.1002/ima.22456>
- Kim, T. N., Myers, F., Reber, C., Loury, P. J., Loumou, P., Webster, D., Echanique, C., Li, P., Davila, J. R., Maamari, R. N., Switz, N. A., Keenan, J., Woodward, M. A., Paulus, Y. M., Margolis, T., & Fletcher, D. A. (2018). A Smartphone-Based Tool for Rapid, Portable, and Automated Wide-Field Retinal Imaging. *Translational Vision Science & Technology*, 7(5), 21. <https://doi.org/10.1167/tvst.7.5.21>
- Koh, J. E. W., Acharya, U. R., Hagiwara, Y., Raghavendra, U., Tan, J. H., Sree, S. V., Bhandary, S. V., Rao, A. K., Sivaprasad, S., Chua, K. C., Laude, A., & Tong, L. (2017). Diagnosis of retinal health in digital fundus images using continuous wavelet transform (CWT) and entropies. *Computers in Biology and Medicine*, 84, 89–97. <https://doi.org/10.1016/j.combiomed.2017.03.008>

- Koh, J. E. W., Ng, E. Y. K., Bhandary, S. V., Hagiwara, Y., Laude, A., & Acharya, U. R. (2018). Automated retinal health diagnosis using pyramid histogram of visual words and Fisher vector techniques. *Computers in Biology and Medicine*, *92*, 204–209. <https://doi.org/10.1016/j.combiomed.2017.11.019>
- Kohler, T., Budai, A., Kraus, M. F., Odstrcilik, J., Michelson, G., & Hornegger, J. (2013). Automatic no-reference quality assessment for retinal fundus images using vessel segmentation. *Proceedings of the 26th IEEE International Symposium on Computer-Based Medical Systems*, 95–100. <https://doi.org/10.1109/CBMS.2013.6627771>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, *60*(6), 84–90. <https://doi.org/10.1145/3065386>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lee, S.-D., Lee, J.-H., Choi, Y.-G., You, H.-C., Kang, J.-H., & Jun, C.-H. (2019). Machine learning models based on the dimensionality reduction of standard automated perimetry data for glaucoma diagnosis. *Artificial Intelligence in Medicine*, *94*, 110–116. <https://doi.org/10.1016/j.artmed.2019.02.006>
- Liang, Z., Wong, D., Liu, J., Chan, K. L., & Wong, T. Y. (2010). Towards automatic detection of age-related macular degeneration in retinal fundus images. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference, 2010*, 4100–4103. <https://doi.org/10.1109/IEMBS.2010.5627289>
- Lopes, C. C., Atallah, Á. N., Valente, O., & Trevisani, V. F. M. (2008). Pentoxifylline for diabetic retinopathy. *Cochrane Database of Systematic Reviews*. <https://doi.org/10.1002/14651858.CD006693.pub2>
- Lossio, J. (2021). Covid-19 en el Perú: respuestas estatales y sociales. *História, Ciências, Saúde-Manguinhos*, *28*(2), 581–585. <https://doi.org/10.1590/s0104-59702021005000001>
- Luna, I., Brechtel, M., & De La Fuente, M. (2009). Relación del espesor corneal central y la variación en la presión intraocular con daño al nervio óptico en pacientes mexicanos con glaucoma. *Revista Mexicana de Oftalmología*, *83*(4), 193–196. <https://www.medigraphic.com/cgi-bin/new/resumen.cgi?IDARTICULO=21797>
- Maheshwari, S., Kanhangad, V., Pachori, R. B., Bhandary, S. V., & Acharya, U. R. (2019). Automated glaucoma diagnosis using bit-plane slicing and local binary pattern techniques. *Computers in Biology and Medicine*, *105*, 72–80. <https://doi.org/10.1016/j.combiomed.2018.11.028>
- Maheshwari, S., Pachori, R. B., & Acharya, U. R. (2017). Automated Diagnosis of Glaucoma Using Empirical Wavelet Transform and Correntropy Features Extracted From Fundus Images. *IEEE Journal of Biomedical and Health Informatics*, *21*(3), 803–813. <https://doi.org/10.1109/JBHI.2016.2544961>
- Maheshwari, S., Pachori, R. B., Kanhangad, V., Bhandary, S. V., & Acharya, U. R. (2017).

- Iterative variational mode decomposition based automated detection of glaucoma using fundus images. *Computers in Biology and Medicine*, 88, 142–149. <https://doi.org/10.1016/j.compbiomed.2017.06.017>
- Mamtora, S., Sandinha, M. T., Ajith, A., Song, A., & Steel, D. H. W. (2018). Smart phone ophthalmoscopy: a potential replacement for the direct ophthalmoscope. *Eye*, 32(11), 1766–1771. <https://doi.org/10.1038/s41433-018-0177-1>
- Mantravadi, A. V., & Vadhar, N. (2015). Glaucoma. *Primary Care: Clinics in Office Practice*, 42(3), 437–449. <https://doi.org/10.1016/j.pop.2015.05.008>
- Marshall, L. L., Hayslett, R. L., & Stevens, G. A. (2018). Therapy for Open-Angle Glaucoma. *The Consultant Pharmacist*, 33(8), 432–445. <https://doi.org/10.4140/TCP.n.2018.432>
- Medina-Mesa, E., Gonzalez-Hernandez, M., Sigut, J., Fumero-Batista, F., Pena-Betancor, C., Alayon, S., & Gonzalez, M. (2016). Estimating the Amount of Hemoglobin in the Neuroretinal Rim Using Color Images and OCT. *Current Eye Research*, 41(6), 798–805. <https://doi.org/10.3109/02713683.2015.1062112>
- Miri, M. S., Abràmoff, M. D., Kwon, Y. H., Sonka, M., & Garvin, M. K. (2017). A machine-learning graph-based approach for 3D segmentation of Bruch’s membrane opening from glaucomatous SD-OCT volumes. *Medical Image Analysis*, 39, 206–217. <https://doi.org/10.1016/j.media.2017.04.007>
- Mohamed, N. A., Zulkifley, M. A., Zaki, W. M. D. W., & Hussain, A. (2019). An automated glaucoma screening system using cup-to-disc ratio via Simple Linear Iterative Clustering superpixel approach. *Biomedical Signal Processing and Control*, 53, 101454. <https://doi.org/10.1016/j.bspc.2019.01.003>
- Moreano, J. (2019). *Glaucoma, todo lo que un estudiante de Ciencias de la Salud debe saber*. Elsevier.Com. <https://www.elsevier.com/es-es/connect/estudiantes-de-ciencias-de-la-salud/glaucoma,-todo-lo-que-un-estudiante-de-ciencias-de-la-salud-debe-saber>
- Murthi, A., & Madheswaran, M. (2012). Enhancement of optic cup to disc ratio detection in glaucoma diagnosis. *2012 International Conference on Computer Communication and Informatics*, 1–5. <https://doi.org/10.1109/ICCCI.2012.6158789>
- Ng, P. C., & Oliver, J. J. (2018). Anatomy of the eye. In *Handbook of Emergency Ophthalmology* (pp. 1–12). Springer International Publishing. [https://doi.org/10.1007/978-3-319-78945-3\\_1](https://doi.org/10.1007/978-3-319-78945-3_1)
- Orlando, J. I., Prokofyeva, E., del Fresno, M., & Blaschko, M. B. (2017). *Convolutional neural network transfer for automated glaucoma identification* (E. Romero, N. Lepore, J. Brieva, & I. Larrabide (eds.); p. 101600U). <https://doi.org/10.1117/12.2255740>
- Panda, R., Puhan, N. B., Rao, A., Padhy, D., & Panda, G. (2018). Automated retinal nerve fiber layer defect detection using fundus imaging in glaucoma. *Computerized Medical Imaging and Graphics*, 66, 56–65. <https://doi.org/10.1016/j.compmedimag.2018.02.006>
- Park, E., Liu, W., Russakovsky, O., Deng, J., Li, F.-F., & Berg, A. (2017). *ImageNet Large Scale Visual Recognition Challenge 2017 (ILSVRC2017)*. <https://image-net.org/challenges/LSVRC/2017/#loc>

- Quigley, H. A., & Broman, A. T. (2006). The number of people with glaucoma worldwide in 2010 and 2020. *The British Journal of Ophthalmology*, *90*(3), 262–267. <https://doi.org/10.1136/bjo.2005.081224>
- Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, *1*(1), 81–106. <https://doi.org/10.1007/BF00116251>
- Raghavendra, U., Fujita, H., Bhandary, S. V., Gudigar, A., Tan, J. H., & Acharya, U. R. (2018). Deep convolution neural network for accurate diagnosis of glaucoma using digital fundus images. *Information Sciences*, *441*, 41–49. <https://doi.org/10.1016/j.ins.2018.01.051>
- Rieger-Reyes, C., & Rubio-Galán, F. J. (2013). Glaucoma: implicaciones farmacológicas. *SEMERGEN - Medicina de Familia*, *39*(1), 26–33. <https://doi.org/10.1016/j.semerg.2012.05.003>
- Saeed, E., Szymkowski, M., Saeed, K., & Mariak, Z. (2019). An Approach to Automatic Hard Exudate Detection in Retina Color Images by a Telemedicine System Based on the d-Eye Sensor and Image Processing Algorithms. *Sensors*, *19*(3), 695. <https://doi.org/10.3390/s19030695>
- Sánchez-Tocino, H., Bringas-Calvo, R., & Iglesias-Cortiñas, D. (2007). Correlación entre presión intraocular, paquimetría y queratometría en una población normal. *Archivos de La Sociedad Española de Oftalmología*, *82*(5). <https://doi.org/10.4321/S0365-66912007000500004>
- Santisteban, J., & Mauricio, D. (2017). Systematic literature review of critical success factors of Information Technology startups. *Academy of Entrepreneurship Journal*, 1–23. <https://siis.unmsm.edu.pe/en/publications/systematic-literature-review-of-critical-success-factors-of-infor-2>
- Schacknow, P., & Samples, J. (2010). *The Glaucoma Book* (P. N. Schacknow & J. R. Samples (eds.)). Springer New York. <https://doi.org/10.1007/978-0-387-76700-0>
- Smits, D. J., Elze, T., Wang, H., & Pasquale, L. R. (2019). Machine Learning in the Detection of the Glaucomatous Disc and Visual Field. *Seminars in Ophthalmology*, *34*(4), 232–242. <https://doi.org/10.1080/08820538.2019.1620801>
- Soorya, M., Issac, A., & Dutta, M. K. (2019). Automated Framework for Screening of Glaucoma Through Cloud Computing. *Journal of Medical Systems*, *43*(5), 136. <https://doi.org/10.1007/s10916-019-1260-2>
- Sundaram, R., & Ravichandran, K. S. (2019). An automated eye disease prediction system using bag of visual words and support vector machine. *Journal of Intelligent & Fuzzy Systems*, *36*(5), 4025–4036. <https://doi.org/10.3233/JIFS-169963>
- Tham, Y.-C., Li, X., Wong, T. Y., Quigley, H. A., Aung, T., & Cheng, C.-Y. (2014). Global Prevalence of Glaucoma and Projections of Glaucoma Burden through 2040. *Ophthalmology*, *121*(11), 2081–2090. <https://doi.org/10.1016/j.ophtha.2014.05.013>
- Ting, D. S. W., Peng, L., Varadarajan, A. V., Keane, P. A., Burlina, P. M., Chiang, M. F., Schmetterer, L., Pasquale, L. R., Bressler, N. M., Webster, D. R., Abramoff, M., & Wong, T. Y. (2019). Deep learning in ophthalmology: The technical and clinical considerations.

- Progress in Retinal and Eye Research*, 72, 100759.  
<https://doi.org/10.1016/j.preteyeres.2019.04.003>
- Uddin, S., Khan, A., Hossain, M. E., & Moni, M. A. (2019). Comparing different supervised machine learning algorithms for disease prediction. *BMC Medical Informatics and Decision Making*, 19(1), 281. <https://doi.org/10.1186/s12911-019-1004-8>
- Van-Leeuwen, J. (2004). *Approaches in Machine Learning* (pp. 151–166).  
[https://doi.org/10.1007/978-94-017-0703-9\\_8](https://doi.org/10.1007/978-94-017-0703-9_8)
- Virgili, G., Michelessi, M., Parodi, M. B., Bacherini, D., & Evans, J. R. (2015). Laser treatment of drusen to prevent progression to advanced age-related macular degeneration. *The Cochrane Database of Systematic Reviews*, 10, CD006537.  
<https://doi.org/10.1002/14651858.CD006537.pub3>
- World Health Organization. (2020). *Blindness*. <https://www.who.int/topics/blindness/es/>
- Yin, F., Liu, J., Wong, D. W. K., Tan, N. M., Cheung, C., Baskaran, M., Aung, T., & Wong, T. Y. (2012). Automated segmentation of optic disc and optic cup in fundus images for glaucoma diagnosis. *2012 25th IEEE International Symposium on Computer-Based Medical Systems (CBMS)*, 1–6. <https://doi.org/10.1109/CBMS.2012.6266344>
- Zayat, W., & Senvar, O. (2020). Framework Study for Agile Software Development Via Scrum and Kanban. *International Journal of Innovation and Technology Management*, 17(04), 2030002. <https://doi.org/10.1142/S0219877020300025>
- Zheng, C., Johnson, T. V., Garg, A., & Boland, M. V. (2019). Artificial intelligence in glaucoma. *Current Opinion in Ophthalmology*, 30(2), 97–103.  
<https://doi.org/10.1097/ICU.0000000000000552>

**ANEXO A: Manual de usuario de la  
herramienta de apoyo**

## **1. Descripción del Sistema**

### **1.1. Introducción**

El glaucoma es una enfermedad silenciosa y difícil de identificar sin los aparatos médicos adecuados, además, estos aparatos médicos tienen un alto precio en el mercado, siendo sus precios los motivos por el que existe dificultad para diagnosticar el glaucoma en zonas rurales, donde se halla un factor económico limitante, además de la falta de médicos especializados en el tema. Qhaway es una herramienta Software creada para que se pueda aprender automáticamente a identificar ojos que tengan o no glaucoma a partir una imagen del fondo de ojo tomada por un teléfono celular.

### **1.2. Objeto**

Qhaway tiene como objetivo ser una herramienta de apoyo de bajo costo y alta precisión para el diagnóstico del glaucoma a partir de una imagen del fondo de ojo en sus diferentes estadios.

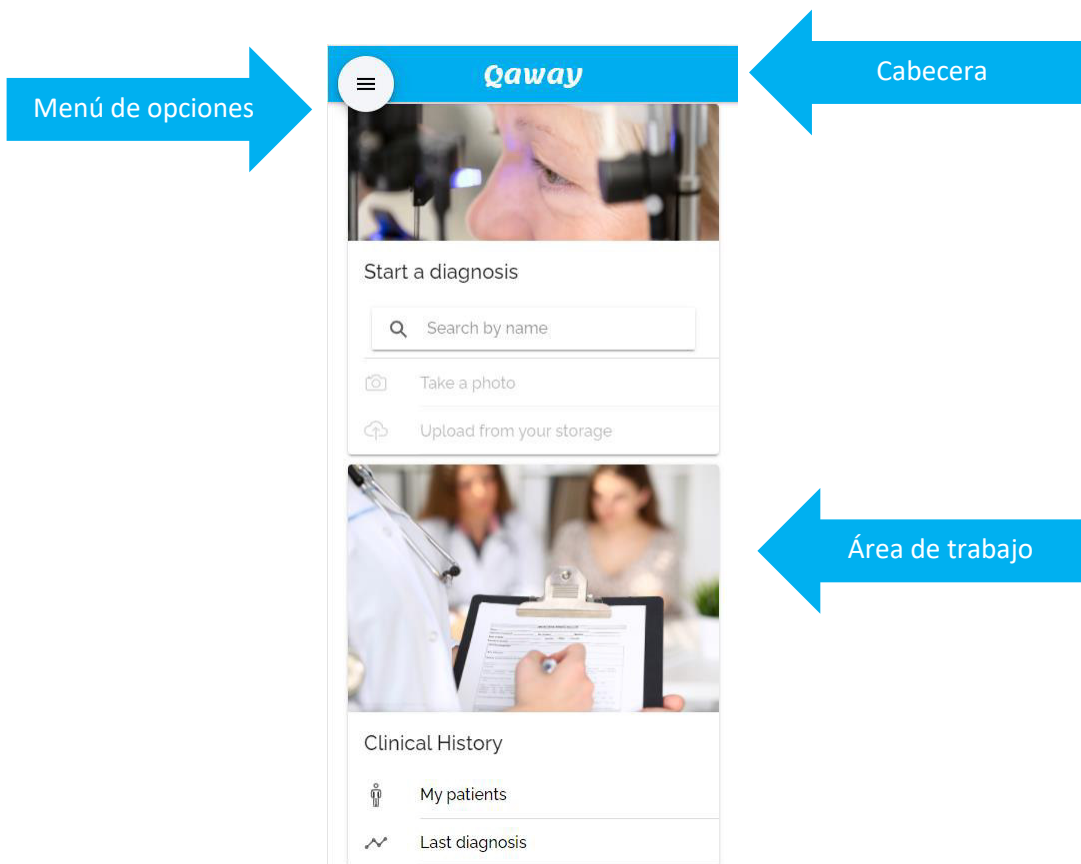
## **2. Estructura General del Sistema**

### **2.1. Componentes de la interfaz de usuario**

En este apartado, se muestra la estructura de la interfaz del sistema para el doctor, a fin de facilitar el entendimiento y mejorar la comprensión de este, a continuación, se detalla las partes que la componen:

- Cabecera
- Menú de opciones
- Área de trabajo





**Figura A.1.** Componentes de la interfaz de Qhaway

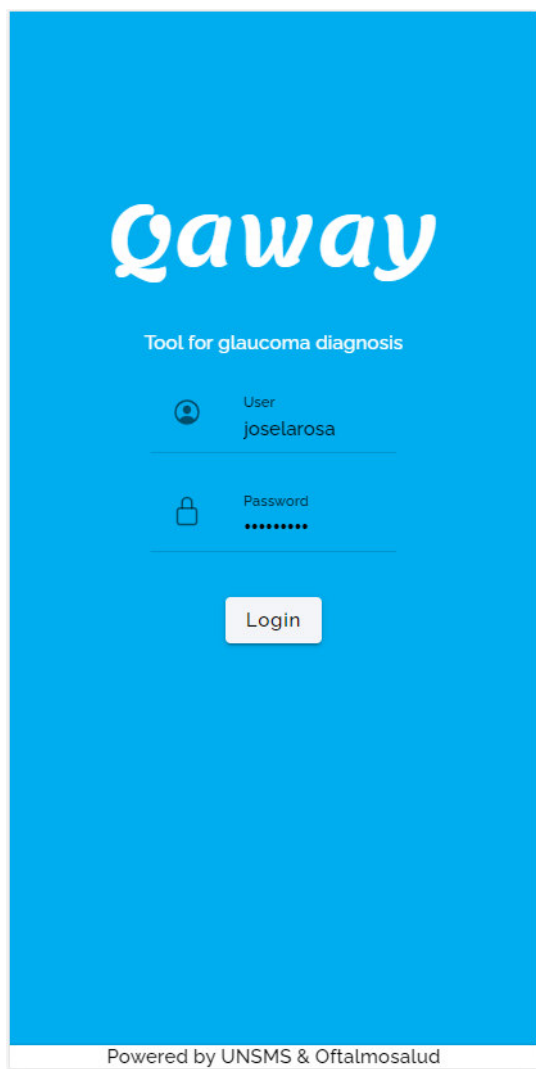
### 3. Operatividad general

En esta sección, se precisarán los pasos a seguir para acceder a Qhaway y ejecutar las funcionalidades que tiene acceso.

#### 3.1. Pantalla de inicio de sesión

Vista inicial donde uno se debe identificar para entrar a la herramienta. Para ello, se siguen los siguientes pasos:

1. Ingresar su nombre de usuario
2. Ingresar contraseña
3. El usuario pulsa el botón “Login”.




**Figura A.2.** Pantalla de inicio de sesión

### 3.2. Pantalla de herramientas

Vista principal de la herramienta que contine todas las funciones que tiene la herramienta:

- Buscar paciente: Búsqueda de pacientes a través de nombres y apellidos
- Cargar imagen: Carga/Toma de imágenes del fondo de ojo
- Mis pacientes: Información de pacientes asociados al doctor
- Últimos diagnósticos: Información de los últimos diagnósticos realizados por el doctor

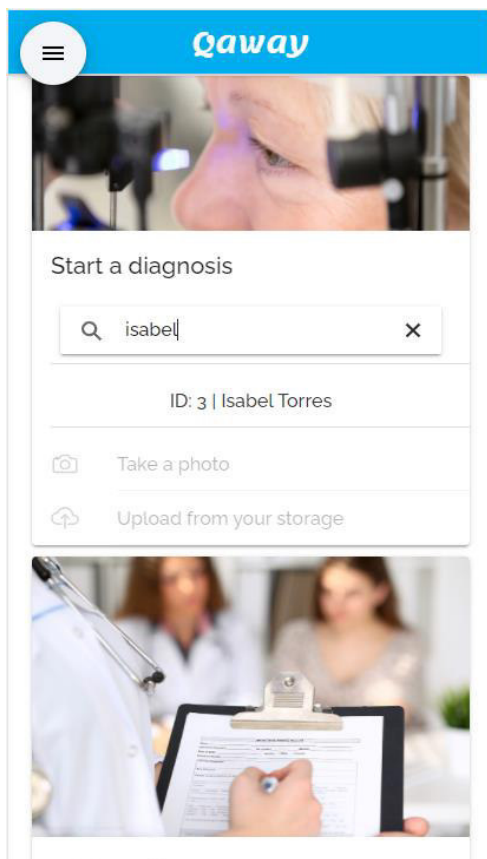


**Figura A.3.** Pantalla principal de la herramienta

### 3.2.1. Buscar paciente

Esta funcionalidad permite buscar pacientes por nombre y apellidos, para poder realizar su diagnóstico. En caso no haya un paciente seleccionado, no se podrá realizar un diagnóstico. Para poder seleccionar un paciente, se deben seguir los siguientes pasos:

1. Hacer clic en la barra de búsqueda (aparecerá un teclado virtual en caso de utilizarse con el teléfono)
2. Escribir el nombre y/o apellidos del paciente
3. Seleccionar el paciente buscado



**Figura A.4.** Búsqueda de paciente para realizar diagnóstico

### 3.2.2. Tomar/Cargar imagen

Esta funcionalidad permite tomar/cargar una imagen del fondo de ojo para su diagnóstico.

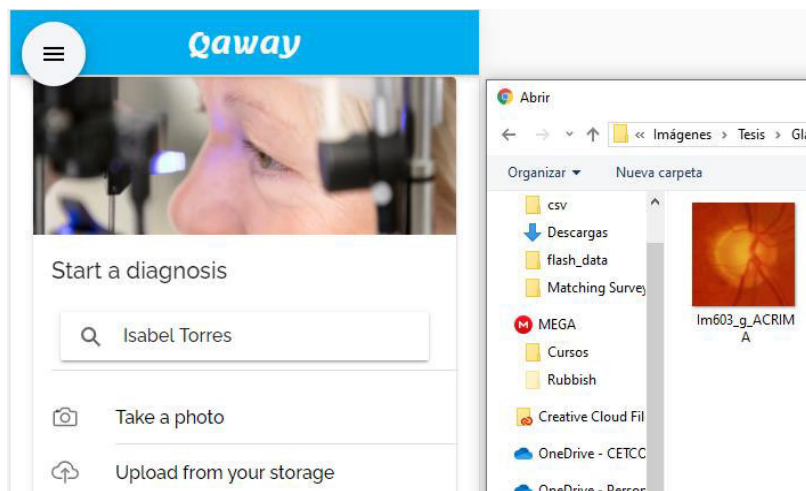
Para poder tomar/cargar una imagen, se deben seguir los siguientes pasos:

Dispositivo móvil:

1. Hacer clic en “Take a photo” (esto abrirá la cámara nativa del smartphone)
2. Seguir el procedimiento para la toma de una imagen del fondo de ojo con un oftalmoscopio indirecto
3. Tomar la foto

Ordenador:


1. Hacer clic en “Take a photo” (esto abrirá el explorador de imágenes del ordenador).
2. Seleccionar la foto por analizar
3. Hacer clic en “Subir imagen”



**Figura A.5.** Carga de una imagen del fondo de ojo desde el ordenador

### 3.2.3. Diagnóstico

Esta pantalla muestra el resultado del diagnóstico. Se ven datos relevantes del paciente y el resultado porcentual de éxito del diagnóstico.




**Figura A.6.** Búsqueda de pacientes

### 3.2.4. Mis pacientes

Esta funcionalidad permite explorar entre los pacientes que se han registrado en el sistema.

Para poder buscar un paciente, se deben seguir los siguientes pasos:

1. Hacer clic en “My Patients” (esto abrirá la vista de búsqueda de pacientes)
2. Hacer clic en la barra de búsqueda
3. Escribir el nombre y/o apellidos del paciente
4. Hacer clic en el “+” para acceder a la información del paciente

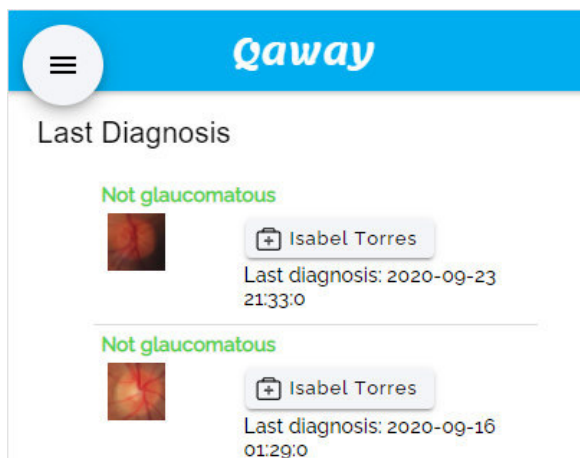


**Figura A.7.** Búsqueda de pacientes

### 3.2.5. Últimos diagnósticos

Esta funcionalidad permite acceder a la lista completa de diagnósticos que fueron realizados por el doctor en sesión, además de poder visualizar el estado y la fecha del diagnóstico y acceder al detalle del paciente. Para poder acceder a los últimos diagnósticos y ver el detalle del paciente, se deben seguir los siguientes pasos:

1. Hacer clic en “Last diagnosis” (esto abrirá la vista de últimos diagnósticos realizados por el doctor en sesión)
2. Identificar el paciente cuyo detalle se desea visualizar
3. Hacer clic en el botón con el nombre para acceder a la información del paciente




**Figura A.8.** Últimos diagnósticos del doctor en sesión



### 3.3. Vista de paciente

Esta funcionalidad permite ver el detalle del histórico del diagnóstico del paciente. Para poder acceder al detalle del paciente se deben seguir los siguientes pasos:

1. Hacer click en el nombre de un paciente. Esto abrirá la vista de últimos diagnósticos realizados por el doctor para ese paciente.
2. Identificar los diagnósticos del paciente.

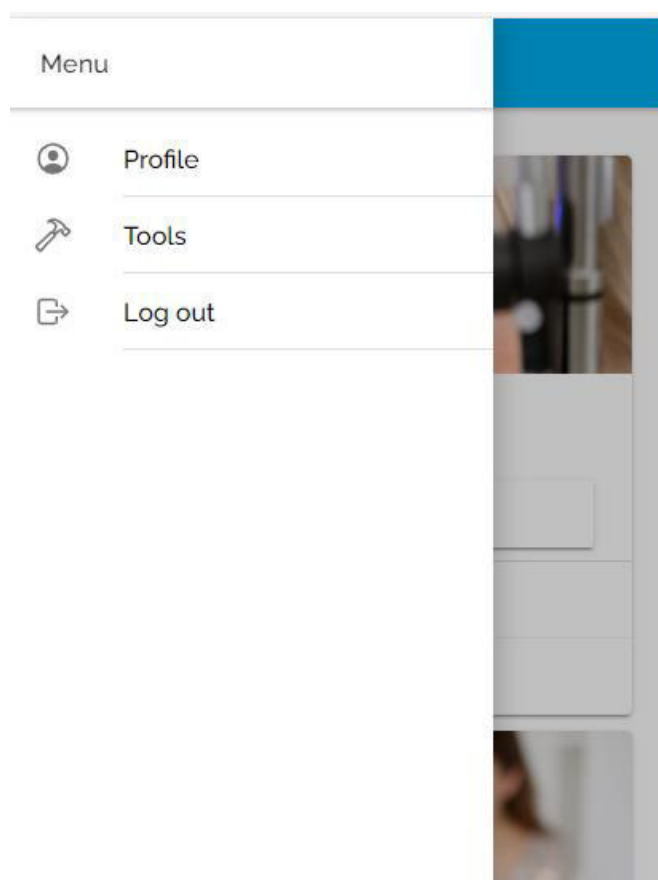


**Figura A.9.** Últimos diagnósticos del paciente

### 3.4. Barra lateral

Barra lateral que dará acceso al perfil, herramientas y cerrar sesión de la aplicación.


- Profile: Muestra el perfil del doctor conectado a la aplicación.
- Tools: Permite acceder a la pantalla principal de la herramienta.
- Log out: Permite cerrar sesión en la herramienta.



**Figura A.10.** Barra lateral de la aplicación

### 3.5. Mi perfil

Vista que mostrará la información general del doctor identificado en el sistema.



**Figura A.11.** Perfil del doctor conectado a la herramienta

#### 4. Accesos

Para acceder a la herramienta principal, se debe utilizar el siguiente enlace

<http://18.224.215.134:8080/login>

Para acceder al modo administrador, se debe utilizar el siguiente enlace

<http://52.15.118.65:8000/admin/>

El usuario administrador por defecto para ambas plataformas es el siguiente:

*Usuario: glaucomaadmin*

*Contraseña: admin2020.\$*