



Educación

Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO®
Instituto Tecnológico de Orizaba

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OPCIÓN I.- TESIS

TRABAJO PROFESIONAL

“Análisis de características para la detección temprana de la DMAE variante húmeda a partir del análisis de imágenes del fondo del ojo utilizando técnicas de visión artificial y el transformador SWIN-V2”

QUE PARA OBTENER EL GRADO DE:
MAESTRO EN SISTEMAS
COMPUTACIONALES

PRESENTA:

I.S.C. Roberto Márquez Castro

DIRECTOR DE TESIS:

Dr. José Luis Sánchez Cervantes

CODIRECTOR DE TESIS:

M.I.D.S. Jorge Ernesto González Díaz



ORIZABA, VERACRUZ, MÉXICO.

DICIEMBRE 2025

Agradecimientos

A Dios quien es el que me dio la vida, que nunca me abandono durante todo el trayecto de mi maestría, quien me da las fuerzas y la voluntad para poder seguir adelante cuando a mí ya no me quedan fuerzas.

A mi madre, mi tío ángel, mis hermanas y mis abuelos QEPD que siempre me apoyaron moral, emocional y económicamente para poder seguir adelante día con día, que siempre hacían todo lo posible y también lo imposible para sacarme adelante y ayudarme, que siempre me daban las fuerzas para ser valiente y enfrentar lo que sea y a quien sea, que siempre me han amado, que me enseñaron a nunca rendirme y siempre ser el mejor, que siempre se han preocupado por mí y por mi bienestar, que gracias a ellos soy ahora maestro, a ellos y a Dios les debo todo.

A mi director de tesis y amigo el Dr. José Luis Sánchez Cervantes, quien no solo fue mi director de tesis, sino también un guía constante, paciente y comprometido durante todo este proceso. Su acompañamiento, sus palabras de aliento a pesar de todas las veces que falle y decepcione y su inquebrantable confianza en mi capacidad fueron fundamentales para culminar este proyecto. Gracias por compartir su conocimiento con generosidad, por impulsar mi crecimiento académico y por enseñarme con el ejemplo el verdadero valor del rigor científico y la pasión por la investigación.

A mi novia Alba Adamary Castillo colorado quien es el amor de mi vida y ha sido una fuente constante de motivación para seguir adelante y superar cualquier obstáculo. A la mamá de mi novia, María del Rosario Colorado Vázquez, quien también me ha tratado como un hijo y me ha ofrecido su cariño y apoyo en todo momento. A la familia Castillo Colorado, que siempre me han recibido como uno más de ellos.

A mis amigos y hermanos de la maestría, al M.S.C. Luis Rodolfo Cabrera Elías y al M.S.C. Augusto Javier Reyes Delgado por todo el apoyo y el ánimo que me brindaron a lo largo de la maestría, también por compartir su conocimiento con generosidad y por estar siempre ahí, incluso en los momentos de duda.

A mis maestros, a la M.S.C Alma Ivonne Sánchez García que desde que entre al tecnológico siempre me ha apoyado, guiado y compartido sus conocimientos para que pudiera concluir la ingeniería y ahora la maestría, al M.I.D.S. Jorge Ernesto González Díaz por ser mi codirector y también por brindarme su tiempo y apoyo, también al Dr. Giner Alor Hernández por darme su voto de confianza durante todo el trayecto de la maestría cuando casi nadie confiaba en mí y que gracias a eso me dieron la oportunidad de entrar a la maestría y hoy de lograr concluirla, también por todas sus palabras de ánimo y confianza.

Por último, quiero agradecer al Tecnológico Nacional de México – Instituto Tecnológico de Orizaba por brindarme la oportunidad de realizar el programa de Maestría en Sistemas Computacionales y también a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) por el apoyo financiero recibido para completar mis estudios de posgrado.

Agradecimientos	i
Índice de tablas	vii
Índice de figuras.....	ix
Resumen	xi
Introducción.....	1
Capítulo 1. Antecedentes	3
1.1 Marco teórico	3
1.1.1 Inteligencia artificial	3
1.1.1.2 Aprendizaje supervisado	3
1.1.1.3 Algoritmos de aprendizaje supervisado	4
1.1.1.4 Naïve bayes	4
1.1.1.5 Regresión lineal.....	4
1.1.1.6 Regresión logística	5
1.1.1.7 Máquinas de vectores de soporte (SVM).....	5
1.1.1.8 K vecino más cercano (KNN)	5
1.1.2 Aprendizaje no supervisado	5
1.1.3 Aprendizaje por refuerzo	6
1.1.4 Red neuronal.....	6
1.1.4.1 Tipos de redes neuronales	6
1.1.6 Modelo Transformer	7
1.1.7 Procesamiento de lenguaje natural (NLP)	8
1.1.8 Transformadores de visión (Vision Transformer).....	8
1.1.9 Transformador Swin (Swin Transformer).....	8
1.1.10 Transformadores generativos preentrenados (GPT)	9
1.1.11 Transformador de imágenes eficiente en datos (DeiT).....	9
1.1.12 Entrenamiento previo BERT de transformadores de imágenes (BeiT).....	10
1.1.13 Visión artificial	10
1.1.14 Sobre Ajuste en Aprendizaje automático	10
1.1.15 Sub-Ajuste en Aprendizaje Automático.....	11
1.1.16 Aumento de datos	11
1.1.17 Degeneración Macular Asociada con la Edad (DMAE)	11
1.1.18 Características DMAE Húmeda.....	13
1.1.18.1 Pérdida brusca y progresiva de agudeza visual.	13
1.1.18.2 Escotoma central.....	13
1.1.18.3 Metamorfopsia.....	13
1.1.18.4 Hemorragia subretiniana.....	13
1.1.18.5 Hemorragia intrarretiniana	14

1.1.18.6 Desprendimiento exudativo	14
1.1.18.7 Desprendimiento del EPR.....	14
1.1.18.8 Atrofia subfoveal	15
1.1.18.9 Exudados lipídicos.....	15
1.2 Situación tecnológica, económica y operativa de la empresa.....	15
1.3 Planteamiento del problema.....	15
1.4 Objetivo general y objetivos específicos.....	16
1.4.1 Objetivo general.....	16
1.4.1.2 Objetivos específicos	17
1.5 Justificación.....	18
Capítulo 2. Estado de la practica.....	19
2.1 Trabajos relacionados.....	19
2.2 Análisis comparativo.....	29
2.3 Propuesta de solución	30
2.3.1 Tecnologías de la propuesta de solución	31
2.3.1.1 Angular	31
2.3.1.2 Python	31
2.3.1.3 JavaScript.....	32
2.3.1.4 PostgreSQL	32
2.3.1.5 Visual Studio Code	33
2.3.1.6 Keras	33
2.3.1.7 PyTorch.....	34
Capítulo 3. Aplicación de la metodología	35
3.1 Planificación	36
3.1.1 Asignación de roles del proyecto	39
3.1.2 Plan de entrega del proyecto	39
3.2 Diseño	40
3.2.1 Diseño de la arquitectura.....	40
3.2.1.1 Capas de la arquitectura.....	41
3.2.1.2 Modularidad	42
3.2.1.3 Flujo de trabajo.....	43
3.2.2 Arquitectura del transformador de visión.....	44
3.3 Análisis de requerimientos.....	47
3.3.1 Requisitos funcionales	47
3.3.2 Requisitos no funcionales.....	50
3.3.3 Casos de uso	52
3.3.3.1 Narrativas de casos de uso.....	53

3.3.4 Diagrama Entidad-Relación	61
3.3.4.1 Diccionario de datos	62
3.3.5 Diagrama de clases.....	65
3.3.6 Diseño del módulo web.....	66
3.4 Codificación y Desarrollo	71
3.4.1 Conjunto de datos de entrenamiento.....	71
3.4.1.1 Obtención de conjuntos de datos	71
3.4.1.2 Etiquetado de imágenes.....	72
3.4.1.3 Aumento de datos.....	73
3.4.1.4 Creación del conjunto de datos.....	74
3.4.2 Entrenamiento del modelo.....	75
3.4.2.1 Implementación del modelo	75
3.4.3 Resultados del modelo	77
3.4.3.1 Evaluación del modelo	78
3.4.4 Desarrollo y control de interfaces graficas.....	79
3.4.4.1 Fragmento de código login.html — Acceso	79
3.4.4.2 Fragmento de código login.css	80
3.4.4.3 Fragmento de código Multiclass Deteccion.html	80
3.4.4.4 Fragmento de código Multiclass Deteccion.css.....	81
3.4.4.5 Fragmento de código History patient.html	82
3.4.4.6 Fragmento de código History patient.css.....	83
3.4.4.7 Fragmento de código Lista-usuarios.html	84
3.4.4.8 Fragmento de código Lista-usuarios.css.....	85
3.4.4.9 Fragmento de código Report eye.html.....	86
3.4.4.10 Fragmento de código Report eye.css	87
3.4.4.11 Fragmento de código Registrar usuario.html.....	88
3.4.4.12 Fragmento de código Registrar usuario.css	89
3.4.4.13 Fragmento de código Carga de imagen de fondo de ojo.....	90
3.4.4.14 Fragmento de código para mostrar alerta	91
3.4.5 Creación de la base de datos.....	92
3.4.6 Consumo de la API de hugging face	93
3.5 Implementación	93
3.5.1 Inicio de aplicación Web.....	93
3.5.2 Interfaz - detección multiclase	94
3.5.3 Interfaz – reporte del análisis	95
3.5.4 Interfaz – historial de análisis.....	95
3.5.5 Interfaz – lista de pacientes	96
3.5.6 Interfaz – registrar usuario.....	96

Capítulo 4. Resultados.....	97
4.1 Caso de estudio	97
4.1.1 Evaluación y resultados.....	98
4.1.1.1 Paciente con DMAE Húmeda	100
4.1.1.2 Paciente con DMAE Seca	101
4.1.1.3 Paciente sin DMAE.....	102
4.1.1.4 Exportar Datos	103
4.1.1.5 Primera evaluación.....	104
4.1.1.6 Segunda evaluación.....	104
Capítulo 5. Conclusiones y recomendaciones.....	106
5.1 Conclusiones.....	106
5.2 Recomendaciones	107
5.2.1 Ajustes en el proceso de aumento de datos	107
5.2.2 Combinación con la DMAE seca	107
Productos Académicos	108
6.1 Artículos de congreso	108
6.1.1 Primer articulo.....	108
6.1.1.1 Publicación de articulo	109
6.2 Ponencias	110
6.2.1 Primera ponencia	110
6.3 Retribución social	111
6.3.1 Primera retribución social	111
6.3.2 Segunda retribución social	112
6.3.3 Tercera retribución social	113
6.3.4 Cuarta retribución social	114
6.3.5 Quinta retribución social	115
6.3.6 Sexta retribución social	116
6.3.7 Séptima retribución social	117
6.3.8 Octava retribución social.....	118
6.3.9 Novena retribución social.....	119
6.4 Poster y video.....	120
6.5 Registro de derechos de autor	121
Referencias bibliográficas.....	122

Índice de tablas

Tabla 2.1 Análisis comparativo de los trabajos relacionados.....	29
Tabla 2.2 Solución propuesta.....	30
Tabla 3.1 Historia de usuario: registro de usuario.....	36
Tabla 3.2 Historia de usuario: registro de paciente.....	36
Tabla 3.3 Historia de usuario: clasificación de imagen de fondo de ojo.....	37
Tabla 3.4 Historia de usuario: consultar historial de clasificaciones.	37
Tabla 3.5 Historia de usuario: recuperación de reporte de clasificación.....	37
Tabla 3.6 Historia de usuario: actualizar datos de usuario.....	38
Tabla 3.7 Historia de usuario: consultar listado de pacientes.	38
Tabla 3.8 Historia de usuario: actualizar datos de paciente.	38
Tabla 3.9 Roles del proyecto.....	39
Tabla 3.10 Plan de entrega proyecto	39
Tabla 3.11 Requisitos funcionales – Registrar usuario	47
Tabla 3.12 Requisitos funcionales – Registrar paciente	47
Tabla 3.13 Requisitos funcionales – Clasificar imagen de fondo de ojo	48
Tabla 3.14 Requisitos funcionales – Consulta de clasificaciones	48
Tabla 3.15 Requisitos funcionales – Recuperar reporte de clasificación.....	48
Tabla 3.16 Requisitos funcionales – Actualizar datos de usuario.....	49
Tabla 3.17 Requisitos funcionales – Consultar datos de pacientes.....	49
Tabla 3.18 Requisitos funcionales – Actualizar datos de paciente.	50
Tabla 3.19 Requisitos funcionales – Eliminar datos de paciente.....	50
Tabla 3.20 Requisitos no funcionales – Base de datos.	50
Tabla 3.21 Requisitos no funcionales – Diseño responsivo.	51
Tabla 3.22 Requisitos no funcionales – Disponibilidad.....	51
Tabla 3.23 Requisitos no funcionales – Rendimiento.....	51
Tabla 3.24 Requisitos no funcionales – Internet.....	52
Tabla 3.25 Narrativa de caso de uso – Registrar Paciente	53
Tabla 3.26 Narrativa de caso de uso – Generar Diagnostico	54
Tabla 3.27 Narrativa de caso de uso – Consultar Historial de Reportes.....	55
Tabla 3.28 Narrativa de caso de uso – Consultar Lista de Pacientes.....	56
Tabla 3.29 Narrativa de caso de uso – Actualizar Datos de Paciente	57
Tabla 3.30 Narrativa de caso de uso – Eliminar Datos	58

Tabla 3.31 Narrativa de caso de uso – Actualizar Datos de Usuario.....	59
Tabla 3.32 Datos_Generales.....	62
Tabla 3.33 Usuarios.....	62
Tabla 3.34 Pacientes	63
Tabla 3.35 Reportes	63
Tabla 3.36 Métricas de evaluación por clase.	79
Tabla 4.1 Métricas de evaluación por modelo final.	100
Tabla 4.2 Resultados de primera iteración de pruebas.....	104
Tabla 4.3 Resultados de segunda iteración de pruebas.	105

Índice de figuras

Figura 1.1 Arquitectura de Swin Transformer. Imagen accedida en ¹	9
Figura 1.2 DMAE avanzada en su manifestación seca. Imagen accedida en ²	12
Figura 1.3 DMAE avanzada en su manifestación húmeda. Imagen accedida en ²	12
Figura 1.4 Ojo con hemorragia retiniana. Imagen accedida en ³	14
Figura 3.1 Fases de la metodología XP tomada de [44]	35
Figura 3.2 Diseño de la arquitectura.	41
Figura 3.3 Flujo de trabajo del módulo.	44
Figura 3.4 Arquitectura del transformador de visión Swin Transformer V2.	45
Figura 3.5 Diagrama de casos de uso.	52
Figura. 3.6 Diagrama Entidad-Relación	61
Figura. 3.7 Diagrama Entidad-Relación	65
Figura. 3.8 Pantalla Acceso-Login	66
Figura. 3.9 Pantalla - Registro de usuario.	67
Figura. 3.10 Pantalla – Realizar detección (Generar Diagnostico).	68
Figura. 3.11 Pantalla – Reporte del análisis.	69
Figura. 3.12 Pantalla – Historial de análisis	70
Figura 3.13 Imágenes clasificadas en los diferentes grados de avance.	72
Figura 3.14 Conjunto de datos en Hugging Face.	74
Figura 3.15 Métricas de entrenamiento (precisión y perdida).	77
Figura 3.16 Tarjeta del modelo.	78
Figura 3.17 Login WAMDS2	94
Figura 3.18 Detección multiclase	94
Figura 3.19 Interfaz resultados detección	95
Figura 3.20 Interfaz historial de análisis.	95
Figura 3.21 Interfaz Lista de pacientes.	96
Figura 3.22 Interfaz registro de usuario.	96
Figura 4.1 Imágenes de caso de uso.	97
Figura 4.2 Tarjeta del modelo final.	98
Figura 4.3 Matriz de confusión del modelo.	99
Figura 4.4 Curva roc del modelo	99
Figura 4.5 Clasificación Paciente anónimo 1	100
Figura 4.6 Resultado de predicción con paciente anónimo 1	100

Figura 4.7 Clasificación paciente anónimo 2	101
Figura 4.8 Resultado de predicción con paciente anónimo 2	101
Figura 4.9 Clasificación paciente anónimo 3	102
Figura 4.10 Resultado de predicción con paciente anónimo 3	102
Figura 4.11 Presentación del historial de análisis.....	103
Figura 4.12 Presentación de reporte en formato PDF.....	103
Figura 4.13 Presentación del historial de análisis en PDF.....	104

Resumen

La degeneración macular asociada con la edad (DMAE) es una afección ocular, la cual se presenta cuando se daña estructura en el fondo central de la retina, conocida como mácula lútea. Esta se caracteriza por la presencia de drusas en sus primeras etapas y vascularización y hemorragias en su etapa más tardía. Según la Organización Mundial de la Salud (OMS), la DMAE representa una de las principales causas de ceguera entre adultos mayores alrededor del mundo y se tornará un mal cada vez más común a medida que la población mundial envejezca.

En su manifestación más severa es la conocida como variante húmeda, la cual es una evolución de la DMAE seca en estado avanzado, el paciente ya presenta una afectación severa e irreparable de la visión, aunque, la degeneración macular es tratable en sus primeras etapas, por lo que es indispensable la detección temprana de la enfermedad, sin embargo, esta no presenta síntomas hasta etapas intermedias.

A partir de lo anteriormente expuesto, surge la idea central de este proyecto: desarrollar un módulo de software web dedicado al análisis de características para la detección temprana de la degeneración macular asociada con la edad. Este módulo utilizó técnicas avanzadas de visión artificial y aprendizaje profundo para examinar imágenes del fondo del ojo, con el objetivo de identificar y clasificar la enfermedad en sus distintos estadios.

La contribución principal de este proyecto radica en su utilidad para los profesionales de la salud en el diagnóstico temprano de la degeneración macular relacionada con la edad en sus diferentes fases, dando énfasis a la variante húmeda. Dada la importancia crucial de la detección temprana, este módulo ayuda a evitar la pérdida total de la visión en aquellos individuos afectados por esta enfermedad. Además, al evitar el deterioro de la calidad de vida tanto de los pacientes como de sus familiares, se convierte en una herramienta invaluable en el ámbito de la salud visual.

Abstract

Age-related macular degeneration (AMD) is an eye condition that occurs when the structure in the central part of the retina, known as the macula lutea, is damaged. It is characterized by the presence of drusen in its early stages and vascularization and hemorrhages in its later stages. According to the World Health Organization (WHO), AMD is one of the leading causes of blindness among older adults worldwide and will become an increasingly common issue as the global population ages.

In its most severe manifestation, it is known as the wet variant, which is an advanced stage of dry AMD. In this stage, the patient already has severe and irreparable vision impairment. Although macular degeneration is treatable in its early stages, early detection of the disease is essential. However, it does not present symptoms until intermediate stages.

From the above, the central idea of this project arises: to develop a web-based software module dedicated to analyzing features for the early detection of age-related macular degeneration. This module utilizes advanced techniques in computer vision and deep learning to examine images of the eye's fundus, with the goal of identifying and classifying the disease in its various stages.

The main contribution of this project lies in its utility for healthcare professionals in the early diagnosis of age-related macular degeneration in its different phases, with a particular focus on the wet variant. Given the crucial importance of early detection, this module helps prevent total vision loss in individuals affected by this disease. Furthermore, by preventing the deterioration of the quality of life for both patients and their families, it becomes an invaluable tool in the field of visual health.

Introducción

Existen varias enfermedades que afectan la visión de las personas, tales como cataratas, glaucoma, y retinopatía diabética. Estas representan un desafío significativo para la salud ocular a nivel mundial. Sin embargo, entre estas condiciones, la degeneración macular asociada con la edad (DMAE) destaca como una preocupación creciente, especialmente en un contexto donde la esperanza de vida ha aumentado y la proporción de personas mayores en la población está en constante incremento.

La DMAE es una de las principales causas de ceguera a nivel global, afectando principalmente a países desarrollados debido a su estrecha asociación con condiciones como la obesidad, la diabetes, la hipertensión y el tabaquismo, todas ellas comunes en México. Esta enfermedad ocular presenta dos formas principales: la húmeda y la seca. Para este proyecto, se focaliza en la manifestación húmeda de la DMAE, que se caracteriza por la presencia de vascularización y hemorragias en la retina del paciente.

Diversas investigaciones demuestran la eficacia del uso de técnicas de visión artificial y aprendizaje profundo en la detección de la degeneración macular, permitiendo identificar las características distintivas asociadas a la enfermedad. Un nuevo enfoque en este campo es la aplicación de algoritmos de inteligencia artificial conocidos como Transformers para la detección de objetos en imágenes. Estos superan en eficacia a las redes neuronales convolucionales, que antes se consideraban el estándar en el análisis y clasificación de imágenes.

El objetivo de este proyecto es utilizar los Transformadores de visión para clasificar imágenes del fondo del ojo y determinar la presencia y el nivel de afectación de la DMAE. Se enfoca particularmente en las etapas tardías de la enfermedad, principalmente en la variante húmeda, la cual es la manifestación más severa de la enfermedad.

El presente trabajo se divide en cinco capítulos. El primer capítulo presenta los antecedentes del trabajo, que incluyen el marco teórico, la formulación del problema, así como el análisis de la situación tecnológica. También se especifican el objetivo general y los objetivos específicos, junto con la justificación del estudio. En el segundo capítulo, se expone el estado actual de la práctica y se realiza un análisis comparativo de los trabajos previos relacionados

con el tema. El tercer capítulo detalla la metodología utilizada, explicando los pasos seguidos para resolver el problema planteado. En el cuarto capítulo, se presentan los resultados obtenidos a través de un caso de estudio. Finalmente, el quinto capítulo expone las conclusiones del proyecto, junto con las recomendaciones para futuras investigaciones.

Capítulo 1. Antecedentes

En este capítulo se presentan los términos relevantes para el estudio del presente tema de tesis. Así como el objetivo general, objetivos específicos, justificación y la problemática a resolver del presente tema.

1.1 Marco teórico

A continuación, se presentan el conjunto de términos relacionados con el tema de investigación.

1.1.1 Inteligencia artificial

Se denomina inteligencia artificial (IA) al área de la informática enfocada en la resolución desafíos cognitivos que suelen estar relacionados con las capacidades humanas, a saber, el aprendizaje, la comprensión e identificación de imágenes [1]. La inteligencia artificial tiene como propósito desarrollar sistemas capaces de aprender por sí mismos y extraer sentido de la información. De este proceso de abstracción, los conocimientos son aplicados para abordar nuevas situaciones de forma análoga a como lo haría un ser humano. Algunas de las principales tecnologías de la IA son: Procesamiento del lenguaje natural, *Machine Learning* y *Deep Learning* por mencionar algunos ejemplos.

1.1.1.1 Aprendizaje automático (*Machine Learning*)

El aprendizaje automático (*ML*) constituye una subdivisión de la inteligencia artificial, enfocada en la creación de sistemas los cuales adquieren conocimiento y según sea el caso mejoran su desempeño en una tarea mediante la información que procesan [2].

A menudo, aprendizaje automático e IA son mencionados a la par y, en ocasiones, se utilizan de manera intercambiable, sin embargo, no son términos equivalentes. Es necesario señalar que, aunque todo aprendizaje automático es parte de la IA, no todos los sistemas de IA se basan en los procesos aprendizaje automático.

1.1.1.2 Aprendizaje supervisado

Se conoce como aprendizaje supervisado al uso de conjuntos de datos etiquetados para el entrenamiento de algoritmos, los cuales hacen clasificaciones y/o predicciones de datos con precisión [3].

Durante el proceso de validación cruzada, los modelos afinan sus ponderaciones conforme se introducen los datos hasta lograr un ajuste adecuado. Esta rama del aprendizaje automático se encuentra dentro del campo más amplio de la inteligencia artificial.

1.1.1.3 Algoritmos de aprendizaje supervisado

En los procesos de *machine learning* supervisados, se utilizan varios algoritmos y técnicas de cálculo. A continuación, se presenta breves explicaciones sobre algunos de los métodos de aprendizaje más comúnmente utilizados:

1.1.1.4 Naive bayes

Naive Bayes es un método de clasificación basado en el principio de independencia condicional de clase del Teorema de Bayes [3]. Esto implica que la presencia de una característica no influye en la presencia de otra para calcular la probabilidad de un resultado, cada predictor tiene un efecto igual sobre dicho resultado. Existen tres variantes de clasificadores bayesianos ingenuos: multinomial, de Bernoulli y Gaussiano.

Naive Bayes es empleado principalmente en tareas de clasificación de texto, detección de spam y en diversos sistemas de recomendación, entre otras.

1.1.1.5 Regresión lineal

La regresión lineal es empleada para determinar la relación entre una variable dependiente y una o más variables independientes. Es usualmente utilizada en predicción de resultados futuros [3]. Cuando solo hay una variable independiente y una variable dependiente involucradas, se denomina regresión lineal simple. A medida que fueron añadidas más variables independientes, se torna en una regresión lineal múltiple. Para ambos casos, el objetivo es obtener la línea de mejor ajuste que se calcula utilizando el método de mínimos cuadrado.

1.1.1.6 Regresión logística

A diferencia de la regresión lineal (que se aplica cuando las variables dependientes son de naturaleza continua) la regresión logística es utilizada para variables dependientes categóricas, los cuales representan resultados binarios como "verdadero" y "falso" o "sí" y "no". Ambos modelos de regresión buscan comprender las relaciones entre los datos de entrada, sin embargo, la regresión logística es empleada principalmente en la resolución de problemas de clasificación binaria, por ejemplo, la detección de spam [3].

1.1.1.7 Máquinas de vectores de soporte (SVM)

Las máquinas de vectores de soporte son modelos de aprendizaje supervisado ampliamente conocidos. Desarrollados originalmente por Vladimir Vapnik, se emplean tanto en la clasificación como en la regresión de datos [3]. No obstante, tienen su principal aplicación en problemas de clasificación, donde construye un hiperplano que maximiza la distancia entre dos clases de puntos de datos.

1.1.1.8 K vecino más cercano (KNN)

También conocido como KNN, el algoritmo de vecinos más cercanos es un método no paramétrico que clasifica los datos en función de su cercanía y relación con otros datos disponibles [3].

Este algoritmo parte de la siguiente premisa: los puntos de datos similares tienden a estar cerca unos de otros. Por lo tanto, busca calcular la distancia entre puntos de datos, típicamente utilizando la distancia euclidiana, para luego asignar una categoría basada en la más común de estas o en el promedio de las categorías más cercanas.

Por su simplicidad y rapidez de cálculo, es muy popular entre científicos de datos, sin embargo, a medida que aumenta el tamaño de los conjuntos de datos, el tiempo requerido para el procesamiento también aumenta, es decir, presenta una baja escalabilidad, lo que lo hace menos apto para trabajar con conjuntos de datos muy grandes.

1.1.2 Aprendizaje no supervisado

Se trata de un tipo de modelo de aprendizaje que identifica patrones basándose en datos que carecen de etiquetas, es decir, conjuntos de datos que no tienen una estructura definida [4].

A diferencia del aprendizaje supervisado, el resultado final no está predefinido, en cambio, el algoritmo analiza los datos y los organiza en grupos según encuentra diferentes características que los relacionan. De ahí que, el aprendizaje no supervisado es útil para la detección patrones y llevar a cabo un modelado descriptivo.

1.1.3 Aprendizaje por refuerzo

El aprendizaje por refuerzo se entiende como un modelo de aprendizaje automático basado en la premisa de "*aprender haciendo*"[4]. En este enfoque, un "agente" aprende como llevar a cabo una tarea específica a través de un proceso de ensayo y error, tal proceso se conoció como ciclo de reacción, y se realiza hasta que se logra un rendimiento satisfactorio. Durante el proceso, el agente recibe una retroalimentación positiva cuando ejecuta la tarea correctamente y una retroalimentación negativa tiene un desempeño deficiente. Un ejemplo común de aprendizaje por refuerzo podría ser el entrenar a una mano robótica para recoger una pelota.

1.1.4 Red neuronal

Una red neuronal es un mecanismo compuesto de neuronas artificiales (denominadas a menudo como perceptrones), que son unidades de procesamiento empleadas para la clasificaron y análisis datos [4]. Los datos se introducen en la primera capa de la red neuronal, donde cada perceptrón toma decisiones y transmite la información a los nodos de la capa siguiente.

1.1.4.1 Tipos de redes neuronales

Existen variedad de redes neuronales, una breve descripción de las más relevantes se realiza a continuación:

Las redes neuronales prealimentadas (FF): Una de las variantes clásicas de las redes neuronales. En estas los datos se desplazan en una única dirección a través de capas de neuronas artificiales hasta alcanzar el resultado deseado.

Las redes neuronales recurrentes (RNN): se distinguen de las redes de alimentación directa porque suelen trabajar con datos de series temporales o secuencias. A diferencia de

las FF (que emplean ponderaciones en cada nodo) las RNN tienen la capacidad de "recordar" lo sucedido en la capa previa, lo cual influye en la salida actual.

Las RNN de memoria a largo/corto plazo (LSTM): son una versión avanzada de RNN que retiene información de capas anteriores, esto a través del uso de "celdas de memoria", lo cual las hace especialmente útiles para tareas como lo son el reconocimiento de voz y la predicción.

Las redes neuronales convolucionales (CNN): este tipo de redes es ampliamente utilizadas en la inteligencia artificial contemporánea, especialmente para la clasificación y reconocimiento de imágenes. En estas redes se emplean capas convolución y agrupación, para filtrar las distintas partes que componen una imagen antes de fusionarlas nuevamente en una capa completamente conectada.

1.1.5 Aprendizaje profundo (*Deep Learning*)

Es una técnica de la inteligencia artificial que instruye a las computadoras sobre cómo procesar los datos basada en el funcionamiento del cerebro humano (mediante el uso de nodos que semejan las neuronas) [5]. Los modelos de aprendizaje profundo tienen la capacidad de identificar patrones complejos en tipos de datos diversos, como lo son imágenes, textos y sonidos, entre otros. Esto con el objetivo de generar información precisa y realizar predicciones. Es mediante el uso de métodos de aprendizaje profundo, que es posible la automatización de tareas que suelen requerir de la intervención humana, dígase la descripción de imágenes o la conversión de texto a audio y viceversa.

El aprendizaje profundo simplifica parte del procesamiento preliminar de datos, que suele ser necesario en el aprendizaje automático convencional.

La capacidad de manejar y analizar datos no estructurados (como texto e imágenes) de estos algoritmos, es lo que permite automatizar la extracción de características y reducir la dependencia de expertos humanos en diversos procesos.

1.1.6 Modelo Transformer

Los transformers o transformadores son una forma de arquitectura de red neuronal que modifica o transforma una secuencia de entrada en una secuencia de salida [6]. Para lograrlo,

estos modelos toman en cuenta el contexto y la relación entre los diferentes elementos de la secuencia. Los transformadores procesan secuencias largas en su totalidad utilizando cálculos paralelos, esto consigue una reducción considerable en el tiempo de entrenamiento, así también como de procesamiento. Este avance ha abierto la posibilidad del entrenamiento de modelos de lenguaje de gran tamaño (LLM), como BERT y el mismo GPT, capaces de aprender representaciones lingüísticas complejas.

1.1.7 Procesamiento de lenguaje natural (NLP)

El procesamiento del lenguaje natural (PLN) es la tecnología de aprendizaje automático otorga la capacidad a las computadoras de comprender, analizar y manipular el lenguaje humano [7].

1.1.8 Transformadores de visión (Vision Transformer)

Los Transformers de Visión, son modelos que utilizan la estructura transformer para realizar clasificación de imágenes [8]. En contraposición a otras tecnologías para la clasificación de imágenes (como las CNN), que consideran a una imagen como una matriz de píxeles, los modelos transformer interpretan los datos visuales como una secuencia de parches con un tamaño fijo, de manera análoga a cómo se analizan las palabras en una oración. Cada parche se transforma y se incrusta de forma lineal y previamente se procesa en secuencia mediante un codificador de transformadores convencional. En el proceso se incluyen incrustaciones posicionales para conservar la información sobre la disposición espacial. Este procedimiento (conocido como autoatención global) permite que el modelo capture las relaciones entre todos los pares de parches, sin importar su posición en la imagen.

1.1.9 Transformador Swin (Swin Transformer)

El transformador Swin representa un tipo de transformador en el ámbito de la visión que elabora mapas de características jerárquicas mediante la fusión de parches de imágenes en capas más profundas [8]. Su innovación radica en que, su complejidad de cálculo es proporcional al tamaño de la imagen de entrada, esto se debe a que realiza el cálculo de autoatención únicamente dentro de cada ventana local. Por ende, este modelo desempeña un rol clave en diversas aplicaciones, tanto para la clasificación de imágenes como para tareas

de reconocimiento detallado. Su arquitectura se detalla en la Figura 1.1.




Figura 1.1 Arquitectura de Swin Transformer. Imagen accedida en¹

1.1.10 Transformadores generativos preentrenados (GPT)

Estos transformadores son conocidos como GPT, y constituyen una serie de modelos de redes neuronales que se basan en la arquitectura de transformadores [8].

La aparición de estos modelos representó un hito importante en el campo de la inteligencia artificial, especialmente en lo que respecta a aplicaciones de IA generativa. Los modelos GPT posibilitan a las aplicaciones, la generación de contenido diverso, como texto, imágenes y música, de manera similar a la humana, además son capaces responder a preguntas y mantener una conversación de manera coherente.

1.1.11 Transformador de imágenes eficiente en datos (DeiT)

Un transformador de imágenes eficiente en datos es un tipo de transformador diseñado específicamente para la clasificación de imágenes [8]. Este modelo se entrena empleando una técnica de entrenamiento denominada estrategia “profesor-alumno”, enfocada en la destilación de un token.

¹Ze Liu, “Swin Transformer: Hierarchical Vision Transformer using Shifted Windows”, Microsoft

1.1.12 Entrenamiento previo BERT de transformadores de imágenes (BeiT)

Este modelo es una representación visual auto-supervisada inspirada en BERT, una técnica popular en el procesamiento del lenguaje natural (PLN) [8]. Este método innovador utiliza el modelado de imágenes enmascaradas para el pre-entrenamiento de los transformadores visuales. Al lograr resultados sobresalientes en tareas como clasificación de imágenes y segmentación semántica, BEIT expande los límites de la inteligencia artificial visual.

1.1.13 Visión artificial

Se conoce como visión artificial, al campo de la inteligencia artificial (IA), que capacita a sistemas informáticos para la extracción información significativa de imágenes, vídeos u otras entradas visuales, permitiéndoles tomar decisiones u ofrecer recomendaciones en función de tal información [9]. A diferencia del proceso biológico de los humanos (donde la información visual se procesa a través de retinas, nervios ópticos y la corteza visual), la visión artificial emplea cámaras, datos y algoritmos para entrenar a las máquinas en dichas tareas. Esto brinda a un sistema entrenado la posibilidad de inspeccionar productos o procesos de fabricación, mientras analiza miles de elementos por minuto, superando rápidamente las capacidades humanas al detectar defectos o problemas sutiles que podrían pasar desapercibidos.

1.1.14 Sobre Ajuste en Aprendizaje automático

Se conoce como sobreajuste al fenómeno del aprendizaje automático que ocurre cuando, el modelo entrenado proporciona predicciones precisas para los datos de entrenamiento, pero no para nuevos datos [10]. Antes de realizar predicciones, los científicos de datos entrenan los modelos de aprendizaje automático utilizando un conjunto de datos conocido. Posteriormente, basándose en esta información, el modelo intenta hacer una clasificación para los nuevos conjuntos de datos. Cuando un modelo sufre de sobreajuste, genera predicciones inexactas y no es eficaz para todos los tipos de datos nuevos.

1.1.15 Sub-Ajuste en Aprendizaje Automático

Se considera que un modelo presenta un sub-ajuste cuando el mismo no logra capturar de manera precisa las relaciones entre las variables de entrada y salida. Esto resulta en una alta tasa de error tanto en el conjunto de entrenamiento como en los datos no observados [10]. Tal situación se presenta cuando el modelo es demasiado simple, lo que sugiere que necesita un mayor tiempo de entrenamiento, una mayor cantidad de funciones de entrada o menos de regularización. De manera análoga al sobreajuste, cuando un modelo presenta un sub-ajuste, no logra identificar de manera precisa las tendencias principales en los datos, lo que resulta en errores durante el entrenamiento y un rendimiento insatisfactorio.

1.1.16 Aumento de datos

El aumento de datos es un proceso que implica la creación de nuevos datos sintéticos a partir de los datos ya existentes. La aplicación de este método tiene el objetivo de entrenar modelos adicionales de aprendizaje automático y aumentar la adaptabilidad de los mismos [11]. A pesar de que los modelos de ML requieren conjuntos de datos amplios y diversos para su entrenamiento inicial, la obtención de datos suficientes del mundo real, es con frecuencia complicado ya que se debe a diversas razones como la fragmentación de los datos, regulaciones y restricciones. Para paliar esta situación, el aumento de datos incrementa artificialmente el tamaño de los conjuntos de datos mediante pequeñas transformaciones en los datos originales.

En diversos sectores, se están implementando soluciones de inteligencia artificial generativa para expandir rápidamente y mejorar la calidad de los conjuntos de datos.

1.1.17 Degeneración Macular Asociada con la Edad (DMAE)

La DMAE es una enfermedad progresiva y degenerativa de la retina que se presenta con mayor frecuencia en personas adultas. Esta enfermedad se deriva por diversas anomalías en la retina, y se caracteriza por la aparición de drusas, atrofia geográfica y/o el desarrollo de neovascularización. Estas condiciones provocan un deterioro en la agudeza de la visión central, lo que impide apreciar detalles finos tanto de cerca como de lejos en el centro focal de la visión, aunque la visión periférica se mantiene normal. También cabe destacar la

relación que tiene con diferentes hábitos, como el tabaquismo y el consumo de alcohol, así como a enfermedades metabólicas como la obesidad, diabetes e hipertensión, y aparecen también por predisposición genética. De esta enfermedad existen dos variedades de DMAE: no vascular o atrófica (Figura 1.2) y neovascular o húmeda [12].




Figura 1.2 DMAE avanzada en su manifestación seca. Imagen accedida en²

Siendo la variante húmeda, una etapa posterior a la forma avanzada seca de la DMAE, como se ilustran en la Figura 1.3.



Figura 1.3 DMAE avanzada en su manifestación húmeda. Imagen accedida en²

² Catherine J. Thomas, "Age-Related Macular Degeneration", Medical Clinics of North America, 2021.

1.1.18 Características DMAE Húmeda

En el estudio presentado en [12] se muestra que las características de la Degeneración Macular Asociada con la Edad en su variante húmeda son las mostradas a continuación:

1.1.18.1 Pérdida brusca y progresiva de agudeza visual.

Cuando se filtra líquido de la coroides, este se acumula entre la capa de células delgadas denominada como epitelio pigmentario de la retina y la retina misma (o dentro de las capas de la retina). Esto provoca anomalías en las capas de la mácula, lo que lleva a la disminución o distorsión de la visión.

1.1.18.2 Escotoma central.

Los escotomas son regiones ciegas o zonas oscuras en el campo visual donde la percepción visual está ausente [13]. Varias condiciones oculares y anomalías visuales, como la visión borrosa, halos, puntos ciegos, y moscas volantes, se manifiestan. La visión borrosa se define por una disminución en la claridad visual y dificultad para percibir detalles finos.

1.1.18.3 Metamorfopsia

En [14] se explica la metamorfopsia como la distorsión de la imagen en la visión de las personas. Tal distorsión consiste en percibir con ondulaciones las líneas que en condiciones normales serían rectas. Además de las líneas rectas, las personas que padecen este síntoma también perciben distorsión en las formas de las cosas o de las personas a las que miran.

1.1.18.4 Hemorragia subretiniana

La hemorragia subretiniana se refiere al sangrado que se produce debajo de la retina. El pronóstico visual asociado con este tipo de hemorragia tiende a variar considerablemente, y está influenciado por tanto la causa subyacente como el intervalo entre el diagnóstico y el tratamiento [15].

1.1.18.5 Hemorragia intrarretiniana

La hemorragia intrarretiniana (por dentro de la retina) es el sangrado ubicado en extremos venosos de los capilares y se localiza en las capas medias de la retina, como se explica en [16]. Un ejemplo de esta condición se aprecia en la Figura 1.4.



Figura 1.4 Ojo con hemorragia retiniana. Imagen accedida en³

1.1.18.6 Desprendimiento exudativo

En [17] se describe que el desprendimiento de retina exudativo se produce cuando líquido se acumula detrás de la retina, sin que existan desgarros ni roturas en ésta. Si se retiene suficiente líquido detrás de la retina, se separa de la parte posterior del ojo, causando su desprendimiento.

1.1.18.7 Desprendimiento del EPR

El desprendimiento seroso del epitelio pigmentario retiniano (EPR) se presenta comúnmente en casos de degeneración macular asociada a la edad (DMAE) en su forma exudativa. Una complicación que se presenta de manera poco frecuente es el desgarro del EPR, que provoca una pérdida brusca de visión [18].

³Fundación redGDPS, "Proyecto MIRA",
<https://www.redgdps.org/proyectomira/testrapido.php?respuesta=1&si=1&idtipo=5&idcaso=70>, 2024

1.1.18.8 Atrofia subfoveal

En [19] se explica a esta como una condición médica donde existe una degeneración o deterioro de una estructura situada inmediatamente debajo del centro de la retina, la llamada mácula, en una ubicación conocida como la fovea. Esta área es crucial para la visión central y fina. Cuando ocurre la atrofia subfoveal, el resultado es una pérdida de la función visual de esa área específica, lo que a menudo se asocia con enfermedades oculares como la DMAE en etapa avanzada.

1.1.18.9 Exudados lipídicos

En [20] se expone que los exudados duros o lipídicos son lesiones amarillentas con bordes bien definidos, que suelen estar asociadas con microaneurismas que filtran líquido o con microhemorragias. Tales exudados suelen estar compuestos por lipoproteínas y macrófagos cargados de lípidos.

1.2 Situación tecnológica, económica y operativa de la empresa

El Instituto Tecnológico de Orizaba, es una institución de educación superior que pertenece al Tecnológico Nacional de México, orientada al desarrollo de la ciencia y la técnica, mediante la formación de recursos humanos y la investigación en dichas áreas, para el fortalecimiento económico y social de la zona de las altas montañas en el centro del estado de Veracruz. Se encuentra ubicado en Avenida Oriente 9 Núm.852, Colonia Emiliano Zapata, C.P. 94320, Orizaba, Veracruz.

1.3 Planteamiento del problema

La Degeneración Macular Asociada con la Edad (DMAE) es catalogada como una enfermedad progresiva y degenerativa de la retina que se presenta con mayor frecuencia en personas adultas mayores a 50 años. La prevalencia de la DMAE es aproximadamente del 30% en el grupo etario de más de 70 años, y varía significativamente entre los diversos estudios epidemiológicos, en personas de 40 a 50 años es de 0.7%, y en personas mayores de

90 años se incrementa al 27%. Se conocen dos tipos de esta enfermedad: 1) La no vascular o atrófica, que también es conocida como seca y, 2) La Neovascular o húmeda. La variedad denominada como seca tiene como principales características la aparición de: drusas, cambios en la melanina en del epitelio pigmentario de la retina (EPR) con redistribución, y atrofia geográfica. Por otro lado, la DMAE catalogada como húmeda tiene como principal elemento característico el desarrollo de neovascularización coroidea (NVC) proceso donde una membrana vascular originada en la coroides crece debajo y a través del EPR y la membrana de Bruch para extenderse debajo de la retina. Es posible que estos vasos presenten pérdidas y hemorragias y causen desprendimientos de retina exudativos, hemorrágicos o ambos.

Con base en lo anterior, se requiere el análisis de características asociadas con la DMAE no vascular o atrófica a partir del análisis de imágenes del fondo del ojo utilizando técnicas de visión artificial considerando la arquitectura emergente Swin Transformer V2, como una alternativa competitiva a las redes neuronales convolucionales (CNN) para la detección de características y que actualmente son lo último en visión por computadora; por lo tanto, se utilizan ampliamente en diferentes tareas, utilizando un proceso que consta de 3 pasos: 1) Se obtiene la imagen que se analizará; 2) Se identifican y resaltan las características de la imagen haciendo uso de ajuste de datos y, 3) El conjunto de características se envía a un modelo de Swin Transformer V2, que será el responsable de la detección temprana de la condición médica de la DMAE no vascular o atrófica a partir de la clasificación de valores multiclase que permitan establecer el nivel de afectación en el ojo de la persona.

1.4 Objetivo general y objetivos específicos

1.4.1 Objetivo general

Desarrollar un módulo para el análisis de características para la detección temprana de la DMAE variante húmeda utilizando técnicas de Visión Artificial y el transformador SWIN-V2 que permita establecer el nivel de afectación en el ojo de la persona.

1.4.1.2 Objetivos específicos

- Analizar trabajos relacionados para establecer la principal aportación del proyecto a través de la identificación de diferencias entre iniciativas existentes y el tema de tesis propuesto.
- Analizar los algoritmos de visión por computadora para la detección de elementos dentro de una región de interés en una imagen.
- Identificar las características preponderantes a partir de imágenes del fondo del ojo para la identificación de Degeneración Macular Asociada con la Edad variante húmeda.
- Adquirir las imágenes que serán la entrada principal del módulo a desarrollar a partir de los repositorios de imágenes del fondo del ojo más adecuados.
- Diseñar el modelo basado en arquitectura de transformadores de visión y aumento de datos para la clasificación de valores multiclase que permitan establecer el nivel de afectación en el ojo de la persona.
- Implementar el modelo, los servicios e interfaces Web y el repositorio de información con los que se integrará el modelo entrenado para la identificación de Degeneración Macular Asociada con la Edad variante húmeda.
- Llevar a cabo al menos un caso de estudio como prueba de concepto que permita describir los resultados y conclusiones obtenidas.

1.5 Justificación

La (DMAE) se cataloga como una enfermedad progresiva y degenerativa de la retina que se presenta con mayor frecuencia en personas adultas. La DMAE catalogada como húmeda tiene como principal elemento característico el desarrollo de neovascularización coroidea (NVC) proceso donde una membrana vascular originada en la coroides crece debajo y a través del EPR y la membrana de Bruch para extenderse debajo de la retina. Estos vasos presentan pérdidas y hemorragias que causan desprendimientos de retina exudativos, hemorrágicos o ambos.

Se identificó a la DMAE variante húmeda como una de las principales causas de deterioro visual en personas de la tercera edad, la detección temprana y el tratamiento oportuno de esta enfermedad da como resultado la preservación de la visión del paciente. Actualmente el desarrollo tecnológico tiene impacto en el sector de la salud Por lo que, por medio del desarrollo de un módulo basado en Transformadores de Visión, técnicas de Visión Artificial y Aprendizaje Profundo se busca mejorar la detección temprana para el oportuno tratamiento de esta enfermedad ocular, con el objetivo de ofrecer mejor calidad de vida al paciente afectado. Este enfoque contribuye al avance en la detección y manejo de la DMAE, con el objetivo de preservar la visión y mejorar la calidad de vida de los pacientes afectados.

Capítulo 2. Estado de la practica

Para poder entender el tema con más claridad, se dio lectura a 15 artículos que contienen información relacionada con el tema propuesto, así mismo se analizó y se extrajo la información más sobresaliente de cada uno de ellos.

Por consiguiente, se muestra de forma breve un resumen con la información de cada artículo investigado.

2.1 Trabajos relacionados

Wei W et al. [21] presentó un método innovador de aprendizaje profundo para la detección y cuantificaciones automatizadas de características atróficas asociadas con la atrofia macular (MA) en la degeneración macular relacionada con la edad (DMAE) húmeda, utilizando análisis de tomografía de coherencia óptica (OCT). La investigación destaca la dificultad de recopilar datos de seguimiento a largo plazo en pacientes con DMAE húmeda de alta resolución, lo que limita la capacidad de generalizar más allá de cohortes externas. Aunque el modelo automatizado logró detectar cambios morfológicos de la atrofia en OCT, no incluyó otras características comunes en la DMAE húmeda, como líquido subretiniano o intrarretiniano, desprendimiento del epitelio pigmentario y material hiperreflectante subretiniano. Esto es a causa de la complejidad de las anotaciones y las posibles superposiciones, lo que afecta el rendimiento del modelo. A pesar de estas limitaciones, el método de aprendizaje profundo logró un puntaje promedio de coeficiente de similitud de Dice (DSC) de 0.706, un puntaje promedio de precisión de 0.834 y un puntaje promedio de sensibilidad de 0.615, lo que demuestra su potencial único para la detección temprana y la identificación de la progresión de la MA en la DMAE húmeda. El desarrollo de este método de inteligencia artificial tiene implicaciones significativas para el diagnóstico temprano y el seguimiento a largo plazo de la progresión de la atrofia macular en pacientes con DMAE húmeda. Aunque el modelo actual centró la detección de cambios morfológicos de la atrofia, su capacidad para identificar otras características comunes de la DMAE húmeda aumento para futuras investigaciones. En última instancia, este enfoque tiene el potencial de servir como una herramienta de detección integral para la progresión de la DMAE húmeda

en entornos clínicos, lo que ayudó a mejorar significativamente la atención y el tratamiento de los pacientes con esta afección ocular debilitante.

En [22] se demostró un enfoque híbrido que combina una red neuronal de fusión completamente densa (FD-CNN) con una máquina de vectores de soporte profundo (D-SVM) para la clasificación de enfermedades retinianas en imágenes de tomografía de coherencia óptica (OCT). Los resultados indican que este enfoque híbrido demostró un rendimiento sobresaliente en la identificación precisa de enfermedades retinianas. En comparación con otros métodos, como D-KNN, el enfoque híbrido FD-CNN/D-SVM mostró una alta precisión, sensibilidad, especificidad, precisión y puntuación F1 en la clasificación de enfermedades retinianas en conjuntos de datos como el de la Universidad de California San Diego (UCSD) y el de Duke. Estos hallazgos respaldan la eficacia del enfoque propuesto para mejorar la precisión en la identificación de enfermedades retinianas en imágenes OCT. Además, la implementación de técnicas de inteligencia artificial explicables, como LIME, mejora la transparencia en el proceso de toma de decisiones, lo que es crucial en aplicaciones médicas. Finalmente, el enfoque híbrido FD-CNN/D-SVM se destaca como una herramienta prometedora para el diagnóstico temprano y el tratamiento efectivo de enfermedades retinianas, por lo que presenta un impacto significativo en la salud visual de los pacientes.

El-Den N. et al. [23] propuso una orientación innovadora para la detección temprana de la degeneración macular relacionada con la edad (AMD) mediante el uso de un modelo de aprendizaje profundo integrado. El modelo propuesto combina un auto-codificador adaptable a la escala con una red de clasificación basada en la arquitectura ResNet50 pre-entrenada. El auto-codificador se encarga de adaptar la escala de las imágenes de la retina, lo que permite una representación más efectiva de las características relevantes para la detección de AMD. Posteriormente, la red de clasificación utiliza esta representación para distinguir entre retina normal y diferentes grados clínicos de AMD, como AMD intermedia, GA o AMD húmeda. Los resultados del estudio demuestran que el modelo propuesto es capaz de reconocer y diferenciar con precisión entre la retina normal y varios grados clínicos de AMD, con una alta precisión. Además, el modelo propuesto supera a otros modelos de aprendizaje profundo previamente propuestos en la literatura. La combinación de un auto-codificador adaptable a

la escala y una red de clasificación basada en ResNet50 pre-entrenada resultó en una alta precisión en la detección de AMD. En conclusión, el modelo propuesto en este estudio ofrece una alternativa no invasiva y eficiente para la detección temprana de AMD a partir de imágenes de la retina en color. La integración de un auto-codificador adaptable a la escala y una red de clasificación basada en ResNet50 pre-entrenada representa un avance significativo en la detección temprana de AMD. Este modelo tiene el potencial de incluirse en sistemas de imagen retiniana existentes para su uso generalizado en entornos clínicos, por lo que contribuye a incrementar significativamente la capacidad de detección temprana de la AMD y beneficiar a un mayor número de pacientes. contribuyo

En [24] se presentó el novedoso enfoque Conv-ViT, que combina la extracción de características híbridas mediante una red neuronal convolucional (CNN) y un modelo de aprendizaje profundo basado en transformadores para mejorar la detección de enfermedades retinianas. Se emplean modelos pre-entrenados como Inception-V3 y ResNet-50, junto con el transformer, para extraer características híbridas seguidas de un modelo de red neuronal profunda (DNN). Los resultados muestran un aumento significativo en la puntuación F1 para la clase de edema macular diabético (DME) al utilizar Conv-ViT con Inception-V3 y ResNet-50. Además, se destaca la capacidad de Conv-ViT para predecir la clase de drusen de manera más precisa en comparación con otros modelos. El estudio cualitativo respalda estas observaciones, demostrando la efectividad del enfoque propuesto. Se señala que el número de parámetros en la unidad MAC para el marco de trabajo propuesto es ligeramente mayor en comparación con los modelos individuales, lo que sugiere una capacidad mejorada para capturar patrones complejos en las imágenes retinianas. Este enfoque híbrido ofrece perspectivas prometedoras para la detección precisa de enfermedades retinianas, lo que muestra implicaciones significativas en el campo de la imagen médica y el diagnóstico. La combinación de características de textura y forma demostró mejorar la precisión, la recuperación y la puntuación F1 del modelo, lo que indica que la fusión de estas características asistió al modelo Conv-ViT propuesto para superar a los modelos de clasificación de enfermedades retinianas más avanzados. Estos resultados sugieren que la combinación de enfoques de aprendizaje profundo es crucial para mejorar la precisión en

la clasificación de enfermedades retinianas, por lo que presento un impacto significativo en la detección temprana y el tratamiento efectivo de estas afecciones.

Haigong E. et al. [25] Expuso el SAE-wAMD, un enfoque innovador para la clasificación detallada de la Degeneración Macular Asociada a la Edad húmeda (wet AMD) utilizando imágenes de Tomografía de Coherencia Óptica (OCT). Se propone un modelo de red neuronal convolucional (CNN) mejorado con autoatención para capturar características cruciales en áreas de lesiones pequeñas. El SAE-wAMD supera significativamente a otros modelos, incluyendo ResNet y DCNN, en la puntuación F1, con un rendimiento destacado en la clasificación de Neovascular AMD y PCV. Además, se incorpora la similitud coseno en la función de pérdida durante la etapa de pre-entrenamiento auto-supervisado, lo que mejora la capacidad del modelo para distinguir instancias de imágenes OCT. Los resultados muestran que el enfoque propuesto mejora la precisión y la capacidad de detección de lesiones, lo que lo hace prometedor para la clasificación precisa de subtipos de AMD húmeda. El SAE-wAMD demuestra su eficacia al superar a modelos basados en CNN convencionales y a la experiencia clínica de oftalmólogos en la clasificación de AMD húmeda. Este enfoque tiene el potencial de mejorar significativamente la precisión y eficiencia en la clasificación de enfermedades fundus, por lo que demuestra un impacto positivo en la práctica clínica. Los resultados respaldan la efectividad del SAE-wAMD y su potencial para aplicaciones clínicas más amplias en el diagnóstico automático de enfermedades oftálmicas. La combinación de autoatención y pre-entrenamiento auto-supervisado en el marco SAE-wAMD demuestra ser prometedora para abordar los desafíos de la clasificación detallada de enfermedades oftálmicas, por lo tanto, demuestra tener implicaciones significativas en la mejora de la atención médica y el desarrollo de herramientas de diagnóstico más precisas.

En [26] se presentó un método automatizado para la detección de la degeneración macular seca y húmeda utilizando redes neuronales convolucionales profundas. Se emplean dos arquitecturas de redes neuronales, AlexNet y ResNet, para clasificar las imágenes de OCT. El conjunto de datos utilizado consta de 8,000 imágenes de OCT, divididas en cuatro categorías: saludable, degeneración macular seca, degeneración macular húmeda y edema

macular diabético. Se utilizan 32,000 imágenes para entrenar los modelos de aprendizaje profundo. Los resultados obtenidos revelan que el modelo ResNet supera al modelo AlexNet en la clasificación, con un área bajo la curva ROC del 94% para la degeneración macular seca y del 63% para la degeneración macular húmeda. Estos hallazgos sugieren que la detección de la degeneración macular seca se realiza de manera más precisa utilizando el modelo ResNet en comparación con la detección de la degeneración macular húmeda. Este resultado es crucial, ya que la detección precisa de la degeneración macular es fundamental para el tratamiento oportuno y efectivo de la enfermedad. El estudio demuestra la eficacia de las redes neuronales convolucionales profundas en la clasificación de la degeneración macular seca y húmeda, por lo tanto, tiene un impacto significativo en la atención médica oftalmológica. La capacidad de realizar una clasificación automatizada y rápida de la degeneración macular utilizando técnicas de aprendizaje profundo mejora los resultados del tratamiento para los pacientes, al permitir una detección temprana y precisa de la enfermedad. Estos resultados respaldan la utilidad de las redes neuronales convolucionales profundas en aplicaciones médicas, especialmente en el campo de la oftalmología, y subrayan la importancia de la investigación en el desarrollo de métodos de detección y diagnóstico asistidos por computadora para enfermedades oftalmológicas.

López-Varela E. et al. [27] exhibió una metodología de diagnóstico asistido por computadora y visualización 3D para la identificación y visualización rápida de la AMD húmeda. La metodología utiliza una red neuronal convolucional (CNN) entrenada con un conjunto de datos de imágenes OCT específicas para la segmentación de las acumulaciones de líquido asociadas a la AMD. Se destacan el uso de técnicas de aumento de datos y transferencia de aprendizaje para mejorar la robustez del modelo. Los resultados muestran que la metodología propuesta logra una reconstrucción 3D precisa y una visualización intuitiva de las acumulaciones de líquido asociadas a la AMD, lo que representa una herramienta con alto rendimiento para el diagnóstico y monitoreo de esta enfermedad. La metodología propuesta facilita y agiliza la carga de trabajo médico al permitir un análisis rápido y repetible, lo que reduce significativamente el impacto de la subjetividad en el diagnóstico final. En conclusión, la metodología propuesta demuestra la efectividad de la visualización 3D y la segmentación mejorada mediante CNN en el diagnóstico de AMD húmeda, lo que sugiere un avance prometedor en el campo de la imagen médica y la atención oftalmológica. La

metodología propuesta es útil para mejorar la precisión y la eficiencia del diagnóstico de AMD, lo que demuestra tener un impacto significativo en la calidad de vida de los pacientes.

En [28] se expuso un enfoque novedoso para la categorización automatizada de la Degeneración Macular Relacionada con la Edad (AMD) mediante el uso de redes neuronales convolucionales (CNN) multi-modales. Los autores emplearon algoritmos de aprendizaje profundo, incluyendo MM-CNN y técnicas de aumento de datos innovadoras como la síntesis de imágenes CFP/OCT basada en GAN y el emparejamiento suelto. El MM-CNN es una red neuronal de dos flujos que combina información de imágenes de tomografía de coherencia óptica (OCT) y fotografías en color de fondo (CFP) para mejorar la precisión en la categorización de AMD. Los resultados muestran que la combinación de información de imágenes de OCT y CFP mejora significativamente la categorización de AMD en comparación con enfoques anteriores de modalidad única. El MM-CNN logra una precisión y sensibilidad superiores en la detección de AMD húmeda y PCV en comparación con enfoques unimodales, demostrando su eficacia en la práctica clínica. Además, los autores desarrollaron dos métodos de aumento de datos para mejorar la eficacia del MM-CNN: la síntesis de imágenes CFP/OCT basada en GAN y el emparejamiento suelto. Los resultados muestran que estos métodos de aumento de datos mejoran significativamente la precisión y la sensibilidad del MM-CNN en la detección de AMD. En general, el estudio demuestra que el enfoque multi-modal y los métodos de aumento de datos innovadores mejoran significativamente la precisión y la sensibilidad en la detección de AMD, lo que tiene implicaciones importantes para la práctica clínica.

En [29] se expuso el conjunto de datos Kermany para entrenar un modelo de red neuronal convolucional ResNet50 pre-entrenado en el conjunto de datos ImageNet para clasificar entre AMD seco y húmedo. El modelo propuesto logró una precisión del 96,56%, superando a los modelos anteriores. La sensibilidad del modelo fue del 89,45% y la especificidad del 98,20%. Se utilizaron técnicas de aprendizaje profundo, como la transferencia de aprendizaje y la normalización por lotes, para mejorar el rendimiento del modelo. Los resultados sugieren que la automatización del análisis de imágenes retinianas son una herramienta útil para el diagnóstico y tratamiento de AMD.

Feng W. et al. [30] abordó un modelo de aprendizaje profundo para la segmentación automatizada de neovascularización coroidea en imágenes de tomografía de coherencia óptica angiográfica (OCTA) de pacientes con degeneración macular relacionada con la edad (DMAE). El modelo propuesto se basa en la red U-net y utiliza un bloque ResNeSt y una pirámide de agrupamiento espacial para mejorar la capacidad de extracción de características y la segmentación. El modelo se entrena con técnicas de aumento de datos y se evalúa utilizando métricas como el área bajo la curva ROC, precisión, sensibilidad, especificidad, intersección sobre unión y coeficiente DICE. Los resultados muestran que el modelo propuesto supera significativamente a los métodos tradicionales y al modelo U-net en términos de rendimiento de segmentación. El modelo propuesto tiene un gran potencial para mejorar el diagnóstico y tratamiento de enfermedades oculares, como la DMAE, y se utiliza para la detección temprana y el seguimiento de la progresión de la enfermedad. Además, el estudio destaca el papel de la inteligencia artificial y el aprendizaje profundo en la medicina, especialmente en la oftalmología, y su capacidad para mejorar la eficiencia y precisión del diagnóstico y tratamiento de enfermedades oculares. En general, el estudio proporciona una valiosa contribución a la investigación en el campo de la segmentación automatizada de OCTA y destaca el potencial de la inteligencia artificial para mejorar la atención médica en oftalmología.

En [31] se mostró un marco basado en el modelo YOLOv5 para detectar logotipos en entornos de conjuntos de datos cerrados y QMUL-Openlogo. Para mejorar la detección de logotipos, se utilizaron algoritmos como YOLOv5, transfer learning y técnicas de aumento de datos. El marco propuesto con pesos pre-entrenados tuvo un rendimiento superior al que carecía de pesos pre-entrenados, y se desarrolló una interfaz gráfica de usuario (GUI) para facilitar su uso. La evaluación del rendimiento se realizó mediante métricas como precisión, sensibilidad y F1-score, y se compararon los resultados con otros enfoques de detección de logotipos. Se observó que el marco propuesto logró una precisión y sensibilidad superiores en comparación con otros métodos. Además, se destacó que la utilización de pesos pre-entrenados mejoró significativamente el rendimiento del modelo. En cuanto a los resultados, se encontró que el marco propuesto logró una precisión del 98,5% y una sensibilidad del

98,6% en el conjunto de datos cerrado, y una precisión del 96,5% y una sensibilidad del 96,7% en el conjunto de datos QMUL-Openlogo. Estos resultados superaron a otros enfoques de detección de logotipos en términos de precisión y sensibilidad. Para futuras extensiones, se planea mejorar la GUI para permitir la detección de múltiples logotipos simultáneamente y ampliar la capacidad de detección de logotipos en entornos en tiempo real. En resumen, el marco propuesto basado en YOLOv5 con pesos pre-entrenados y técnicas de aumento de datos demostró ser efectivo en la detección de logotipos en entornos de conjuntos de datos cerrados y QMUL-Openlogo.

Corazza P et al. [32] se enfocó en predecir la degeneración macular relacionada con la edad (DMAE) utilizando tecnología de DARC (Detection of Apoptosing Retinal Cells) para predecir la formación de neovascularización coroidea (CNV) en pacientes con degeneración macular relacionada con la edad (DMAE) húmeda. Se empleó un algoritmo de (CNN) para analizar imágenes de DARC y predecir el desarrollo de exudación subretiniana (SRF) durante un período de seguimiento de 36 meses. Los resultados mostraron que DARC, con un recuento de CNN superior a 5, estaba significativamente asociado con la formación de SRF, con valores de valor predictivo positivo (PPV), especificidad y sensibilidad superiores al 70%. Además, se observó una relación entre la magnitud de SRF y el recuento de DARC, lo que sugiere la capacidad de DARC para identificar la actividad angiogénica endotelial temprana. Este hallazgo es relevante, ya que es la primera vez que se aplica la tecnología DARC a una enfermedad distinta del glaucoma, lo que sugiere su utilidad como biomarcador de la actividad retiniana. El estudio incluyó pacientes con DMAE seca y húmeda, y se comparó la capacidad de detección clínica de SRF en OCT con algoritmos automatizados. Se encontró que la identificación clínica de SRF en OCT era menos precisa que la detección automatizada, con una sensibilidad de 0.583 para especialistas en comparación con 0.940 para el sistema de inteligencia artificial (IA). Estos hallazgos resaltan la importancia de la precisión en la detección temprana de la progresión de la DMAE, y sugieren que los algoritmos de IA superan las expectativas de los expertos clínicos en esta tarea. Además, se identificaron biomarcadores específicos que demostraron ser indicativos de la progresión de la DMAE, por lo tanto, presentaron tener implicaciones importantes para el desarrollo de herramientas de diagnóstico molecular.

En [33] propuso un sistema de detección automática para identificar enfermedades retinianas a partir de imágenes de OCT, utilizando arquitecturas de CNN de última generación y transferencia de aprendizaje. El sistema se desarrolló para evitar diagnósticos erróneos y garantizar que los pacientes reciban tratamiento oportuno. Se utilizaron varios algoritmos de CNN, incluyendo ResNet18, InceptionV3 y ResNext50, y se aplicó transferencia de aprendizaje para mejorar el rendimiento del modelo. Los resultados de la evaluación mostraron que el modelo InceptionV3_bn tuvo el mejor rendimiento, con una precisión del 99,795%, una sensibilidad del 99,174% y una especificidad del 99,725%. Los otros modelos también lograron una precisión, sensibilidad y especificidad promedio por encima del 99%. El sistema de detección automática se implementó en una aplicación web que permite a los usuarios cargar imágenes de OCT y seleccionar el modelo para realizar la detección. La aplicación web se desarrolló en dos etapas: el desarrollo del backend para construir una API REST que suba los modelos y realice predicciones, y el desarrollo del frontend para construir una interfaz de usuario que interactúe directamente con los usuarios. En general, los resultados de este estudio revelaron que el sistema de detección automática desarrollado con modelos de CNN se utiliza para detectar enfermedades retinianas en imágenes de OCT con un buen rendimiento. El sistema permite ayudar a mejorar la precisión del diagnóstico y garantizar que los pacientes reciban tratamiento oportuno.

Wu M. et al. [34] examinó la clasificación de la degeneración macular seca y húmeda utilizando varios modelos de aprendizaje automático, incluyendo VGG16, ResNet18, ResNet50, EfficientNetB7, RegNet y ConvNeXT. Se empleó un conjunto de datos original y expandido, con la expansión de datos destinada a igualar el número de imágenes para cada categoría. Tras el entrenamiento y la evaluación de los modelos, se observó que la expansión de datos mejoró significativamente el rendimiento de todos los modelos, con mejoras en la precisión y el valor kappa. El modelo ConvNeXT destacó en términos de precisión y capacidad de diagnóstico, logrando una precisión del 96.89% en el conjunto de datos expandido, superando a los demás modelos. En particular, demostró una sensibilidad del 97.50% para imágenes de fondo normales, del 93.75% para degeneración macular seca y del 84.30% para degeneración macular húmeda. Estos resultados sugieren que el modelo ConvNeXT es altamente efectivo en la clasificación precisa de diferentes categorías de

imágenes de fondo de ojo. Además, se destacó que el modelo ConvNeXT requiere menos memoria y tiene menos parámetros en comparación con otros modelos, lo que lo hace más adecuado para su implementación en dispositivos finales. En general, el estudio subraya la importancia de la expansión de datos para mejorar el rendimiento de los modelos de aprendizaje automático en el campo de la clasificación de enfermedades oculares. Los resultados también resaltaron el potencial del modelo ConvNeXT como una herramienta eficaz para la clasificación precisa de la degeneración macular seca y húmeda, por lo tanto, presento tener implicaciones significativas en el diagnóstico clínico y el desarrollo de tratamientos para esta afección ocular común.

En [35] se presentó un estudio sobre el uso de la inteligencia artificial (IA) en la clasificación y estratificación del riesgo de la degeneración macular relacionada con la edad (DMAE). El estudio se sustentó en el análisis de datos clínicos de pacientes con DMAE y utiliza algoritmos de aprendizaje profundo para predecir la progresión de la enfermedad y el riesgo de conversión a la forma avanzada de la DMAE. Los resultados del estudio revelaron que el algoritmo de IA desarrollado supero las expectativas de los expertos clínicos en la predicción de la progresión de la DMAE. Además, el algoritmo también sobrepasa la expectativa de los expertos en la identificación de pacientes con alto riesgo de conversión a la forma avanzada de la DMAE. El estudio también destaca la importancia de establecer un punto de referencia para el rendimiento humano en la predicción de la progresión de la DMAE. Los expertos clínicos que participaron en el estudio demostraron un rendimiento mejor que el azar, pero con una variabilidad significativa en la sensibilidad y especificidad. El estudio utilizó datos clínicos de pacientes recopilados por el Hospital de Ojos Moorfields en Londres, Reino Unido. Los datos se dividieron aleatoriamente en conjuntos de entrenamiento, validación y prueba, y se utilizaron algoritmos de aprendizaje profundo para analizar los datos. Finalmente, este estudio demuestra el alto nivel de la IA en la clasificación y estratificación del riesgo de la DMAE.

2.2 Análisis comparativo

La tabla 2.1 muestra un análisis comparativo de los artículos relacionados con el tema de tesis propuesto que lograron obtener un estado finalizado, así mismo se destaca algunas características como tipo de detección, tecnologías utilizadas, y resultados.

Tabla 2.1 Análisis comparativo de los trabajos relacionados.

Año	Autor	Condicion Medica	Arquitectura	Tipo de imagen	Precision
2023	Wei W et al. [21]	Wet AMD	U-net	OCT	83.4%
2023	Kayadibi, İ et al. [22]	Wet AMD Diabetic Macular Edema (DME)	FD-CNN	OCT	99.60%
2023	El-Den N. et al. [23]	Wet AMD Dry AMD	ResNet50	Color Retinal Fundus Image	96.2%,
2023	Dutta et al [24]	Wet AMD Dry AMD	Conv-ViT: Inception-V3 ResNet-50	OCT	94.47%
2022	Haigong E. et al. [25]	Wet AMD Wet AMD	SAE-VGG16	OCT	92.56%
2023	López-Varela E. et al. [27]	Wet AMD	U-net	OCT	83.4%
2022	Abdullahi. et al [29]	Wet AMD	U-net	OCT	94.92% 96.03%
2021	Feng W. et al. [30]	Wet AMD Dry AMD	ResNet50	OCT	96.56%
2023	Corazza P et al. [32]	Wet AMD	U-net	OCTA	98.91%
2020	Wu M. et al. [34]	Wet AMD	DARC-CNN	OCT DARC	97%.

La comparativa presentó que el uso y la aplicación de redes neuronales convolucionales y métodos de aprendizaje profundo obtienen resultados efectivos para la clasificación y detección de la Degeneración Macular Asociada con la Edad (DMAE), más precisamente con la variante húmeda que es el tema central que se aborda en el presente documento, entre otras enfermedades visuales.

2.3 Propuesta de solución

El desarrollo propuesto es el siguiente: un módulo para el análisis de características para la detección temprana de la Degeneración Macular Asociada con la Edad variante húmeda utilizando técnicas de Visión Artificial y el transformador Swin Transformer V2. La propuesta a implementar se realizará a través de la web. Una vez se acceda a la aplicación, el usuario final cargará la imagen del fondo de ojo que será procesada mediante algoritmos de visión artificial para su clasificación.

A continuación, en la Tabla 2.2 se muestra la opción que se consideró más apropiada, basándose en el análisis y las características de las tecnologías, para resolver la problemática.

Tabla 2.2 *Solución propuesta.*

Alternativa	Lenguajes de programación	Gestor de base de datos	IDE	Biblioteca de IA	Transformador	Documento de datos	Marco de trabajo	Metodología
1	Python + JS	PostgreSQL	Visual Studio Code	PyTorch	Swin Transformer V2	JSON	Fast API + Angular	Extreme Programming

Se eligió la anterior solución con base en un análisis conjunto de las tecnologías consideradas para el desarrollo del proyecto. Por su alta utilización en la inteligencia artificial, Python se seleccionó como principal lenguaje de programación, JavaScript, por su uso en el marco de trabajo Fast API. PostgreSQL fue el gestor de bases de datos seleccionado para su integración con el proyecto que le precede. El entorno de desarrollo seleccionado fue Visual Studio Code, pues es altamente compatibles con Python para el entrenamiento del modelo y JavaScript para su uso del framework Angular. La biblioteca seleccionada para la implementación del modelo de transformador de visión fue PyTorch, por su amplio uso en proyectos de investigación y

comunidad de soporte. La arquitectura Transformer seleccionada fue Swin Transformer V2, por sus resultados en el análisis de imágenes. Keras se ha seleccionado como la herramienta principal para el aumento de datos debido a su amplia gama de opciones disponibles para el preprocesamiento de imágenes. En cuanto a la metodología de desarrollo, se ha optado por XP.

2.3.1 Tecnologías de la propuesta de solución

2.3.1.1 Angular

AngularJS es un marco de trabajo de código abierto, impulsado por Google, para el desarrollo de aplicaciones web dinámicas y de una sola página (SPA). Este marco se diseñó para facilitar la creación de aplicaciones web escalables y mantenibles, permitiendo a los desarrolladores crear interfaces de usuario interactivas y fluidas.

Una de las características clave de AngularJS es su enfoque en la arquitectura de cliente y servidor separada, lo que permite una mayor modularidad y reutilización del código. Además, AngularJS utiliza la vinculación de datos bidireccional, lo que significa que los cambios en el modelo de datos se reflejan automáticamente en la vista y viceversa, eliminando la necesidad de manipular manualmente el DOM (Modelo de Objetos del Documento). AngularJS también ofrece un conjunto robusto de características, incluyendo enrutamiento, validación de formularios, inyección de dependencias y pruebas unitarias integradas. Estas características hacen que sea más fácil para los desarrolladores construir y mantener aplicaciones web complejas [36].

2.3.1.2 Python

Es un lenguaje de programación considerado de alto nivel, orientado a objetos, interpretado y con tipado dinámico. Es de sintaxis relativamente sencilla, lo que facilita su aprendizaje, aunque ofrece funcionalidades muy completas para un uso más avanzado. Es extremadamente popular y cuenta con una vasta comunidad de desarrolladores en todo el mundo. Se utiliza ampliamente en áreas como la automatización de scripts, el desarrollo web del lado del servidor, tareas de ciencia de datos y aprendizaje automático. Respecto a aprendizaje automático, Python se emplea en la clasificación de imágenes, texto, tráfico de red, reconocimiento de lenguaje natural y reconocimiento facial.

Python dispone de numerosas bibliotecas y marcos de trabajo centrados en la inteligencia artificial, como OpenCV para Python en términos de bibliotecas, además de PyTorch y TensorFlow como marcos de trabajo para aprendizaje automático [37] [38].

2.3.1.3 JavaScript

JavaScript (JS) es un lenguaje de programación interpretado de peso ligero (o compilado justo a tiempo) con funciones de primera clase. Aunque es reconocido principalmente como el lenguaje de scripting para páginas web, también se utiliza en muchos entornos que no son de navegador, como Node.js, CouchDB Apache y Adobe Acrobat. JavaScript es un lenguaje basado en prototipos, multiparadigma, de un solo hilo y de estilos dinámicos, orientado a objetos, imperativo y declarativo (por ejemplo, programación funcional).

Las capacidades dinámicas de JavaScript incluyen la construcción de objetos en tiempo de ejecución, listas de parámetros variables, variables de función, creación de scripts dinámicos (a través de eval), introspección de objetos (a través de for...in y utilidades Object), y recuperación de código fuente (las funciones JavaScript almacenan su texto fuente y se recuperan mediante toString()) [39].

2.3.1.4 PostgreSQL

Es un sistema de bases de datos relacional orientado a objetos, gratuito, multiplataforma y de código abierto, conocido por su potencia y flexibilidad. Utiliza y expande el lenguaje SQL combinado con varias características de almacenamiento y escalado para manejar cargas de trabajo complejas. PostgreSQL se ejecuta en todos los principales sistemas operativos (Linux, macOS, Windows, BSD y Solaris), es compatible con ACID desde 2001 y cuenta con potentes complementos, como el popular extensor de bases de datos geoespaciales PostGIS. Viene con características destinadas a ayudar a los desarrolladores a crear aplicaciones, a los administradores a proteger la integridad de los datos, a crear entornos tolerantes a fallos y a gestionar los datos independientemente del tamaño del conjunto de datos. Es extremadamente popular y cuenta con una amplia comunidad de soporte en todo el mundo, además de diversas aplicaciones que permiten manejar bases de datos creadas con PostgreSQL de manera gráfica, como pgAdmin o PhpPgAdmin [40].

2.3.1.5 Visual Studio Code

Visual Studio Code es un editor de texto enriquecido para el desarrollo de código abierto que combina la simplicidad de un editor de texto con las potentes funcionalidades de un IDE tradicional. Ofrece características como el autocompletado y un depurador de código que permite la visualización en tiempo real de la ejecución del código, facilitando así la detección de errores de manera rápida y sencilla.

Este entorno es ampliamente utilizado debido a su modularidad, personalización y extensibilidad. La versión básica de VS Code tiene la capacidad de ampliarse según las necesidades del desarrollador, desde la personalización de los esquemas de color hasta la instalación de servidores adicionales. Además, cuenta con una gran comunidad que constantemente desarrolla extensiones para mejorar sus funcionalidades. VS Code incluye soporte integrado para Git y GitHub, lo que simplifica el control de versiones sin necesidad de salir del entorno de desarrollo. Está disponible para Windows, MacOS y Linux, lo que garantiza un sólido soporte multiplataforma. Además, ofrece soporte para una amplia variedad de lenguajes de programación, incluyendo JavaScript, Python, Java, Markdown, TypeScript, C, C++, C#, PHP, GO, entre otros, lo que permite a los desarrolladores trabajar con múltiples lenguajes sin necesidad de cambiar de entorno. Todo esto contribuye a reducir la carga de trabajo del desarrollador [41].

2.3.1.6 Keras

Keras ofrece herramientas integradas para la realización de técnicas de aumento de datos, proporcionando una clase y un módulo dedicados específicamente para este propósito. Con estas funcionalidades, Keras facilita la aplicación de diversas técnicas de aumento de datos en imágenes, lo que contribuye a enriquecer y diversificar los conjuntos de datos utilizados en el entrenamiento de modelos de aprendizaje automático.

La flexibilidad y el conjunto considerable de opciones para el aumento de datos que ofrece Keras hacen que sea una excelente opción, especialmente si ya se está utilizando en otras partes del proyecto. La integración previa de Keras en el flujo de trabajo simplifica su implementación y la hace una elección conveniente para mejorar la robustez y la capacidad de generalización de los modelos de aprendizaje automático [42].

2.3.1.7 PyTorch

Se trata de una biblioteca de código abierto desarrollada por Facebook AI Research, se destaca en los campos de la inteligencia artificial y el aprendizaje automático, se utiliza para crear y entrenar modelos de aprendizaje profundo. Con aplicaciones que abarcan desde la generación de texto hasta la detección de objetos, PyTorch ofrece una flexibilidad y facilidad de uso que lo hacen popular entre los desarrolladores.

PyTorch se integra de manera nativa con Python, lo que facilita su adopción para aquellos familiarizados con este lenguaje. Esto permite a los usuarios crear y entrenar modelos de aprendizaje profundo de manera eficiente, utilizando técnicas como las redes neuronales convolucionales.

Esta biblioteca ofrece una serie de características atractivas. Es compatible con las principales plataformas en la nube y aprovecha tanto la potencia de las CPU como de las GPU, así como el procesamiento paralelo y distribuido en múltiples máquinas y GPUs. Los modelos pre-entrenados tienen la posibilidad de ser invocados desde PyTorch Hub, y la biblioteca cuenta con una amplia gama de herramientas y bibliotecas en áreas como la visión artificial y el aprendizaje por refuerzo [43].

Capítulo 3. Aplicación de la metodología

En este capítulo se expone la metodología XP, la cual se utiliza en este trabajo de tesis con el fin de resolver la problemática planteada y alcanzar los objetivos establecidos para el desarrollo del módulo de detección temprana de la degeneración macular asociada con la edad variante húmeda utilizando técnicas de visión artificial y aprendizaje profundo, así mismo la justificación del mismo.

El uso de XP se justifica por las siguientes razones:

- XP proporciona una metodología ágil diseñada para equipos pequeños a medianos que buscan desarrollar software de alta calidad y adaptarse eficazmente a los cambios del proyecto. Al igual que otras metodologías ágiles, XP promueve la colaboración cercana entre los miembros del equipo y la entrega continua de software a realizar.
- XP otorga un enfoque ágil en los aspectos técnicos del desarrollo de software. XP se centra en seguir prácticas de ingeniería precisas que garantizan que los equipos desarrollen código de alta calidad de manera sostenible a lo largo del proyecto. Estas prácticas incluyen la programación en pares, las pruebas automatizadas, la integración continua y la refactorización constante del código. [44].

A continuación, la figura 3.1 se muestran las diferentes fases que conforman XP:



Figura 3.1 Fases de la metodología XP tomada de [44]

3.1 Planificación

La fase de planificación es el punto de partida en XP. Durante esta etapa, el equipo colabora estrechamente con el cliente para entender qué se necesita desarrollar. Se identifican las historias de usuario, que son descripciones breves de funcionalidades desde la perspectiva del usuario final. También se establecen los valores fundamentales que guiarán el proyecto (como la simplicidad, la comunicación, la retroalimentación continua y el respeto). Se discuten los criterios de adaptación, es decir, las condiciones bajo las cuales se podrían realizar cambios en el plan o en el proyecto. Finalmente, se crea un plan de iteración, que desglosa el desarrollo en ciclos cortos y manejables, llamados iteraciones, en los que se van a entregar pequeñas partes funcionales del software.

Tabla 3.1 Historia de usuario: registro de usuario.

Numero: 1	
Nombre de Historia: Registro de usuario	
Prioridad: Alta	Riesgo de Desarrollo: Bajo
Puntos Estimados: 1	Iteración Asignada: 1
Descripción: El usuario completa los campos requeridos en un formulario, y los datos ingresados se guardan en la base de datos.	
Observaciones: El registro corresponde al usuario (médico)	

Tabla 3.2 Historia de usuario: registro de paciente.

Numero: 2	
Nombre de Historia: Registro de paciente	
Prioridad: Alta	Riesgo de Desarrollo: Bajo
Puntos Estimados: 1	Iteración Asignada: 1
Descripción: Un usuario introduce la información de un "Paciente" en un formulario, y los datos ingresados se guardan en la base de datos.	
Observaciones: Se entiende por "Paciente" a la persona cuya imagen de fondo de ojo se clasifica. El propio paciente no realiza el registro.	

Tabla 3.3 Historia de usuario: clasificación de imagen de fondo de ojo.

Numero: 3	
Nombre de Historia: Clasificación de imagen de fondo de ojo	
Prioridad: Alta	Riesgo de Desarrollo: Alta
Puntos Estimados: 1	Iteración Asignada: 1
Descripción: El usuario carga en el sistema la imagen del fondo de ojo de un paciente. El sistema realiza una clasificación y presenta un informe con el resultado de la evaluación.	
Observaciones: El resultado muestra el porcentaje de coincidencia para los distintos niveles de afectación (No DMAE, DMAE Seca, DMAE Húmeda).	

Tabla 3.4 Historia de usuario: consultar historial de clasificaciones.

Numero: 4	
Nombre de Historia: Consultar historial de clasificaciones	
Prioridad: Media	Riesgo de Desarrollo: Bajo
Puntos Estimados: 1	Iteración Asignada: 1
Descripción: El usuario consulta el historial de clasificaciones previas.	
Observaciones: El usuario contará con opciones para filtrar los datos.	

Tabla 3.5 Historia de usuario: recuperación de reporte de clasificación.

Numero: 5	
Nombre de Historia: Recuperación de reporte de clasificación	
Prioridad: Media	Riesgo de Desarrollo: Bajo
Puntos Estimados: 1	Iteración Asignada: 1
Descripción: El usuario obtiene el reporte de clasificación de un paciente en formato PDF.	
Observaciones: El usuario elige un reporte del historial de clasificaciones según los filtros aplicados a la lista de reportes.	

Tabla 3.6 Historia de usuario: actualizar datos de usuario.

Numero: 6	
Nombre de Historia: Actualizar datos de usuario	
Prioridad: Baja	Riesgo de Desarrollo: Bajo
Puntos Estimados: 1	Iteración Asignada: 1
Descripción: El usuario cuenta con la opción de actualizar su información a través de un formulario.	
Observaciones: El usuario solo modifica sus propios datos, no los de otros usuarios.	

Tabla 3.7 Historia de usuario: consultar listado de pacientes.

Numero: 7	
Nombre de Historia: Consultar listado de pacientes	
Prioridad: Baja	Riesgo de Desarrollo: Bajo
Puntos Estimados: 1	Iteración Asignada: 1
Descripción: Se muestra al usuario la lista de usuarios registrados.	
Observaciones: La lista se despliega según los filtros aplicados a la lista de pacientes, y el usuario solo ve a sus propios pacientes.	

Tabla 3.8 Historia de usuario: actualizar datos de paciente.

Numero: 8	
Nombre de Historia: Actualizar datos de paciente	
Prioridad: Media	Riesgo de Desarrollo: Bajo
Puntos Estimados: 1	Iteración Asignada: 1
Descripción: El usuario actualiza la información de uno de sus pacientes a través de un formulario.	
Observaciones: El usuario solo tiene permiso para modificar los datos de sus propios pacientes.	

El sistema clasifica el grado de avance de la DMAE a partir de una imagen del fondo de ojo proporcionada por el usuario, obtenida previamente por un oftalmólogo. Esta imagen se procesa mediante un modelo entrenado con datos de diversos repositorios.

La clasificación y visualización de resultados se gestionan a través de una aplicación web. Para usarla, el usuario debe registrarse, validar su cuenta y registrar los datos del paciente antes de analizar la imagen y obtener los resultados.

3.1.1 Asignación de roles del proyecto

En la Tabla 3.9 se establece la asignación de cada rol para el desarrollo del proyecto.

Tabla 3.9 Roles del proyecto.

Roles	Encargado
Gestor	I.S.C. Roberto Marquez Castro
Programador	I.S.C Roberto Marquez Castro
Encargado de Pruebas	I.S.C. Roberto Marquez Castro M.I.D.S. Jorge Ernesto González Díaz
Encargado de Seguimiento	Dr. José Luis Sánchez Cervantes
Cliente	Entidad Medica de Pruebas (Fundacion Doctor Hernandez Zurita) – Oftalmologo- Retinologo
Entrenador de modelo	I.S.C. Roberto Marquez Castro

3.1.2 Plan de entrega del proyecto

En la Tabla 3.10 El plan de entrega se establece basándose en las historias de usuario.

Tabla 3.10 Plan de entrega proyecto

Historia	Iteración	Prioridad	Riesgo	Fecha Inic.	Fecha Fin.
Historia 1	1	Alta	Bajo	01/08/24	27/05/25
Historia 2	1	Alta	Bajo	01/08/24	27/05/25
Historia 3	1	Alta	Alto	01/08/24	27/05/25
Historia 4	1	Media	Bajo	01/08/24	27/05/25
Historia 5	1	Media	Bajo	01/08/24	27/05/25
Historia 6	1	Baja	Bajo	01/08/24	27/05/25
Historia 7	1	Baja	Bajo	01/08/23	27/05/24
Historia 8	1	Media	Bajo	01/08/23	27/05/24

3.2 Diseño

El diseño en XP es simple y funcional, y se enfoca en evitar sobrecargar el software con características innecesarias. En esta fase, se utilizan herramientas como las tarjetas CRC (*Class- Responsibility-Collaboration*), que ayudan a visualizar las clases en un sistema orientado a objetos y su relación con otros componentes. También se elaboran prototipos para tener una visión clara de cómo funciona el software. La simplicidad en el diseño es clave en XP, ya que se busca construir la solución más directa y evitar complicaciones innecesarias. Los diseños se actualizan de manera continua durante las iteraciones, ajustándose según los resultados de las pruebas y retroalimentación.

3.2.1 Diseño de la arquitectura

En esta sección se presenta el diseño de la arquitectura que contempla el uso de Swin-V2, que se justifica por su eficiencia computacional, su capacidad para manejar variaciones en la resolución de la imagen, su capacidad para capturar patrones complejos y su adaptabilidad a técnicas de aumento de datos [45]. Además, en comparación con el ViT clásico y Swin Transformer V1, su diseño jerárquico, flexibilidad en el manejo de imágenes y generalizabilidad lo convierten en una opción robusta y eficaz para el desarrollo del módulo de detección temprana de DMAE húmeda.




Figura 3.2 Diseño de la arquitectura.

3.2.1.1 Capas de la arquitectura

A continuación, se presentan las capas que conforman la arquitectura del módulo del presente trabajo.

Capa de presentación: A través de esta capa, el usuario accederá al sistema a través de una aplicación web, donde se le permite ingresar una imagen del fondo de ojo y los datos de registro y autenticación de los usuarios. Tras este paso, la imagen se ajusta mediante diversas técnicas de aumento y preprocesamiento de datos. Estas técnicas incluyen rotaciones, escalado, recorte, ajustes de brillo y contraste, todas ellas implementadas a través de Keras, una librería integrada en TensorFlow. Eso permite generar variaciones de las imágenes originales, mejorando así la generalización del modelo y minimizando el sobreajuste. Por lo tanto, resaltar

las características patológicas de la DMAE húmeda, como la neovascularización, los exudados y el edema macular, aspectos fundamentales para el diagnóstico y clasificación de esta condición.

Capa de clasificación de la degeneración macular húmeda: Esta capa se utiliza para clasificar las imágenes y para recibir, procesar, analizar y devolver el resultado, que se almacena en la capa de persistencia de datos y posteriormente se observa en la capa de presentación. Además, esta capa está compuesta por dos submódulos:

- 1) **Módulo de procesamiento de datos:** Este módulo procesa la imagen del fondo de ojo, realizando transformaciones como el escalado a 300x300 píxeles, ajustes de brillo y modificaciones de contraste. Estas operaciones resaltan los detalles que el modelo entrenado necesita para la clasificación.
- 2) **Módulo de aprendizaje profundo:** A través de este módulo de aprendizaje profundo se realiza la clasificación utilizando un modelo Swin 2 (previamente entrenado), que es una notable evolución de la arquitectura Swin Transformer original desarrollada por investigadores de la Universidad de Ciencia y Tecnología de China y ByteDance [46]. El modelo obtiene una clasificación multiclase para determinar el grado de afectación de la enfermedad en el ojo del paciente. Los resultados obtenidos se envían a la aplicación que utilice el usuario, donde se mostrará el diagnóstico (No DMAE, DMAE Seca, DMAE Húmeda). Posteriormente, el informe generado se almacena en el módulo de persistencia de datos.

Capa de persistencia de datos: Esta capa almacena toda la información introducida en el sistema. Esto incluye los datos del usuario, la información del paciente al que pertenecen las imágenes del fondo de ojo, las propias imágenes y los resultados obtenidos mediante la capa de clasificación de la degeneración macular húmeda.

3.2.1.2 Modularidad

La arquitectura está compuesta por varias capas, cada una integrada por distintos módulos que se describen a continuación:

- **Gestión de información:** Módulo encargado de gestionar (registrar, modificar y eliminar) los datos de los usuarios del sistema y de los pacientes.
- **Carga de imagen:** Módulo a través del cual el usuario carga en el sistema la imagen que el modelo entrenado se encarga de clasificar.

- **Presentación de resultados:** Módulo destinado a mostrar los resultados de la clasificación de imágenes.
- **Gestión de expedientes:** Módulo para administrar (recuperar y eliminar) los reportes generados por el sistema después de clasificar una imagen.
- **Módulo de procesamiento de datos:** Realiza el preprocesamiento de la imagen ingresada al sistema antes de su clasificación, aplicando transformaciones como cambio de resolución, brillo y contraste, para resaltar características clave en la imagen.
- **Módulo de aprendizaje profundo:** Consiste en un modelo de transformador de visión entrenado con imágenes de fondo de ojo. Recibe las imágenes preprocesadas, las divide en parches, agrega información de posición y convierte estos parches en una serie de tokens, procesando la secuencia de tokens para realizar la clasificación.
- **Clasificación:** Extensión del módulo de aprendizaje profundo, encargado de clasificar la imagen ingresada.
- **Servicios de almacenamiento y recuperación de información:** Módulo responsable de almacenar y recuperar los datos de usuarios y pacientes del sistema.

3.2.1.3 Flujo de trabajo

Este proceso inicia con la captura de los datos generales y de autenticación, así como de la imagen del fondo de ojo, hasta la representación de los resultados obtenidos. A continuación, se describe brevemente el flujo de trabajo de la arquitectura:

1. El usuario accede al sistema a través de una interfaz web introduciendo sus credenciales. Si las credenciales son válidas, se concede el acceso.
2. El usuario proporciona la información del paciente, incluyendo una imagen del fondo de ojo, la cual se procesa para su clasificación. Estos datos se almacenan en la base de datos.
3. La imagen cargada se procesa para mejorar sus características visuales mediante el ajuste de parámetros como el contraste, el color y el brillo, resaltando las características requeridas por el modelo entrenado.
4. Utilizando el modelo Swin Transformer V2, el sistema clasifica la imagen en uno de los niveles de progresión de la DMAE: No DMAE, DMAE Seca, DMAE Húmeda.

- Tras la clasificación, el sistema genera un informe detallando los resultados, el cual se almacena en la base de datos.
- Finalmente, se presentan al usuario los resultados de la clasificación mediante un informe detallado que incluye los porcentajes de probabilidad correspondientes a cada uno de los niveles de severidad identificados. La Figura 3.3 muestra el diagrama de despliegue que describe el flujo de trabajo anteriormente mencionado.




Figura 3.3 Flujo de trabajo del módulo.

3.2.2 Arquitectura del transformador de visión

El módulo de aprendizaje profundo Swin Transformer V2 es una arquitectura mejorada de su antecesora Swin Transformer V1 diseñada para procesar imágenes de alta resolución de manera eficiente. Esto permite reducir la complejidad computacional mientras mantiene un rendimiento sobresaliente en tareas como clasificación, segmentación y detección de imágenes.




Figura 3.4 Arquitectura del transformador de visión Swin Transformer V2.

La arquitectura de Swin V2 funciona de la siguiente manera:

1. Partición de Imagen en Parches:

- La imagen de entrada se divide en pequeños bloques (parches), como en un grid.
- Cada parche se convierte en un vector mediante una proyección lineal y se considera una "palabra" en el espacio de características, similar a cómo los Transformers procesan palabras en el procesamiento de lenguaje natural.

2. Window-based Multi-Head Self-Attention (W-MSA):

- La atención propia (self-attention) se aplica localmente dentro de ventanas no solapadas. Esto reduce la carga computacional porque se enfoca en pequeñas regiones de la imagen en lugar de analizar toda la imagen a la vez.
- Dentro de cada ventana, el modelo aprende relaciones entre los píxeles del parche.

3. Shifted Window Multi-Head Self-Attention (SW-MSA):

- Introduce ventanas "desplazadas" (shifted) entre capas. Esto permite que regiones vecinas intercambien información, ayudando al modelo a capturar relaciones globales entre parches.
- El desplazamiento garantiza que las ventanas no estén aisladas, integrando información más amplia.

4. Jerarquía de Resolución:

Swin Transformer V2 trabaja con una jerarquía de múltiples etapas, similar a una red convolucional:

- En cada etapa, el tamaño de los parches se reduce (por ejemplo, mediante un downsampling), y el número de canales aumenta
- Esto permite capturar características desde patrones locales a nivel fino hasta relaciones globales a gran escala.

5. Componentes Internos del Bloque Swin Transformer:

- Normas de Capa (Layer Norm, LN): Normalizan las activaciones para estabilizar el entrenamiento.
- Conexiones Residuales: Ayudan a evitar el desvanecimiento del gradiente y facilitan el aprendizaje.
- MLP (Multi-Layer Perceptron): Procesa las características aprendidas en cada ventana para transformarlas en representaciones más abstractas.
- Módulo de Atención: Aplica atención múltiple dentro de las ventanas (W-MSA o SW-MSA).

6. Etapas (Stages):

El modelo tiene varias etapas (Stage 1, Stage 2, Stage 3, Stage 4), donde cada una procesa la imagen en una resolución diferente. Esto es similar a cómo las redes convolucionales (CNNs) extraen características a diferentes escalas.

3.3 Análisis de requerimientos

El siguiente paso es el análisis e identificar los requerimientos del sistema, desglosados en los puntos que se presentan a continuación:

3.3.1 Requisitos funcionales

Los requisitos funcionales (RF) son aquellos que especifican las funciones y capacidades que el software tiene para satisfacer las necesidades del usuario y alcanzar los objetivos del sistema. A continuación, se visualizan en las siguientes tablas.

Tabla 3.11 Requisitos funcionales – Registrar usuario

ID	RF1
Nombre	Registrar usuario.
Tipo	Requisito
Prioridad	Media
Descripción	La plataforma presenta un conjunto de campos obligatorios necesarios para completar el proceso de registro.
Observación	El usuario proporciona la información solicitada, la cual se verifica por el sistema antes de guardarse en la base de datos.
Salidas	Registro de datos con éxito.

Tabla 3.12 Requisitos funcionales – Registrar paciente

ID	RF2
Nombre	Registrar paciente.
Tipo	Requisito
Prioridad	Media
Descripción	La aplicación despliega un conjunto de campos obligatorios que el usuario completa para efectuar el registro.
Observación	Un usuario previamente autenticado se encarga de ingresar la información correspondiente al paciente, la cual se almacena por el

	sistema.
Salidas	Registro de datos con éxito.

Tabla 3.13 *Requisitos funcionales – Clasificar imagen de fondo de ojo*

ID	RF3
Nombre	Clasificar imagen de fondo de ojo.
Tipo	Requisito
Prioridad	Alta
Descripción	La plataforma habilita un campo destinado a la carga de una imagen del fondo de ojo, la cual se proporciona por el usuario.
Observación	Una vez recibida, el sistema procesa la imagen y devuelve un análisis correspondiente.
Salidas	Resultados de Clasificación

Tabla 3.14 *Requisitos funcionales – Consulta de clasificaciones*

ID	RF4
Nombre	Consulta de clasificaciones.
Tipo	Requisito
Prioridad	Media
Descripción	La plataforma despliega un listado con los análisis previamente efectuados.
Observación	Asimismo, se dispondrá de opciones para aplicar filtros sobre la información mostrada.
Salidas	No aplica

Tabla 3.15 *Requisitos funcionales – Recuperar reporte de clasificación.*

ID	RF5
Nombre	Recuperar reporte de clasificación.

ID	RF5
Tipo	Requisito
Prioridad	Media
Descripción	El sistema permite visualizar los resultados detallados de un informe previamente almacenado.
Observación	Además, se ofrece la funcionalidad de descargar dicho reporte en formato PDF.
Salidas	No aplica

Tabla 3.16 *Requisitos funcionales – Actualizar datos de usuario.*

ID	RF6
Nombre	Actualizar datos de usuario.
Tipo	Requisito
Prioridad	Baja
Descripción	El usuario realiza la modificación de la información de un paciente a través de un formulario habilitado para tal fin.
Observación	Ninguna.
Salidas	El usuario modifica los campos para actualizar

Tabla 3.17 *Requisitos funcionales – Consultar datos de pacientes.*

ID	RF7
Nombre	Consultar datos de pacientes.
Tipo	Requisito
Prioridad	Media
Descripción	El sistema despliega un listado con los usuarios registrados.
Observación	Únicamente se visualizan los pacientes asociados al usuario con perfil de doctor.
Salidas	No aplica

Tabla 3.18 Requisitos funcionales – Actualizar datos de paciente.

ID	RF8
Nombre	Actualizar datos de paciente.
Tipo	Requisito
Prioridad	Baja
Descripción	El usuario actualiza los datos de los pacientes mediante un formulario.
Observación	Ninguna
Salidas	El usuario modifica los campos que desea actualizar

Tabla 3.19 Requisitos funcionales – Eliminar datos de paciente.

ID	RF9
Nombre	Eliminar datos de paciente.
Tipo	Requisito
Prioridad	Baja
Descripción	El usuario lleva a cabo la eliminación de los datos correspondientes a un paciente seleccionado.
Observación	Como parte del proceso, se suprimen también los reportes vinculados a dicho paciente.
Salidas	La base de datos se actualiza para reflejar los cambios.

3.3.2 Requisitos no funcionales

Estos requisitos no están directamente vinculados a las funciones específicas del software, sino que se refieren a su desempeño en calidad, rendimiento y otros atributos. A continuación, se presentan los requisitos no funcionales (**RFN**) del sistema:

Tabla 3.20 Requisitos no funcionales – Base de datos.

ID	RNF1
Nombre	Base de datos
Tipo	Requisito
Prioridad	Alta

ID	RNF1
Descripción	Cada vez que se genera un nuevo registro, ya sea de usuario, paciente o análisis de imagen, la información correspondiente es almacenada en la base de datos.
Observación	Ninguna

Tabla 3.21 Requisitos no funcionales – Diseño responsivo.

ID	RNF2
Nombre	Diseño responsivo
Tipo	Requisito
Prioridad	Media
Descripción	La interfaz gráfica del usuario cuenta con un diseño responsivo, lo que le permite ajustarse automáticamente a distintas resoluciones para su correcta visualización en cualquier tipo de dispositivo.
Observación	Ninguna

Tabla 3.22 Requisitos no funcionales – Disponibilidad

ID	RNF3
Nombre	Disponibilidad
Tipo	Requisito
Prioridad	Media
Descripción	El sistema se encuentra accesible en todo momento y desde cualquier ubicación, conforme a las necesidades del usuario.
Observación	Ninguna

Tabla 3.23 Requisitos no funcionales – Rendimiento

ID	RNF4
Nombre	Rendimiento
Tipo	Requisito
Prioridad	Media

ID	RNF4
Descripción	El sistema ofrece tiempos de carga y respuesta óptimos para su uso como herramienta de soporte ágil. En el caso específico de la clasificación de imágenes, el procesamiento no excede los 10 segundos.
Observación	Ninguna

Tabla 3.24 Requisitos no funcionales – Internet

ID	RNF5
Nombre	Internet
Tipo	Requisito
Prioridad	Media
Descripción	Para acceder al sistema, es necesario contar con una conexión a internet estable, con una velocidad mínima recomendada entre 5 y 10 Mbps.
Observación	Ninguna

3.3.3 Casos de uso

En base a los requisitos funcionales se desarrolló un diagrama de casos de uso representando las acciones del usuario. A continuación, se muestra el diagrama realizado.




Figura 3.5 Diagrama de casos de uso

3.3.3.1 Narrativas de casos de uso

Una vez que se definen los casos de uso se procedió a realizar su respectiva narrativa a continuación se describe cada una de ellas:

Tabla 3.25 Narrativa de caso de uso – Registrar Paciente

Caso de Uso	Registrar Paciente
Actor	Usuario/ofthalmólogo
Precondición	El usuario inicia sesión en la aplicación web mediante el proceso de autenticación.
Postcondición	La información que se capturo se registra correctamente en la base de datos.
Fujo Básico	
Actor	Sistema
1. El usuario ingresa a la sección de registro dentro de la aplicación web.	
	2. Despliega un formulario solicitando los siguientes datos del paciente: nombre(s), primer apellido, segundo apellido, fecha de nacimiento, género, estado y ciudad.
3. El usuario completa el formulario con la información requerida y selecciona la opción "Registrar Paciente".	
	4. Verifica que todos los campos se han llenado correctamente. Si se detecta alguna omisión o dato inválido, se redirige al flujo alternativo "Datos de entrada inválidos". 5. Asigna un identificador único al paciente.

	El sistema almacena los datos ingresados. 7. Fin del caso de uso.
Flujo alternativo – Datos de entrada inválidos.	
Actor	Sistema
	El usuario no completó el formulario correctamente, el sistema despliega un mensaje de error indicando la existencia de campos incorrectos o incompletos, y solicita al usuario que realice las correcciones necesarias antes de continuar con el registro.

Tabla 3.26 Narrativa de caso de uso – Generar Diagnostico

Caso de Uso	Generar Diagnostico
Actor	Usuario/ofthalmólogo
Precondición	El usuario accedió exitosamente a la aplicación web. Existen pacientes previamente registrados en el sistema.
Postcondición	La información generada se almacena correctamente en la base de datos.
Fujo Básico	
Actor	Sistema
El usuario Selecciona un paciente desde la lista disponible. 2. Indica el ojo a analizar: izquierdo o derecho. 3. Sube o arrastra al sistema la imagen correspondiente al fondo de ojo.	
	4. Recibe y registra la imagen cargada.

5. Presiona el botón "Generar Diagnóstico".	
	Realiza el análisis con el modelo entrenado. Va a la pantalla de resultados y muestra el reporte de análisis con el porcentaje de precisión de cada uno de los posibles grados de avance. Ver flujo alternativo “Guardar Reporte”. 9. Fin de caso de uso.
Flujo alternativo – Guardar Reporte.	
Actor	Sistema
Selecciona la opción "Guardar" para almacenar el reporte generado	
	Registra el reporte en la base de datos y lo asocia al paciente correspondiente. 3. Redirige al usuario a la pantalla principal.

Tabla 3.27 Narrativa de caso de uso – Consultar Historial de Reportes

Caso de Uso	Consultar Historial de Reportes
Actor	Usuario/ofthalmólogo
Precondición	El usuario inicio sesión correctamente en la aplicación web. Existen reportes previamente registrados en el sistema.
Postcondición	Ninguna.
Fujo Básico	
Actor	Sistema

Selecciona la opción “Ver Historial de Diagnósticos” dentro del sistema. 2. De manera opcional, aplica filtros para refinar la búsqueda de reportes.	
	3. Muestra un listado con los reportes generados previamente.
4. Si lo desea, selecciona un reporte específico y hace clic en “Imprimir”. Se continúa con el flujo alternativo “Imprimir Reporte”.	
	5. Fin del caso de uso.
Flujo alternativo – Imprimir Reporte.	
Actor	Sistema
	1. Genera y proporciona un documento en formato PDF con el contenido del reporte seleccionado. Este incluye los resultados del análisis, así como los datos del paciente correspondiente.

Tabla 3.28 Narrativa de caso de uso – Consultar Lista de Pacientes

Caso de Uso	Consultar Lista de Pacientes
Actor	Usuario/ofthalmólogo
Precondición	El usuario accedió correctamente a la aplicación web. Existen pacientes previamente registrados en el sistema.
Postcondición	Ninguna
Fujo Básico	
Actor	Sistema
1. Selecciona la opción “Ver lista de	

pacientes” en la interfaz de la aplicación.	
	2. Carga y muestra la lista de pacientes registrados disponibles para consulta.
3. Fin del caso de uso.	

Tabla 3.29 Narrativa de caso de uso – Actualizar Datos de Paciente

Caso de Uso	Actualizar Datos de Paciente
Actor	Usuario/ofthalmólogo
Precondición	El sistema cuenta con pacientes previamente registrados. El usuario accedió a la lista de pacientes.
Postcondición	La información del paciente se actualiza correctamente en la base de datos.
Fujo Básico	
Actor	Sistema
1. Selecciona un paciente desde la lista disponible. 2. Hace clic en la opción “Actualizar”.	
	3. Carga una interfaz con el formulario que contiene los datos actuales del paciente.
4. Realiza las modificaciones necesarias en los campos deseados. 5. Presiona el botón “Guardar” para confirmar los cambios.	

	6. Verifica que todos los campos estén correctamente completados. Si se detectan errores u omisiones, se redirige al flujo alternativo “Datos de entrada inválidos”. 7. Actualiza la información del paciente en la base de datos. 8. Fin del caso de uso.
Flujo alternativo – Datos de entrada inválidos.	
Actor	Sistema
	1. Detecta que el formulario no se completo correctamente, muestra un mensaje de error e indica al usuario que corrija los campos inválidos o incompletos.

Tabla 3.30 Narrativa de caso de uso – Eliminar Datos

Caso de Uso	Eliminar Datos
Actor	Usuario/ofthalmólogo
Precondición	El sistema cuenta con pacientes registrados. El usuario ingreso previamente a la lista de pacientes.
Postcondición	La base de datos se actualiza al eliminar los registros del paciente seleccionado.
Fujo Básico	
Actor	Sistema
1. Selecciona un paciente desde la lista disponible. 2. Hace clic en la opción “Eliminar Datos”.	

	3. Despliega un mensaje solicitando confirmación para proceder con la eliminación.
4. Confirma la acción haciendo clic en “Aceptar”.	
	5. Elimina de forma permanente los datos del paciente, junto con los reportes relacionados, de la base de datos. 6. Fin del caso de uso.

Tabla 3.31 Narrativa de caso de uso – Actualizar Datos de Usuario

Caso de Uso	Actualizar Datos de Usuario
Actor	Usuario/ofthalmólogo
Precondición	El usuario inicio sesión correctamente en la aplicación web.
Postcondición	Los datos personales del usuario se actualizan exitosamente en la base de datos.
Fujo Básico	
Actor	Sistema
1. Hace clic en la opción “Actualizar Datos” dentro del sistema.	
	2. Muestra una pantalla con un formulario que contiene la información actual del usuario.

Caso de Uso	Actualizar Datos de Usuario
3. Modifica los campos deseados con la información que desea actualizar. 4. Hace clic en “Guardar” para enviar los cambios.	
	5. Verifica que todos los campos requeridos estén correctamente completados. Si se detecta alguna omisión o error, se dirige al flujo alternativo “Datos de entrada inválidos”. 6. Actualiza los datos del usuario en la base de datos. 7. Fin del caso de uso.
Flujo alternativo – Datos de entrada inválidos.	
Actor	Sistema
	. Detecta que el formulario contiene errores o campos incompletos, muestra un mensaje de advertencia solicitando al usuario que corrija la información ingresada.

Las narrativas de casos de uso son esenciales porque proporcionan una descripción clara y detallada de cómo los usuarios interactúan con un sistema, lo que permite comprender mejor los requisitos funcionales y las expectativas. Estas narrativas ayudan a alinear a los equipos de desarrollo, diseño y negocios al definir escenarios reales de uso, lo que facilita la identificación de posibles problemas, la priorización de funcionalidades y la toma de decisiones informadas durante el diseño y la implementación del sistema. Además, son una herramienta clave para garantizar que el producto final cumpla con las necesidades del usuario y los objetivos del proyecto.

3.3.4 Diagrama Entidad-Relación

Una vez que se definieron los casos de uso y sus respectivas narrativas, se continua con la presentación del diagrama entidad-relación como se observa en la figura 3.6. Un DER (Diagrama Entidad-Relación) es una representación gráfica que muestra las conexiones entre entidades en un mismo sistema.



Figura. 3.6 Diagrama Entidad-Relación

3.3.4.1 Diccionario de datos

A continuación, se describe el diccionario de datos que se obtuvo del diagrama Entidad-Relación como se observa en la figura 3.6

Tabla 3.32 Datos_Generales

Campo	Llave Primaria	Tipo	Nulo	Descripción
id	Sí	INTEGER (IDENTITY)	No	Identificador único (clave primaria).
name	No	CHARACTER VARYING(10)	No	Nombre del paciente o usuario.
lastname	No	CHARACTER VARYING(50)	No	Apellido del paciente o usuario.
birthdate	No	DATE	No	Fecha de nacimiento del paciente o usuario.
city	No	CHARACTER VARYING(100)	No	Ciudad de residencia del paciente o usuario.
gender	No	CHARACTER(1)	No	Género del paciente o usuario (M/F).
phone	No	BIGINT	Sí	Número de teléfono del paciente o usuario.
photo	No	CHARACTER VARYING(255)	Sí	Ruta o nombre de archivo de la foto del paciente o usuario.

Tabla 3.33 Usuarios

Campo	Llave Primaria	Tipo	Nulo	Descripción
id	Sí	INTEGER (IDENTITY)	No	Identificador único de cada usuario (clave primaria).

Campo	Llave Primaria	Tipo	Nulo	Descripción
username	No	CHARACTER VARYING(100)	No	Nombre de usuario utilizado para la autenticación.
password	No	CHARACTER VARYING(255)	No	Contraseña del usuario (almacenada de forma segura).
email	No	CHARACTER VARYING(255)	No	Dirección de correo electrónico del usuario.
rol	No	INTEGER	No	Rol del usuario en el sistema (ejemplo: administrador, paciente).

Tabla 3.34 Pacientes

Campo	Llave Primaria	Tipo	Nulo	Descripción
id	Sí	INTEGER (IDENTITY)	No	Identificador único de cada paciente (clave primaria).
doctor_id	No	INTEGER	No	ID del doctor asignado a este paciente (clave foránea).
enfermedad	No	CHARACTER VARYING(255)	Sí	Descripción de la enfermedad del paciente.
ngs	No	CHARACTER VARYING(25)	Sí	Número de identificación del paciente.

Tabla 3.35 Reportes

Campo	Llave Primaria	Tipo	Nulo	Descripción
id	Sí	INTEGER (IDENTITY)	No	Identificador único del reporte (clave primaria).
patient_id	No	INTEGER	No	ID del paciente al que pertenece el reporte (clave

Campo	Llave Primaria	Tipo	Nulo	Descripción
				foránea).
side	No	CHARACTER VARYING(25)	No	Lado del cuerpo (izquierda/der echa) relacionado con el reporte.
accuracy	No	DOUBLE PRECISION	No	Precisión del análisis del reporte.
image	No	CHARACTER VARYING(255)	No	Ruta o nombre de archivo de la imagen asociada al reporte.
analysis_date	No	DATE	No	Fecha en la que se realizó el análisis.
recommendations	No	TEXT	Sí	Recomendaciones derivadas del análisis.

Los diccionarios de datos son herramientas fundamentales dentro del diseño y gestión de una base de datos. Su propósito principal es documentar de manera detallada cada uno de los elementos que la componen, como las tablas, los campos, los tipos de datos, los valores permitidos, las relaciones entre tablas y cualquier otra regla o restricción asociada. Funcionan como una especie de "manual técnico" que permite a los desarrolladores, administradores y usuarios entender con claridad cómo está estructurada la base de datos y cómo deben interactuar con ella. Además, facilitan el mantenimiento, ayudan a prevenir errores en la manipulación de los datos y garantizan que se mantenga la integridad, coherencia y calidad de la información almacenada a lo largo del tiempo.

3.3.5 Diagrama de clases

Después de lo desarrollado en los puntos anteriores se generó el respectivo diagrama de clases el cual se muestra en la figura 3.7




Figura. 3.7 Diagrama Entidad-Relación


3.3.6 Diseño del módulo web

A partir del diseño interno del sistema, se desarrolló la capa externa encargada de facilitar la interacción con el usuario, asegurando que se alineara con las historias de usuario definidas previamente. También se consideró fundamental elegir un nombre adecuado para la aplicación, que reflejara claramente su propósito y permitiera a los usuarios identificarla fácilmente. Como resultado, se nombró al sistema “WAMDS2” destacando su función principal. Además, se crearon varios wireframes para las interfaces gráficas necesarias en la aplicación web del sistema.



Figura. 3.8 Pantalla Acceso-Login

El usuario necesita ingresar sus credenciales (nombre de usuario y contraseña) para acceder al sistema. Sin embargo, es imprescindible que previamente esté registrado. Para ello, se requiere una pantalla que permita al médico interesado en registrarse proporcionar sus datos, la cual se muestra en la Figura 3.8



WAMDS2

EDUCACIÓN SECRETARÍA DE EDUCACIÓN PÚBLICA

TECNOLOGÍAS NACIONALES DE MÉXICO

Inicio Realizar detección Historial de analisis Registrar Usuario Cerrar Sesión

Registrar Usuario

Nombre(s): Roberto

Apellido paterno: Marquez

Apellido materno: Castro

Teléfono: 2721696251

Fecha de nacimiento: 07/08/1998

Género: ☐ Femenino ☐ Masculino

Estado: Veracruz

Ciudad: Nogales

Rol: Médico

Correo electrónico: roberto_mar@live.com.mx

Contraseña: *****

Fotografía: Seleccionar archivo No se ha seleccionado archivo

Limpiar formulario Registrar Cancelar

Figura. 3.9 Pantalla - Registro de usuario.

Después de registrarse e iniciar sesión, el usuario accede a la pantalla principal del sistema, mostrada en la Figura 3.8. En esta interfaz, tiene acceso directo a diversas funciones, como registrar pacientes y generar diagnósticos, además de contar con botones que permiten navegar hacia otras funcionalidades del sistema.




Figura. 3.10 Pantalla – Realizar detección (Generar Diagnostico).

El usuario selecciona a un paciente previamente ya registrado y ahí mismo carga la imagen de fondo de ojo para realizar la detección (en este caso, se espera que el médico, como usuario final, suba imágenes de fondo de ojo a la aplicación), indicar si el ojo a analizar es el derecho o el izquierdo, y hacer clic en "Realizar detección". Una vez realizado este proceso, el sistema muestra una nueva pantalla (Figura 3.11) con el reporte del análisis.




Figura. 3.11 Pantalla – Reporte del análisis.

Una vez que se realiza la detección se muestra el reporte del análisis de la imagen en cual el usuario podrá ver los datos del paciente y su fotografía, así mismo observa la imagen que se analizó, el nivel de afectación, el porcentaje de precisión y tiene la opción de guardar el reporte o descartarlo.

WAMDS2

EDUCACIÓN SECRETARÍA DE EDUCACIÓN PÚBLICA

TECNOLOGÍA NACIONAL DE MÉXICO

Inicio Realizar detección **Historial de analisis** Registrar Usuario Cerrar Sesión

Historial de analisis

Filtrar por: Fecha Fecha inicial 16/05/2024 Fecha final 19/05/2024 Filtrar Descargar PDF Descargar Excel

ID	Fecha	Paciente	Genero	Nivel de afectación	Presicion del resultado	
75857	16/05/2024	José Luis Sánchez Cervantes	M	Leve	90.01%	  
67845	17/05/2024	Jorge Ernesto Gonzalez Diaz	M	Avanzado	98.92%	  
87695	18/05/2024	Luis Rodolfo Cabrera Elias	M	Moderado	92.21%	  
98989	19/05/2024	Alma Ivonne Sánchez García	F	Moderado	94.10%	  
09809	19/05/2024	Augusto Javier Reyes Delgado	M	Sin Afectación	95.35%	  

<< 1 2 3 >>

Figura. 3.12 Pantalla – Historial de análisis

El usuario observa la lista de los pacientes registrados y tiene la opción de filtrar por fecha de análisis, género y nivel de afectación así mismo tiene la opción de modificar o eliminar los datos de un paciente. Si lo requiere tiene la opción de descargar la lista de los pacientes en formato de Excel y el reporte del análisis de la imagen de fondo de ojo en formato PDF.

3.4 Codificación y Desarrollo

La tercera etapa de la metodología XP corresponde a la fase de desarrollo, durante la cual se escribe el código necesario para implementar las historias de usuario previamente definidas.

Esto implica construir los mecanismos funcionales que darán forma al sistema propuesto.

En esta fase, se documentan los procesos involucrados en el desarrollo del sistema, incluyendo tanto el entrenamiento del modelo de visión artificial basado en transformadores como la integración de este modelo en una aplicación diseñada para que el usuario final acceda a sus funcionalidades. Para entrenar el modelo de visión artificial, es fundamental disponer de datos de entrenamiento, un aspecto que se aborda en el siguiente apartado.

3.4.1 Conjunto de datos de entrenamiento

El modelo de visión artificial analiza las características presentes en las imágenes de fondo de ojo para llevar a cabo una clasificación precisa y consistente. Para lograrlo, resulta crucial contar con un conjunto de datos de entrenamiento que sea extenso, diverso y correctamente etiquetado.

3.4.1.1 Obtención de conjuntos de datos

Para recopilar imágenes de fondo de ojo con la condición de degeneración macular asociada con la edad, se exploraron diversos repositorios de datos. Como resultado, se seleccionaron dos fuentes principales para extraer imágenes y conformar un nuevo conjunto de datos: el conjunto iChallenge-AMD [47] y un dataset disponible en Kaggle, publicado por Mujib [48], que a su vez reúne imágenes provenientes de varios conjuntos de datos.

Estas imágenes están clasificadas de manera binaria, diferenciando únicamente entre aquellas que presentan degeneración macular y las que no. Sin embargo, el objetivo del proyecto de tesis es clasificar las imágenes de fondo de ojo según los diferentes niveles de progresión de la degeneración macular húmeda. Para cumplir este propósito, es necesario etiquetar las imágenes de acuerdo con la severidad de la condición.

3.4.1.2 Etiquetado de imágenes

Para garantizar un etiquetado preciso de las imágenes del conjunto de datos, fue indispensable contar con la colaboración de expertos en oftalmología. En este proyecto, participaron el Dra. Mariana Méndez López, directora de proyectos y logística, y el Dr. Diego Alberto Flores Pineda, perteneciente al Instituto de Oftalmología Fundación Doctor Hernández Zurita I.B.P. Este último se encargó específicamente de clasificar las imágenes de fondo de ojo provenientes de los conjuntos de datos seleccionados.


Grado	Imagen
NO DMAE	
DMAE SECA	
DMAE HUMEDA	

Figura 3.13 *Imágenes clasificadas en los diferentes grados de avance.*

Una vez completada la clasificación de las imágenes según los diferentes grados de avance, se llevó a cabo un proceso de aumento de datos.

3.4.1.3 Aumento de datos

El proceso de aumento de datos, que implica aplicar diversas transformaciones a las imágenes para ampliar el conjunto de entrenamiento, se implementó ya que el número de imágenes disponible se consideraba insuficiente, lo cual genera problemas asociados a un conjunto de datos pequeño. Antes de aplicar este proceso, se separaron imágenes específicas para los segmentos de prueba y validación, los cuales no fueron sometidos a las transformaciones.

Las transformaciones se realizaron utilizando la interfaz de Keras (de TensorFlow), y se incluyeron los siguientes cambios: 1) rotación, 2) traslación vertical, 3) traslación horizontal, 4) volteo vertical, 5) volteo horizontal, 6) ajustes de brillo y 7) ajustes de contraste.

Listado 3.1 Transformaciones con Keras.


```
1  from tensorflow.keras.preprocessing.image import
2  ImageDataGenerator, array_to_img, img_to_array, load_img

4  datagen = ImageDataGenerator(
5      rotation_range=10,
6      width_shift_range=0.03,
7      height_shift_range=0.03,
8      horizontal_flip=True,
9      vertical_flip=True,
10     fill_mode='nearest',
11     brightness_range=[0.4,1.5],
12     channel_shift_range=100
13 )
```

El fragmento de código mostrado en el Listado 3.1 implementa una serie de transformaciones aleatorias sobre el conjunto de datos original. Estas transformaciones permitieron la generación de nuevas instancias de imágenes, utilizadas para conformar el conjunto final de entrenamiento. En particular, se decidió generar cinco variaciones por cada imagen original, manteniendo una resolución de 300x300 píxeles. No obstante, algunas de las imágenes resultantes presentaron defectos visuales, como iluminación excesiva, alteraciones en el contraste o una combinación de ambos factores, por lo que fueron excluidas del conjunto de entrenamiento.

3.4.1.4 Creación del conjunto de datos

Tras finalizar el proceso de aumento de datos, se construyó el conjunto definitivo destinado al entrenamiento del modelo de visión artificial. Las imágenes transformadas se asignaron al segmento de entrenamiento, alcanzando un total de 710 muestras. Este conjunto se integró posteriormente con los conjuntos de prueba y validación, compuestos cada uno por 52 imágenes, según lo descrito previamente, conformando así el conjunto de datos final. Dicho conjunto se aloja en la plataforma Hugging Face, como se ilustra en la Figura 3.14, bajo el identificador “dmae-humeda-da”. Desde esta plataforma, el conjunto está disponible para su descarga, consulta y utilización en tareas de entrenamiento de modelos de visión por computadora.



Datasets: RobertoSonic / dmae-humeda-da like 0

Modalities: Image Formats: parquet Size: < 1K Libraries: Datasets pandas Croissant +1

Dataset card Viewer Files and versions Community Settings

Dataset Viewer Auto-converted to Parquet API Embed Full Screen Viewer

Split (3)
train · 606 rows

Split (3)

- train (606 rows)
- validation (52 rows)
- test (52 rows)

label
class label

5 classes

	1 avanzada humeda
	1 avanzada humeda
	1 avanzada humeda
	1 avanzada humeda
	1 avanzada humeda

< Previous 1 2 3 ... 7 Next >

Figura 3.14 Conjunto de datos en Hugging Face.

3.4.2 Entrenamiento del modelo

Una vez que el conjunto de datos de entrenamiento estuvo listo, se inició el proceso de entrenamiento del modelo de visión artificial. Para ello, se utilizó la versión de Swin Transformer V2 proporcionado por Google, junto con el framework PyTorch y la librería Transformers. El entrenamiento se realizó mediante notebooks en la plataforma Google Colab, y se aprovechó la plataforma de Hugging Face tanto para acceder al conjunto de datos previamente creado como para alojar el modelo entrenado.

3.4.2.1 Implementación del modelo

```
1 model_checkpoint = "microsoft/swinv2-tiny-patch4-window8-256"  
  # pre-trained model from which to fine-tune
```

Listado 3.2 Modelo que se utiliza

Se cargo el conjunto de datos que se creó en el notebook

Listado 3.3 Carga del conjunto de datos.

```
1 from datasets import load_dataset  
2 ...  
3 dataset = load_dataset("RobertoSonic/dmae-humeda-da ")
```

Para llevar a cabo el proceso de entrenamiento, es imprescindible definir una serie de parámetros conocidos como hiperparámetros o "argumentos de entrenamiento". Estos parámetros son esenciales para configurar el proceso y cubren aspectos como el punto de control, la cantidad de épocas de entrenamiento y la tasa de aprendizaje, entre otros. Un ejemplo de estos hiperparámetros se presenta en el Listado 3.4.

Listado 3.4 Ajuste de hiperparámetros.

```
1 model_name = model_checkpoint.split("/")[-1]

2 args = TrainingArguments(
3     f"{model_name}-dmae-humeda-DA",
4     remove_unused_columns=False,
5     evaluation_strategy = "epoch",
6     save_strategy = "epoch",
7     learning_rate=5e-5,
8     per_device_train_batch_size=batch_size,
9     gradient_accumulation_steps=4,
10    per_device_eval_batch_size=batch_size,
11    num_train_epochs=40,
12
13    warmup_ratio=0.1,
14    logging_steps=10,
15    load_best_model_at_end=True,
16    metric_for_best_model="accuracy",
17    push_to_hub=True,
```

Los hiperparámetros se describen brevemente a continuación:

- **Tasa de aprendizaje (`learning_rate`):** Hiperparámetro que regula el ajuste de los pesos del modelo en cada actualización durante el entrenamiento. Se establece en $5e-5$.
- **Tamaño del lote de entrenamiento por dispositivo (`per_device_train_batch_size`):** Define el tamaño del lote de entrenamiento para cada dispositivo de procesamiento. Se configura mediante la variable `batch_size`.
- **Pasos de acumulación de gradientes (`gradient_accumulation_steps`):** Establece cuántos pasos de retropropagación se acumulan antes de actualizar los pesos del modelo. Su valor es 4.
- **Número total de épocas de entrenamiento (`num_train_epochs`):** Especifica cuántas veces el modelo recorre el conjunto completo de datos de entrenamiento. Se fija en 40.
- **Proporción de calentamiento (`warmup_ratio`):** Indica la fracción del total de épocas destinada al periodo de calentamiento, en este caso, el 10%.
- **Frecuencia de registro de métricas (`logging_steps`):** Determina cada cuántos pasos se registran las métricas durante el entrenamiento. Se establece en 10 pasos.

Los valores asignados a los hiperparámetros se ajustan a través de un proceso experimental. Se probaron diferentes configuraciones, como 12, 14 y 16 épocas de entrenamiento, y se concluyó que alrededor de 40 épocas era el valor más adecuado hasta el momento para las condiciones del modelo.

3.4.3 Resultados del modelo

Se realizaron primeros entrenamientos con diferentes configuraciones de hiperparámetros, observando un aumento en la precisión conforme se realizaron los ajustes.




Figura 3.15 Métricas de entrenamiento (precisión y pérdida).

El modelo entrenado “dmae-humeda-da” alcanzó una precisión de 0.7692 con una pérdida del 0.9032, como se muestra en la Figura 3.16.

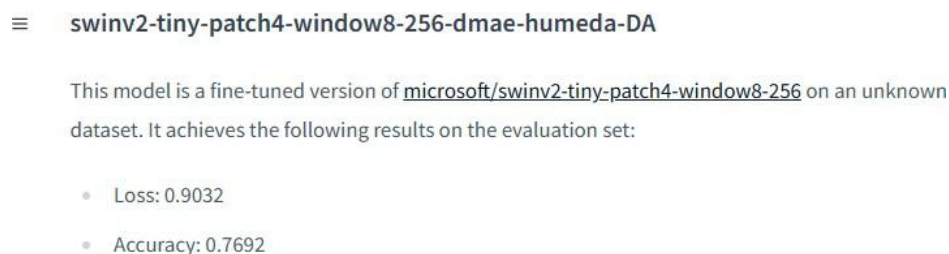


Figura 3.16 Tarjeta del modelo.

3.4.3.1 Evaluación del modelo

Creado el modelo, se pasó a evaluar la precisión del mismo, para ello se utilizaron 52 imágenes de fondo de ojo y se evaluaron las métricas de: 1.-*Accuracy* (Exactitud), 2.-*Precision* (Precisión), 3.- Sensibilidad y 4.- F1 Score.

```
!pip install datasets==3.0.0 --quiet
2 import torch
3
4 import numpy as np
5
6 from torch.utils.data import DataLoader
7 from PIL import Image
8
9
10 dataset = load_dataset("RobertoSonic/dmae-humeda-da"),
11 split="test")
12
13 model_name = "swinv2-tiny-patch4-window8-256-dmae-humeda-DA "
14 model=AutoModelForImageClassification.from_pretrained(model_name
15 ).to(device)
16
17
18 ...
19
```

Listado 3.5 Código evaluación del modelo.

Los resultados obtenidos de la evaluación se muestran en la Tabla 3.36.

Tabla 3.36 Métricas de evaluación por clase.

Accuracy	Set	Class	Precision	Sensitivity	F1-Score
0.7692	Test	No amd	0.5714	0.8000	0.6666
		Mild	0.7894	0.7142	0.7500
		Moderate	0.7058	0.8000	0.7500
		Advanced	1.0000	0.6000	0.7500
		Advanced wet	1.0000	1.0000	1.000

Se observó en la tabla anterior que el modelo generaliza todas las clases con una precisión alrededor del 76%.

3.4.4 Desarrollo y control de interfaces gráficas

En esta fase del desarrollo se implementó la interfaz gráfica de usuario. Para construir el frontend se emplearon tecnologías como HTML, CSS y EJS, dado que el backend se estructuró utilizando Fast API en python. A continuación, se presenta el código fuente del front-end para el diseño de las interfaces de la aplicación:

3.4.4.1 Fragmento de código login.html — Acceso

```

1 <div class="container-fluid vh-100 d-flex align-items-center justify-
2 content-center bg-light" style="background-color: #005aa7
3 !important;">
4 <div class="row w-100">
5 <div class="col-md-7 d-none d-md-block" style="background-image:
6 url('assets/eye-bg.jpg'); background-size: cover;">
7     <div class="p-5 text-white" style="background: rgba(0,0,0,0.6);
8     height: 100%;">
9     <h2 class="fw-bold">WAMDS2</h2>
10    <h5 class="mt-4">"Transformando el diagnóstico de enfermedades
11    Oftalmológicas con Inteligencia Artificial"</h5>
12    <p class="mt-3">
13        Bienvenido/a a la plataforma que utiliza técnicas de
14        inteligencia artificial y aprendizaje profundo para la
15        detección temprana de la Degeneración Macular Asociada
16        Con la Edad variante húmeda. Aquí, podrás subir
17        imágenes, recibir análisis detallados y colaborar en
18        investigaciones innovadoras sobre salud ocular.
19    </p>

```

3.4.4.2 Fragmento de código login.css

```
2 body, html {  
3   margin: 0;  
4   padding: 0;  
5   height: 100%;  
6 }  
7 .bg-primary {  
8   background: linear-gradient(to bottom,  
9     #005aa7, #fffde4);
```

El fragmento de código login.css establece estilos básicos para la vista de inicio de sesión. Se definen reglas globales para los elementos body y html, eliminando márgenes y rellenos por defecto, y asegurando que ocupen el 100% de la altura de la ventana.

3.4.4.3 Fragmento de código Multiclass Deteccion.html

```
<div class="container text-center">  
2   <br>  
3   <h3 class="text-center mb-1">Deteccion Multiclase</h3>  
4   <div class="row">  
5     <div class="col">  
6       <h2>Bienvenido: Dr. {{userdata.name}} {{userdata.firstname}}  
7     {{userdata.slastname}}</h2>  
8       <img [src]="userdata.photo == null ? 'assets/icono_patient.png' :  
9     'http://localhost:8000/'+userdata.photo" width="150px" height="200px">  
10      <br>  
11      <br>  
12    </div>  
13    <div class="col">  
14      <label for="paciente" class="form-label text-  
15 start"><strong>Paciente:</strong></label>  
16      <select class="form-select"  
17 [(ngModel)]="selectedIndex" (change)="onSelectPatient(selectedIndex)">  
18        <option *ngFor="let i of patients; let idx=index" [value]="idx">  
19          {{i.fullname}}
```

Esta sección de código, la interfaz muestra un mensaje de bienvenida personalizado para el doctor que inicia sesión, facilitando una navegación clara y personalizada dentro de la plataforma de detección multiclase.

3.4.4.4 Fragmento de código Multiclass Deteccion.css

```
1  .blue-box {
2    border: 2px solid blue;
3    background-color: #cce5ff; /* tono azul claro */
4    padding: 20px;
5    text-align: center;
6    width: 300px; /* ajusta el tamaño según necesites */
7    margin: 20px auto; /* centra el cuadro en la página */
8    border-radius: 8px; /* esquinas redondeadas opcionales */
9  }
10 .blue-box p {
11   font-size: 16px;
12   font-weight: bold;
13   margin-bottom: 15px;
14   color: #003366; /* color del texto */
15 }
16 .blue-box img {
17   max-width: 100%;
18   height: auto;
19 }
20
21 .blue-box {
22 border: 2px dashed blue;
23 background-color: #cce5ff; /* Fondo azul claro */
24 padding: 20px;
25 text-align: center;
26 width: 300px;
27 margin: 20px auto;
28 border-radius: 8px;
```

Este diseño visual crea un recuadro azul claro que resalta información importante de forma agradable y ordenada. El recuadro tiene un borde azul punteado y esquinas redondeadas para hacerlo más amigable a la vista. Su contenido está centrado y presenta un espacio adecuado alrededor del texto o imagen para facilitar la lectura.

3.4.4.5 Fragmento de código History patient.html

```
1 <!DOCTYPE html>
2 <html lang="es">
3 <head>
4   <meta charset="UTF-8">
5   <title>Historial de análisis</title>
6   <link
7     href="https://cdn.jsdelivr.net/npm/bootstrap@5.3.2/dist/css/bootstr
8     ap.min.css" rel="stylesheet">
9   <link href="https://cdn.jsdelivr.net/npm/bootstrap-
10     icons/font/bootstrap-icons.css" rel="stylesheet">
11 </head>
12
13 <div class="container filtro-container">
14   <h4 class="text-center mb-4">Historial de análisis</h4>
15
16   <div class="row g-2 align-items-end mb-3">
17     <div class="col-md-2">
18       <label for="filtro" class="form-label">Filtrar por:</label>
19       <select class="form-select" [(ngModel)]="filter" id="filtro">
20         <option value="date" selected>Fecha</option>
21         <option value="patient">Paciente</option>
22         <option value="level">Nivel de afectación</option>
23         <option value="gender">Genero</option>
24       </select>
25     </div>
26     <div class="col-md-3" *ngIf="filter == 'date'">
27       <label for="fechaInicio" class="form-label">Fecha
28       inicial</label>
```

Este fragmento de la aplicación web está diseñada para que el usuario, en este caso el oftalmólogo o medico familiar, tenga la opción de visualizar, filtrar y gestionar el historial de análisis realizados a los pacientes. El código genera una interfaz con un diseño claro y organizado que permite seleccionar distintos filtros como fecha, nombre del paciente, nivel de afectación o género, con el fin de facilitar la búsqueda de reportes específicos.

3.4.4.6 Fragmento de código History patient.css

```
body {  
2  
3     background-size: cover;  
4     background-position: center;  
5     background-attachment: fixed;  
6 }  
7  
8 .filtro-container {  
9     padding: 20px;  
10    border-radius: 10px;  
11    margin-top: 30px;  
12 }  
13  
14 .tabla-container {  
15     border-radius: 10px;  
16     padding: 20px;  
17     margin-top: 20px;  
18 }  
19  
20 .btn-exportar {  
21     min-width: 140px;  
22 }  
23  
24 .badge-accion {  
25     border: none;  
26     font-size: 1rem;  
27 }
```

Este fragmento de código mejora la experiencia visual del usuario al consultar el historial de análisis. El fondo se adapta al tamaño de la pantalla y permanece fijo al hacer scroll, lo que genera una vista limpia y estable. Los contenedores del filtro y la tabla están diseñados con bordes redondeados, márgenes y espacio interno para facilitar la lectura y la organización visual.

3.4.4.7 Fragmento de código Lista-usuarios.html

```
<!DOCTYPE html>
2 <html lang="es">
3 <head>
4   <meta charset="UTF-8">
5   <title>Lista de {{filterMode === "paciente" ? "pacientes" :
6 "usuarios"}}</title>
7   <link
8 href="https://cdn.jsdelivr.net/npm/bootstrap@5.3.2/dist/css/bootstr
9 ap.min.css" rel="stylesheet">
10  <link href="https://cdn.jsdelivr.net/npm/bootstrap-
11 icons/font/bootstrap-icons.css" rel="stylesheet">
12 </head>
13
14 <div class="container filtro-container">
15   <br>
16   <h4 class="text-center mb-4"><strong>Lista de {{filterMode ===
17 "paciente" ? "pacientes" : "usuarios"}}</strong></h4>
18
19   <div class="row g-2 align-items-end mb-3">
20     <div class="col-md-2">
21       <label for="filtro" class="form-label">Filtrar por:</label>
22       <select [(ngModel)]="filterMode" (change)="loadUsers()"
23 class="form-select" id="filtro">
24         <option selected></option>
25         <option value="paciente">Paciente</option>
26         <option value="user">Usuario</option>
27       </select>
28     </div>
```

Este fragmento HTML presenta al usuario una interfaz para visualizar y gestionar una lista de personas, ya sea de pacientes o usuarios, según el filtro seleccionado. Al cargar la página, el usuario encuentra un encabezado claro que cambia dinámicamente dependiendo del tipo de lista elegida. Justo debajo, se ofrece un menú desplegable que permite filtrar por “paciente” o “usuario”.

3.4.4.8 Fragmento de código Lista-usuarios.css

```
2 body {  
3  
4     background-size: cover;  
5     background-position: center;  
6     background-attachment: fixed;  
7 }  
8  
9 .filtro-container {  
10     padding: 20px;  
11     border-radius: 10px;  
12     margin-top: 30px;  
13 }  
14  
15 .tabla-container {  
16     border-radius: 10px;  
17     padding: 20px;  
18     margin-top: 20px;  
19 }  
20  
21 .btn-exportar {  
22     min-width: 140px;  
23 }  
24  
25 .badge-accion {  
26     border: none;  
27     font-size: 1rem;  
28 }
```

Este fragmento de código CSS define estilos visuales enfocados en mejorar la experiencia del usuario al interactuar con la interfaz web. Se establece un fondo adaptable que permanece fijo mientras se navega, lo que aporta una apariencia moderna y limpia. Las secciones principales, como los contenedores de filtros y tablas, cuentan con bordes redondeados, relleno interno y márgenes superiores para ofrecer una disposición ordenada y cómoda a la vista.

3.4.4.9 Fragmento de código Report eye.html

```
2 <div class="card reporte">
3   <h3 class="text-center">Reporte</h3>
4   <div class="text-center my-2">
5     <button class="btn btn-imprimir" (click)="imprimir();">Imprimir
6 Reporte</button>
7     <button (click)="updateNotes();" class="btn btn-
8 primary">Guardar notas</button>
9   </div>
10
11 <h5 class="text-center">Reporte de Análisis de Imagen del Fondo
12 de Ojo</h5>
13 <table class="table table-bordered mt-3">
14   <tbody>
15     <tr>
16       <th>Doctor:</th>
17       <td>{{doctorName}}</td>
18     <th>Paciente:</th>
19     <td>{{reportData.name}} {{reportData.flastname}}
20 {{reportData.slastname}}</td>
21   </tr>
22   <tr>
23     <th>Edad:</th>
24     <td>{{reportData.edad}}</td>
25     <th>Género:</th>
26     <td>{{reportData.data == 'H' ? 'Hombre' : 'Mujer'}}</td>
27   </tr>
28   <tr>
29     <th>Ojo analizado:</th>
```

Este fragmento de código HTML está diseñado para presentar al usuario un reporte clínico detallado sobre el análisis de una imagen del fondo de ojo. La estructura está organizada visualmente en una tarjeta (card) que centraliza y da formato a la información médica, permitiendo al profesional de la salud ver datos clave.

3.4.4.10 Fragmento de código Report eye.css

```
1  .blue-box {
2      border: 2px solid blue;
3      background-color: #cce5ff; /* tono azul claro */
4      padding: 20px;
5      text-align: center;
6      width: 300px; /* ajusta el tamaño según necesites */
7      margin: 20px auto; /* centra el cuadro en la página */
8      border-radius: 8px; /* esquinas redondeadas opcionales */
9  }
10 .blue-box p {
11     font-size: 16px;
12     font-weight: bold;
13     margin-bottom: 15px;
14     color: #003366; /* color del texto */
15 }
16 .blue-box img {
17     max-width: 100%;
18     height: auto;
19 }
20
21 .blue-box {
22     border: 2px dashed blue;
23     background-color: #cce5ff; /* Fondo azul claro */
24     padding: 20px;
25     text-align: center;
26     width: 300px;
27     margin: 20px auto;
28     border-radius: 8px;
```

Este fragmento de código CSS define un estilo visual atractivo y funcional para el usuario mediante una caja azul (.blue-box) centrada en la página. Está diseñada con bordes azules (sólidos o punteados), un fondo azul claro, esquinas redondeadas y un tamaño fijo para destacar información importante.

3.4.4.11 Fragmento de código Registrar usuario.html

```
<div class="row">
2   <div class="col">
3     <h1>WAMDS2</h1>
4   </div>
5   <div class="col">
6     
7   </div>
8   <div class="col">
9     
10  </div>
11 </div>
12
13 <nav class="navbar navbar-expand-lg " data-bs-theme="dark"
14 style="background-color: #2E74B5; height: 50px;" >
15   <div class="container-fluid">
16   </div>
17 </nav>
18 <div class="background-container">
19 <div class="container text-center mb-2">
20   <br>
21   <h3 class="text-center mb-1">Registrar Usuario</h3>
22   <div class="row">
23     <div class="col">
24       <label for="name" class="text-start form-
25 label"><strong>Nombre:</strong></label>
26       <input type="text"
27 (keypress)="allowOnlyLetters($event);" [(ngModel)]="datos.name"
28 id="name" class="form-control">
```

Este fragmento de código corresponde a la interfaz de registro de usuarios dentro del sistema. Su diseño está centrado en la facilidad de uso, presentando un formulario limpio y ordenado donde el usuario ingresa su información personal de manera clara y segura. Se incluyen campos para capturar el nombre completo, cédula profesional y género, todos acompañados de etiquetas descriptivas para guiar al usuario.

3.4.4.12 Fragmento de código Registrar usuario.css

```
blue-box {  
2   border: 2px solid blue;  
3   background-color: #cce5ff; /* tono azul claro */  
4   padding: 20px;  
5   text-align: center;  
6   width: 300px; /* ajusta el tamaño según necesites */  
7   margin: 20px auto; /* centra el cuadro en la página */  
8   border-radius: 8px; /* esquinas redondeadas opcionales */  
9 }  
10 .blue-box p {  
11   font-size: 16px;  
12   font-weight: bold;  
13   margin-bottom: 15px;  
14   color: #003366; /* color del texto */  
15 }  
16 .blue-box img {  
17   max-width: 100%;  
18   height: auto;  
19 }  
20  
21 .blue-box {  
22   border: 2px dashed blue;  
23   background-color: #cce5ff; /* Fondo azul claro */  
24   padding: 20px;  
25   text-align: center;  
26   width: 300px;  
27   margin: 20px auto;  
28   border-radius: 8px;
```

El CSS aplicado al formulario de registro de usuarios está diseñado para ofrecer una experiencia visual limpia, organizada y accesible. Se usa un contenedor `blue-box` con fondo azul claro y bordes azules suaves (discontinuos) para enmarcar el formulario de manera amigable, lo que da al usuario una sensación de confianza y claridad.

3.4.4.13 Fragmento de código Carga de imagen de fondo de ojo

```
2 @router.post("/predict/")
3 async def predict(request:Request,file: UploadFile = File(...)):
4     # Leer el archivo de imagen
5     try:
6         app=request.app
7         image = Image.open(io.BytesIO(await file.read()))
8         if image.mode == "RGBA":
9             # Crear un fondo negro (RGB)
10             background = Image.new("RGB", image.size, (0, 0, 0)) #
11 Fondo negro
12
13             # Pegar la imagen sobre el fondo negro, usando el canal
14 alfa como máscara
15             background.paste(image, (0, 0),
16 image.convert("RGBA").split()[3]) # Usamos el canal alfa como
17 máscara
18
19             # La imagen "background" ahora tiene el fondo negro
20             image = background
21
22             # Preprocesar la imagen
23             inputs = app.state.processor(images=image,
24 return_tensors="pt")
```

Este endpoint del backend recibe una imagen enviada por el usuario, la procesa y la prepara para su análisis. Si la imagen tiene fondo transparente (formato RGBA), se convierte automáticamente en una versión con fondo negro para asegurar una visualización y análisis consistentes.

3.4.4.14 Fragmento de código para mostrar alerta

```
2  this.serv.predict(formData).subscribe((res:any)=>{
3      Swal.fire({
4          title: "Realizando predicci&oacute;n",
5          timerProgressBar: true,
6          timer:7000,
7          didOpen : () => {
8              Swal.showLoading()
9          },
10         willClose: () => {
11             this.router.navigate(["/ResultsPresentation"],
12 {queryParams: {
13         WMD : res["WMD"],
14         Level: res["Level"],
15         Accuracy: res["Accuracy"],
16         Recomendation: res["Recomendation"],
17         TextColor: res["TextColor"],
18         imageSrc : this.imageSrc,
19         patient_id : this.datos.id,
20         eyeside : this.selectedEye
21     }}})
22     }
23 })
24 }, (error:any) => {
25     Swal.fire({
26         title : "Error",
27         icon : "error",
28         text : "Error al realizar la predicci&oslash;n"
29     })
30 })
```

Cuando el usuario sube una imagen y solicita un análisis, el sistema inicia el proceso de predicción mostrando una alerta visual que indica que se está trabajando en los resultados. Esta alerta incluye una barra de progreso y un mensaje de "Realizando predicción" que mantiene al usuario informado.

3.4.5 Creación de la base de datos

En esta fase se diseñó y configuró la base de datos del sistema, donde se guardan tanto los datos de los pacientes como los de los usuarios (médicos/oftalmólogos) de la aplicación, incluyendo las credenciales necesarias para su acceso autorizado. Además, se registran los datos relacionados con los reportes generados a partir del análisis de las imágenes.

Fragmento del script para la creación de la base de datos:

```
-- DROP TABLE IF EXISTS public.datos_generales;

CREATE TABLE IF NOT EXISTS public.datos_generales
(
    id integer NOT NULL GENERATED ALWAYS AS IDENTITY ( INCREMENT 1
START 1 MINVALUE 1 MAXVALUE 2147483647 CACHE 1 ),
    name character varying(100) COLLATE pg_catalog."default" NOT
NULL,
    flastname character varying(50) COLLATE pg_catalog."default"
NOT NULL,
    slastname character varying(50) COLLATE pg_catalog."default"
NOT NULL,
    birthdate date NOT NULL,
    state character varying(100) COLLATE pg_catalog."default" NOT
NULL,
    city character varying(100) COLLATE pg_catalog."default" NOT
NULL,
    phone bigint NOT NULL,
    gender character(1) COLLATE pg_catalog."default" NOT NULL,
    photo character varying COLLATE pg_catalog."default",
    CONSTRAINT datos_generales_pkey PRIMARY KEY (id)
)

TABLESPACE pg_default;

ALTER TABLE IF EXISTS public.datos_generales
    OWNER to postgres;
```

3.4.6 Consumo de la API de hugging face

El siguiente código descarga un modelo preentrenado de clasificación de imágenes y su procesador asociado desde Hugging Face, y luego los guarda localmente para uso posterior.

```
2 from transformers import AutoImageProcessor,  
3 AutoModelForImageClassification  
4  
5 # Cargar el modelo y procesador desde Hugging Face  
6 processor =  
7 AutoImageProcessor.from_pretrained("RobertoSonic/swinv2-tiny-  
8 patch4-window8-256-dmae-humeda-DAV72")  
9 model =  
10 AutoModelForImageClassification.from_pretrained("RobertoSonic/swinv  
11 2-tiny-patch4-window8-256-dmae-humeda-DAV72")  
12  
13 # Guardar el procesador y el modelo localmente  
14 processor.save_pretrained("./ModelWet")  
15 model.save_pretrained("./ModelWet")
```

3.5 Implementación

Después de finalizar el desarrollo de los distintos módulos que forman la aplicación, se llevó a cabo la integración completa de todos ellos para verificar que el sistema operara correctamente de manera conjunta. En esta parte se presenta el funcionamiento general de la aplicación.

3.5.1 Inicio de aplicación Web

Se diseñó una interfaz de usuario sencilla y minimalista, buscando proporcionar al usuario únicamente la información esencial para manejar la aplicación, junto con un conjunto reducido de botones y enlaces para prevenir posibles confusiones. En la Figura 3.17 se ilustra la pantalla de inicio de la aplicación.




Figura 3.17 Login WAMDS2

Para acceder a las funcionalidades del sistema, el medico familiar/oftalmólogo para ser registrado necesita contar con una dirección de correo valida y además llenar todos los cambios solicitados entre ellos su cedula profesional.

3.5.2 Interfaz - detección multiclase



Figura 3.18 Detección multiclase

Una vez el medico familiar/oftalmólogo esta registrado correctamente (convertido en usuario) e inicia sesión, tiene a su alcance las diversas opciones del sistema (listado de pacientes, ver historial, actualizar datos, registrar paciente), la principal de ellas siendo el análisis de imagen, para ello se selecciona uno de entre una lista de pacientes.

3.5.3 Interfaz – reporte del análisis



Datos del Paciente
Nombre: Maria Fernanda
Apellidos: Castillo Hernandez
Fecha de nacimiento: 1985-02-02
Enfermedad: Diabetes
Telefono: 2721898874
Genero: Mujer
Estado: Veracruz
Ciudad: Orizaba
Lado Ojo: Izquierdo

Resultado



Degeneracion Macular: Negativo
Nivel de impacto: No DMAE
Precisión: 78.62228155136108%
Predicción: No se encontraron señales alarmantes

Cancelar Guardar

Figura 3.19 Interfaz resultados detección

La pantalla de resultados muestra la imagen analizada, los resultados de la clasificación y da las opciones para guardar o descartar el reporte.

3.5.4 Interfaz – historial de análisis

Historial de análisis

Filtrar por: Fecha Filtrar Descargar PDF

ID	Imagen	Fecha	Paciente	Género	Nivel de afectación	Precisión del resultado	Acciones
37		2025-05-28	Lizeth Castro Diaz	M	avanzada humeda	95.0862%	 
35		2025-05-28	Maria Fernanda Castillo Hernandez	M	No DMAE	78.6222%	 

Figura 3.20 Interfaz historial de análisis

Los reportes guardados tienen la opción para su consulta en la vista de historial de análisis, a la cual se accede desde la vista de inicio de usuario. En el historial de reportes el usuario accede a la lista de reportes guardados, en la que aplica las opciones de filtrado, impresión y eliminación.

3.5.5 Interfaz – lista de pacientes

Lista de pacientes

Filtrar por:

Paciente

Agregar paciente

ID	Foto:	Paciente	Género	Acciones
64		Lizeth Castro Diaz	M	
13		Maria Fernanda Castillo Hernandez	M	

Figura 3.21 Interfaz Lista de pacientes

El usuario podrá visualizar el listado de pacientes registrados además de que también se le permitirá modificar sus datos por si existe algún error, eliminar a un paciente o si lo desea registrar a un nuevo paciente.

3.5.6 Interfaz – registrar usuario



Figura 3.22 Interfaz registro de usuario

En la interfaz de registrar usuario se registra a un nuevo médico o si lo desea el usuario también registrar a un nuevo paciente.

Capítulo 4. Resultados

Este capítulo expone los resultados obtenidos del sistema desarrollado en este proyecto. Se logró desarrollar una aplicación web accesible e intuitiva que permite al usuario final interactuar con el modelo previamente entrenado para clasificar imágenes del fondo de ojo. La combinación de esta aplicación con el modelo facilita el proceso de identificación de la degeneración macular en su variante húmeda a partir de dichas imágenes. A continuación, se describe el caso de estudio utilizado para evaluar el funcionamiento de la solución propuesta.

4.1 Caso de estudio

Se recibieron un total de 30 imágenes de fondo de ojo pertenecientes a diferentes pacientes anónimos. Las imágenes de fondo de ojo utilizadas para llevar a cabo las pruebas fueron proporcionadas gracias a la colaboración con el Instituto de Oftalmología Fundación Doctor Hernández Zurita I.B.P, la validación y revisión de dichas imágenes estuvo a cargo del Dr. Diego Alberto Flores Pineda, con cédula profesional número 14797921.




Figura 4.1 Imágenes de caso de uso

Cabe destacar que estas imágenes no estuvieron etiquetadas por lo que los pacientes del presente caso de estudio podrían presentar otras enfermedades oculares incluyendo DMAE.

El objetivo principal de este caso de estudio fue evaluar el rendimiento y la efectividad de la aplicación web desarrollada para clasificar imágenes de fondo de ojo, específicamente en la identificación de la degeneración macular húmeda. Se busca verificar que la aplicación web funcione correctamente al interactuar con el modelo entrenado y que sea capaz de realizar una clasificación precisa y confiable de las imágenes.

Premisas del caso de estudio:

- Se utilizaron 30 imágenes proporcionadas por el Instituto de Oftalmología Fundación Doctor Hernández Zurita I.B.P.
- Las imágenes fueron validadas y revisadas por un especialista (Dr. Diego Alberto Flores Pineda), lo que asegura que las imágenes están correctamente etiquetadas y son apropiadas para la evaluación.
- El modelo fue entrenado previamente con un conjunto de imágenes similares para clasificar la degeneración macular en su variante húmeda.

4.1.1 Evaluación y resultados

Previo a realizar pruebas con las imágenes proporcionadas para el presente caso de estudio se procedió a realizar nuevos entrenamientos bajo los mismos hiperparámetros descritos en el punto 3.3.2, cambiando solo el conjunto de entrenamiento y así mismo reduciendo las clases a No DMAE, DMAE Seca y DMAE Húmeda dado que el alcance del proyecto solo se centra en la detección de la variante húmeda pero manteniendo la clasificación multiclase, con el objetivo de mejorar la precisión del modelo y así obtener mejores resultados. Se obtuvo un nuevo modelo, mostrado en la Figura 4.2.



Figura 4.2 Tarjeta del modelo final.

Así mismo se generó la matriz de confusión del modelo entrenado para analizar a fondo los aciertos y errores del modelo, permitiendo entender cómo y dónde falla el sistema, lo cual es clave para mejorar modelos de inteligencia artificial, especialmente en campos sensibles como la medicina.




Figura 4.3 Matriz de confusión del modelo.

De igual manera también se generó la curva roc ya que es útil para conocer el desempeño del modelo tanto en general como específicamente en la detección de DMAE húmeda, permitiendo observar si el modelo confunde esta condición con clases no patológicas o con DMAE seca, y ajustar los umbrales según se desee priorizar sensibilidad o especificidad.




Figura 4.4 Curva roc del modelo

De igual manera se obtuvieron las métricas resultantes del nuevo modelo entrenado reflejándose de la siguiente manera en el conjunto de prueba:

Tabla 4.1 Métricas de evaluación por modelo final.

Accuracy	Set	Class	Precision	Sensitivity	F1-Score
0.8743	Test	No DMAE	0.7777	0.8888	0.8200
		DMAE Seca	0.9222	0.8600	0.8999
		DMAE Húmeda	0.9400	0.8888	0.9100

4.1.1.1 Paciente con DMAE Húmeda

Tomando de las 30 imágenes para determinar que un **paciente anónimo 1** tiene DMAE Húmeda se ingresa la imagen del fondo del ojo tal como se muestra en la figura 4.5:




Figura 4.5 Clasificación Paciente anónimo 1

Después de ejecutar la predicción se obtuvo el siguiente resultado:




Figura 4.6 Resultado de predicción con paciente anónimo 1

Se concluye que el paciente tiene **DMAE Húmeda** y el modelo entrenado e implementado para realizar la predicción obtuvo un **95.08%** de precisión. Cabe destacar que el porcentaje de precisión se divide entre las 3 clases y devuelve la predicción con el porcentaje mayor.

4.1.1.2 Paciente con DMAE Seca

Para determinar que el **paciente anónimo 2** tiene DMAE Seca se ingresa la imagen del fondo del ojo de la misma manera que el punto 4.2.1:




Figura 4.7 Clasificación paciente anónimo 2

Después de ejecutar la predicción se obtuvo el siguiente resultado:



Figura 4.8 Resultado de predicción con paciente anónimo 2

Se concluye que el paciente tiene **DMAE Seca** y el modelo entrenado e implementado para realizar la predicción obtuvo un **94.79%** de precisión.

4.1.1.3 Paciente sin DMAE

Para concluir, el **paciente anónimo 3** presenta una baja probabilidad de tener DMAE, tal como se muestra en los dos puntos previos, se ingresa la imagen del fondo del fondo del ojo a la aplicación web para realizar la predicción:




Figura 4.9 Clasificación paciente anónimo 3

Finalmente, se obtuvo el resultado de la predicción en la pantalla.




Figura 4.10 Resultado de predicción con paciente anónimo 3

Se determina que el paciente tiene **bajas probabilidades de tener DMAE** y el modelo entrenado e implementado para realizar la predicción obtuvo un **80.50%** de precisión.

4.1.1.4 Exportar Datos

El presente módulo web cuenta con la capacidad de listar y convertir los resultados obtenidos previamente para llevar un registro de los datos médicos. En esta subsección se muestran las diferentes formas de presentación disponibles:

Historial de análisis

Filtrar por: Fecha Fecha inicial: 16/07/2025 Fecha final: 16/07/2025 [Filtrar] [Descargar PDF]

ID	Imagen	Fecha	Paciente	Género	Nivel de afectación	Precisión del resultado	Acciones
41		2025-07-16	xxxxxx xxxxxx xxxxxx	H	DMAE Humeda	95.0862%	 
42		2025-07-16	xxxxxx xxxxxx xxxxxx	M	No DMAE	80.5007%	 
43		2025-07-16	xxxxxx xxxxxx xxxxxx	H	DMAE Seca	94.7914%	 

Figura 4.11 Presentación del historial de análisis

WAMDS2

EDUCACIÓN
Secretaría de Educación Pública

FUNDACIÓN
Doctor Hernández Zúñiga, I.B.P.
Asesoría y Servicio al Cliente

TECNOLOGÍAS
NACIONAL DE MÉXICO

Reporte

[Imprimir Reporte] [Guardar notas]

Reporte de Análisis de Imagen del Fondo de Ojo

Doctor:	Roberto Marquez Castro	Paciente:	xxxxxx xxxxxx xxxxxx
Edad:	64	Género:	Mujer
Ojo analizado:	Izquierdo	Resultado:	95.0862% de probabilidad de DMAE Humeda
Fecha de análisis:	2025-07-16		

Imagen analizada



Notas:

localhost:4205/Reporte/Eye?id=41 1/2

Figura 4.12 Presentación de reporte en formato PDF

Reporte de Análisis - Listado

ID	Patient ID	Nombre Completo	Lado ojo	Género	Phase	Accuracy	Fecha
41	66	xxxxxx xxxxxx xxxxxx	Izquierdo	H	DMAE Humeda	95.0862%	2025-07-16
42	67	xxxxxx xxxxxx xxxxxx	Derecho	M	No DMAE	80.5007%	2025-07-16
43	68	xxxxxx xxxxxx xxxxxx	Derecho	H	DMAE Seca	94.7914%	2025-07-16

Figura 4.13 Presentación del historial de análisis en PDF

4.1.1.5 Primera evaluación

Para finalizar el análisis del caso de estudio que se presenta en este capítulo se realizaron las pruebas con las 30 imágenes proporcionadas, y se obtuvieron los siguientes resultados, todos validados por el especialista en oftalmología:

Tabla 4.2 Resultados de primera iteración de pruebas.

4.1.1.6 Segunda evaluación

Imagen	Predicción	Exactitud	Etiqueta Real
IMG_01	DMAE HUMEDA	0.9993	Retinopatía diabética proliferativa
IMG_02	DMAE HUMEDA	0.9902	Edema macular diabetic
IMG_03	DMAE SECA	0.9780	Edema macular daibetico
IMG_04	DMAE SECA	0.9988	Edema macular diabetic
IMG_05	DMAE HUMEDA	0.9275	Retinopatía diabética proliferativa
IMG_06	DMAE SECA	0.9828	retinopatía diabética proliferativa
IMG_07	DMAE HUMEDA	0.9980	Atrofia peripapilar
IMG_08	DMAE SECA	0.9923	Edema macular diabetic
IMG_09	DMAE HUMEDA	0.9977	Retinopatía dibética proliferativa
IMG_10	DMAE SECA	0.9479	DMAE SECA
IMG_11	NO DMAE	0.6306	NO DMAE
IMG_12	DMAE SECA	0.7919	RETINOPATIA DIABETICA PROLIFERATIVA
IMG_13	DMAE HUMEDA	0.9961	TOXOPLASMOSIS OCULAR
IMG_14	NO DMAE	0.9173	NO DMAE
IMG_15	NO DMAE	0.9840	NO DMAE

Entre las validaciones del especialista se observó que algunas imágenes se encontraban otras enfermedades oculares, no obstante, se mantuvieron como parte de los resultados ya que dichas enfermedades poseen características similares con DMAE Húmeda, esto con el fin de poder escalar e incrementar el alcance del proyecto para detectar nuevas enfermedades oculares.

Tabla 4.3 Resultados de segunda iteración de pruebas.

Imagen	Predicción	Exactitud	Etiqueta Real
IMG_16	DMAE HUMEDA	0.9983	Edema macular diabético
IMG_17	DMAE HUMEDA	0.9995	Retinopatía diabética proliferativa
IMG_18	DMAE HUMEDA	0.9980	DMAE HUMEDA
IMG_19	DMAE HUMEDA	0.8022	NO DMAE
IMG_20	NO DMAE	0.9962	PB DMAE
IMG_21	NO DMAE	0.8050	NO DMAE
IMG_22	NO DMAE	0.9022	NO DMAE
IMG_23	NO DMAE	0.9860	NO DMAE
IMG_24	DMAE HUMEDA	0.9508	DMAE HUMEDA
IMG_25	DMAE HUMEDA	0.8898	Retinopatía diabética proliferativa
IMG_26	DMAE HUMEDA	0.9995	Retinopatía diabética proliferativa
IMG_27	DMAE HUMEDA	0.9985	DMAE HUMEDA
IMG_28	DMAE SECA	0.9753	Retinopatía diabética proliferativa
IMG_29	NO DMAE	0.7862	NO DMAE
IMG_30	DMAE SECA	0.9651	NO DMAE

Los resultados obtenidos evidencian una mejora significativa en el rendimiento del modelo de clasificación, alcanzando una exactitud máxima del 87.43%. Este nivel de precisión lo sitúa en un rango competitivo respecto a lo reportado en estudios previos, resaltando que, a diferencia de muchos trabajos enfocados únicamente en una clasificación binaria de la enfermedad, el modelo desarrollado en este proyecto es capaz de abordar una clasificación multiclase. Con base en los resultados presentados, se afirma que la aplicación construida representa una herramienta eficaz de apoyo diagnóstico.

Capítulo 5. Conclusiones y recomendaciones

En este capítulo se presentan las conclusiones y recomendaciones derivadas de los resultados obtenidos de la presente investigación. Se resumen los principales hallazgos del estudio y se proponen sugerencias para futuras investigaciones o mejoras en el campo de estudio.

5.1 Conclusiones

Durante el desarrollo de esta tesis se desarrolló una herramienta que cumple con el objetivo general del proyecto y con cada uno de los objetivos específicos. El propósito principal fue implementar técnicas de visión por computadora y el transformador de visión Swin V-2 para construir una aplicación capaz de clasificar imágenes del fondo de ojo, orientada a la detección de la degeneración macular relacionada con la edad (DMAE) en sus distintos niveles de avance, y más específico con la variante húmeda.

Para alcanzar dicha meta, se revisaron y analizaron diversas investigaciones previas que demuestran cómo la tecnología se aplica en el diagnóstico y clasificación de la DMAE. Asimismo, se seleccionaron las arquitecturas de visión artificial más adecuadas, así como las bibliotecas de preprocesamiento más eficientes para optimizar el entrenamiento del modelo.

De entre las opciones disponibles, se eligió Swin Transformer V2 (Swin V-2) como arquitectura base del modelo de clasificación, mientras que PyTorch fue la biblioteca empleada para su implementación. Keras se utilizó para realizar las técnicas de aumento de datos. Con estas herramientas, se llevaron a cabo múltiples ciclos de entrenamiento con el objetivo de mejorar progresivamente el desempeño del modelo en la clasificación de imágenes retinianas.

En la etapa de validación, utilizando bases de datos públicas, se logró una exactitud del 87.43%. con el modelo final entrenado, antes de considerar los aspectos específicos del caso de estudio. Posteriormente, se desarrolló una aplicación para el usuario final, implementada en Fast API para realizar las predicciones.

Una vez obtenido el caso de estudio, se identificaron características particulares no contempladas en los datos previos. Se realizaron ajustes al modelo para incorporar estas nuevas condiciones, logrando una mejora en la precisión. Este rendimiento se encuentra al nivel de los trabajos reportados en la literatura, con la ventaja añadida de que el modelo propuesto permite clasificación multiclase, en contraste con otros enfoques que solo abordan clasificaciones binarias.

Como resultado final, se consolidó una herramienta denominada WAMDS2 (Wet AMD Swin V-2), que ofrece asistencia en la detección temprana y multiclase de la degeneración macular asociada a la edad. Se concluye que esta solución tecnológica representa un recurso útil y accesible para facilitar diagnósticos oportunos, especialmente en contextos donde el acceso a especialistas en oftalmología es limitado. Además, WAMDS2 funciona como una segunda opinión para respaldar las decisiones de los profesionales del área médica.

5.2 Recomendaciones

5.2.1 Ajustes en el proceso de aumento de datos

Durante las fases de entrenamiento se evaluaron distintas configuraciones para el aumento de datos. Sin embargo, no todas contribuyeron a mejorar el rendimiento del modelo; en algunos casos, incluso introdujeron ruido en el conjunto de entrenamiento. Por ello, se sugiere ajustar el proceso de aumento de datos empleando una configuración más apropiada y alineada con lo expuesto.

5.2.2 Combinación con la DMAE seca

Dado que el alcance del proyecto abarco la variante húmeda y parte de la variante seca es necesario realizar una combinación de un modelo que se centre con los diferentes niveles de la variante seca ya que representa la mayoría de los casos presentados de DMAE. Por lo tanto, se sugiere se incorpore la clase "DMAE Seca" en sus 4 categorías.

Productos Académicos

En esta sección de presentan los productos académicos que se obtuvieron del presente proyecto de tesis.


6.1 Artículos de congreso

6.1.1 Primer artículo

Arquitectura de un módulo para la detección temprana de la Degeneración Macular Asociada con la Edad Variante húmeda utilizando Swin Transformer V2.



6.1.1.1 Publicación de artículo



6.2 Ponencias

6.2.1 Primera ponencia



6.3 Retribución social

6.3.1 Primera retribución social



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 1: Asesoría a jóvenes de licenciatura en su formación en TECNM – Campus Orizaba con el proyecto de residencias “ANÁLISIS COMPARATIVO DE TÉCNICAS DE VISION POR COMPUTADORA PARA LA SEGMENTACION DE DRUSAS ATRAVES DE IMÁGENES DE FONDO DE OJO”.

Descripción de la actividad: Tutoría sobre temas relacionados con la visión artificial por computadora.

Fecha de inicio: 10 de septiembre del 2024

Fecha de término: 10 de diciembre del 2024

Institución en la que se realizó la actividad: Tecnológico Nacional de México – Campus Orizaba

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: El joven aprendió los conceptos de los diferentes algoritmos de visión artificial y pudo finalizar satisfactoriamente su proyecto de residencias.

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.3.2 Segunda retribución social



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 2: Participar en foros de intercambio de experiencias sociales/institucionales mediante la participación en la charla de café titulada "LA INTELIGENCIA ARTIFICIAL APLICADA EN EL CUIDADO DE LA SALUD VISUAL".

Descripción de la actividad: Se llevó a cabo una platica explicando el uso de visión artificial para el cuidado de la salud visual por los estudiantes de la MSC. Roberto Marquez Castro y Augusto Javier Reyes Delgado, Estudiante del DCI. Jorge Ernesto González Díaz y el Dr. José Luis Sánchez Cervantes

Fecha de inicio: 12 de abril del 2024

Fecha de término: 12 de abril del 2024

Institución en la que se realizó la actividad: Tecnológico Nacional de México – Campus Orizaba

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: La divulgación del uso de la inteligencia artificial para la salud visual tiene como impacto aumentar la conciencia sobre la salud visual e inspirar a estudiantes del área informática a desarrollar habilidades en inteligencia artificial.

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.3.3 Tercera retribución social



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 3: Participar en foros de intercambio de experiencias de proyectos apoyados por el COVEICYDET mediante la presentación del proyecto titulado "PREVENCIÓN Y DETECCIÓN TEMPRANA DE ENFERMEDADES CARDIOVASCULARES UTILIZANDO TÉCNICAS DE APRENDIZAJE AUTOMÁTICO, BIG DATA Y EL INTERNET DE LAS COSAS (IOT).

Descripción de la actividad: Se presento un stand destacando la investigación sobre la prevención y detección temprana de enfermedades cardiovasculares utilizando técnicas de aprendizaje automático.

Fecha de inicio: 18 de septiembre del 2024

Fecha de término: 18 de diciembre del 2024

Institución en la que se realizó la actividad: KANÁ, Museo de Ciencia y Tecnología de Veracruz – Xalapa, Veracruz

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: La participación en el evento subrayo el compromiso con la investigación científica y el desarrollo tecnológico, especialmente en áreas que buscan soluciones practicas para la mejora de la calidad de vida de las comunidades veracruzanas.

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.3.4 Cuarta retribución social



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 4: Divulgación en la Feria de Posgrado del Tecnológico Nacional de México – Campus Orizaba del trabajo de investigación titulado “ANÁLISIS DE CARACTERÍSTICAS PARA LA DETECCIÓN TEMPRANA DE DMAE VARIANTE SECA A PARTIR DEL ANÁLISIS DE IMÁGENES DEL FONDO DEL OJO UTILIZANDO TÉCNICAS DE VISIÓN ARTIFICIAL Y APRENDIZAJE PROFUNDO”.

Fecha de inicio: 14 de noviembre del 2024

Fecha de término: 15 de noviembre del 2024

Institución en la que se realizó la actividad: Tecnológico Nacional de México – Campus Orizaba

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: Los jóvenes fueron motivados a continuar sus estudios profesionales mediante los proyectos expuestos mediante el ingreso al programa de Maestría en Sistemas Computacionales que ofrece la institución.

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.3.5 Quinta retribución social



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 5: Impartición de clases a estudiantes de nivel licenciatura de la materia titulada "ANÁLISIS Y MODELADO DE SISTEMAS DE INFORMACIÓN".

Descripción de la actividad: Se impartió la materia de análisis y modelado de sistemas de información como apoyo a la formación de estudiantes de la carrera de ingeniería informática.

Fecha de inicio: 11 de septiembre del 2024

Fecha de término: 2 de diciembre del 2024

Institución en la que se realizó la actividad: Tecnológico Nacional de México – Campus Orizaba

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: Los estudiantes de informática entendieron los conceptos básicos del proceso de análisis y modelado de sistemas de información computacionales.

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.3.6 Sexta retribución social



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 6: Elaboración de notas y artículos de difusión mediante la presentación y publicación del artículo "Arquitectura de un módulo para la detección temprana de la degeneración macular asociada con la edad variante húmeda utilizando Swin Transformer V2".

Descripción de la actividad: Se presentó el artículo antes mencionado, en el 3er Congreso Internacional de Tecnologías y Ciencias Aplicadas (CITCA) celebrado en Tecnológico Nacional de México-Campus CENIDET en Cuernavaca, Morelos

Fecha de inicio: 19 de noviembre del 2024

Fecha de término: 22 de noviembre del 2024

Institución en la que se realizó la actividad: Tecnológico Nacional de México-Campus CENIDET

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: Se dio a conocer la propuesta de la arquitectura del módulo del trabajo de investigación de la maestría y se obtuvo la retroalimentación para mejorar la investigación como fomentar a los presentes a participar en este tipo de actividades de investigación. ISSN 2992-8338.

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.3.7 Séptima retribución social



Educación
Secretaría de Educación Pública



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 7: Crear materiales multimedia y comunicación social con resultados de investigación. Mediante la elaboración del poster "ANÁLISIS DE CARACTERÍSTICAS PARA LA DETECCIÓN TEMPRANA DE DMAE VARIANTE HUMEDA A PARTIR DEL ANÁLISIS DE IMÁGENES DEL FONDO DEL OJO UTILIZANDO TÉCNICAS DE VISION ARTIFICIAL Y EL TRANSFORMADOR SWIN-V2".

Descripción de la actividad: Se realizó el póster para comunicar los resultados de la investigación realizada con la tesis de Maestría en Sistemas Computacionales.

Fecha de inicio: 27 de mayo del 2025

Fecha de término: 27 de mayo del 2025

Institución en la que se realizó la actividad: Tecnológico Nacional de México – Campus Orizaba

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: El póster realizado permite comunicar a un gran número de personas de forma breve y concisa los resultados de la investigación y a su vez generando interés en la audiencia.

Enlace póster:

https://orizabatecnmmx-my.sharepoint.com/:b/g/personal/m16011057_orizaba_tecn_mx/EVa69uQrGEJKv8P_MzKDWEQB64LzwvNjRIHIBWpvWj-Kxw?e=csdzhB

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.3.8 Octava retribución social



Educación
Secretaría de Educación Pública



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 8: Crear materiales multimedia y comunicación social con resultados de investigación. Mediante la elaboración del video "ANALISIS DE CARACTERISTICAS PARA LA DETECCION TEMPRANA DE DMAE VARIANTE HUMEDA A PARTIR DEL ANALISIS DE IMÁGENES DEL FONDO DEL OJO UTILIZANDO TECNICAS DE VISION ARTIFICIAL Y EL TRANSFORMADOR SWIN-V2".

Descripción de la actividad: Se realizó el video para comunicar los resultados de la investigación realizada con la tesis de Maestría en Sistemas Computacionales.

Fecha de inicio: 27 de mayo del 2025

Fecha de término: 27 de mayo del 2025

Institución en la que se realizó la actividad: Tecnológico Nacional de México – Campus Orizaba

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: Como medio audiovisual, proporciona al público en general el acceso al conocimiento generado con el desarrollo del proyecto de tesis de maestría. A través del video las personas tienen una alternativa de comunicación científica que les garantiza la reproducibilidad de la investigación realizada las veces que sea necesario para adquirir conocimiento o interesarse en la realización de proyectos de investigación a través de los estudios de posgrado.

Enlace video:

https://orizabatecnmmx-my.sharepoint.com/:v/g/personal/m16011057_orizaba_tecn_mx/EVjdj0RORNNHoe-drlTXf04BKx9P_twf28foGJOKfq1EDg?e=q7Si8s

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.3.9 Novena retribución social



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Constancia de actividades de retribución social

Actividad 9: Ponencia en el 1er Foro de la Agenda Estratégica de Salud del TecNM con el proyecto titulado “ANÁLISIS DE CARACTERÍSTICAS PARA LA DETECCIÓN TEMPRANA DE LA DMAE VARIANTE SECA Y HUMEDA A PARTIR DEL ANÁLISIS DE IMÁGENES DEL FONDO DEL OJO UTILIZANDO TÉCNICAS DE VISIÓN ARTIFICIAL Y APRENDIZAJE PROFUNDO”.

Descripción de la actividad: La ponencia se llevó a cabo de forma presencial y se abordó las distintas problemáticas de salud pública mediante herramientas tecnológicas como inteligencia artificial, aprendizaje profundo y sistemas inteligentes de apoyo clínico.

Fecha de inicio: 11 de abril del 2025

Fecha de término: 11 de abril del 2025

Institución en la que se realizó la actividad: Tecnológico Nacional de México – Campus Orizaba

Nombre del responsable de supervisar la actividad: José Luis Sánchez Cervantes

Cargo del responsable de supervisar la actividad: Director de tesis de maestría

Datos de contacto del responsable de la actividad: jose.sc@orizaba.tecnm.mx

Descripción del impacto social de la actividad: Con la ponencia se demuestra el compromiso con la generación de conocimiento y la aplicación de tecnologías emergentes al servicio del bienestar social, consolidando al proyecto como un referente dentro del ecosistema de salud e innovación del TecNM.

I.S.C. Roberto Marquez Castro
CVU: 1306207

Dr. José Luis Sánchez Cervantes



2025
Año de
La Mujer
Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



6.4 Poster y video





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLOGÍA
CENTRO DE INVESTIGACIÓN Y DESARROLLO



División de Estudios de
Posgrado e Investigación
Tecnológico Nacional de México Campus Orizaba



MAESTRIA EN SISTEMAS COMPUTACIONALES

ANÁLISIS DE CARACTERÍSTICAS PARA LA DETECCIÓN TEMPRANA DE LA DMAE VARIANTE HÚMEDA A PARTIR DEL ANÁLISIS DE IMÁGENES DEL FONDO DEL OJO UTILIZANDO TÉCNICAS DE VISIÓN ARTIFICIAL Y EL TRANSFORMADOR SWIN-V2.

Hola, mi nombre es Roberto Márquez Castro, Maestro en sistemas computacionales, y en este video presento los resultados de mi proyecto de tesis, el cual se titula: "ANÁLISIS DE CARACTERÍSTICAS PARA LA DETECCIÓN TEMPRANA DE LA DMAE VARIANTE HÚMEDA A PARTIR DEL ANÁLISIS DE IMÁGENES DEL FONDO DEL OJO UTILIZANDO TÉCNICAS DE VISIÓN ARTIFICIAL Y EL TRANSFORMADOR SWIN-V2."

Referencias bibliográficas

- [1] AWS, "¿Qué es la inteligencia artificial? - Explicación de la inteligencia artificial (IA) - AWS," [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/artificial-intelligence/>. [Accedido: 19-mar-2024].
- [2] Google Cloud, "¿Qué es el aprendizaje automático? | Google Cloud | Google Cloud," [En línea]. Disponible en: <https://cloud.google.com/learn/what-is-machine-learning?hl=es-419>. [Accedido: 20-mar-2024].
- [3] IBM, "¿Qué es el aprendizaje supervisado? | IBM," [En línea]. Disponible en: <https://www.ibm.com/mx-es/topics/supervised-learning>. [Accedido: 20-mar-2024].
- [4] Google Cloud, "¿Qué es la inteligencia artificial o IA? | Google Cloud | Google Cloud," [En línea]. Disponible en: <https://cloud.google.com/learn/what-is-artificial-intelligence?hl=es-419>. [Accedido: 20-mar-2024].
- [5] AWS, "¿Qué es el aprendizaje profundo? - Explicación del aprendizaje profundo - AWS," [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/deep-learning/#:~:text=cantidades%20de%20procesadores,-,%20BFQu%C3%A9%20es%20el%20aprendizaje%20profundo%20en%20AWS%3F,para%20que%20sean%20m%C3%A1s%20r%C3%A1pidas>. [Accedido: 20-mar-2024].
- [6] AWS, "¿Qué son los transformadores?: explicación de los transformadores en inteligencia artificial: AWS," [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/transformers-in-artificial-intelligence/>. [Accedido: 20-mar-2024].
- [7] AWS, "¿Qué es el procesamiento de lenguaje natural? - Explicación del procesamiento de lenguaje natural - AWS," [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/nlp/>. [Accedido: 20-mar-2024].
- [8] AWS, "¿Qué son los transformadores?: explicación de los transformadores en inteligencia artificial: AWS," [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/transformers-in-artificial-intelligence/>. [Accedido: 20-mar-2024].
- [9] AWS, "Visión artificial | Amazon Web Services," [En línea]. Disponible en: <https://aws.amazon.com/es/computer-vision/>. [Accedido: 20-mar-2024].
- [10] AWS, "¿Qué es el sobreajuste? - Explicación del sobreajuste en machine learning - AWS," [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/overfitting/>. [Accedido: 20-mar-2024].
- [11] AWS, "¿En qué consiste el aumento de datos?: Explicación sobre las técnicas de aumento de datos: AWS," [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/data-augmentation/>. [Accedido: 20-mar-2024].

- [12] "Enhanced Reader," [En línea]. [Accedido: 20-mar-2024].
- [13] "Al día en Salud - Escotoma," [En línea]. Disponible en: <https://aldiaensalud.com/home/articulos/escotoma/>. [Accedido: 20-mar-2024].
- [14] "Qué es la metamorfopsia y como monitorizarla en pacientes con patologías como la DMAE - IMO," [En línea]. Disponible en: <https://www.imo.es/que-es-la-metamorfopsia-y-como-monitorizarla-en-pacientes-con-patologias-como-la-dmae/>. [Accedido: 20-mar-2024].
- [15] "Hemorragias subretinales – Institut de la Màcula," [En línea]. Disponible en: <https://www.institutmacula.com/es/patologia/hemorragias-subretinales/>. [Accedido: 20-mar-2024].
- [16] "Proyecto MIRA," [En línea]. Disponible en: <https://www.redgdps.org/proyectomira/testrapido.php?idtipo=5>. [Accedido: 20-mar-2024].
- [17] National Eye Institute, "Tipos y causas del desprendimiento de la retina | National Eye Institute," [En línea]. Disponible en: <https://www.nei.nih.gov/espanol/aprenda-sobre-la-salud-ocular/enfermedades-y-afecciones-de-los-ojos/desprendimiento-de-la-retina/tipos-y-causas-del-desprendimiento-de-la-retina#:~:text=El%20desprendimiento%20de%20la%20retina%20exudativo%20o%20curre%20cuando%20se%20acumula,y%20hacer%20que%20se%20desprenda>. [Accedido: 20-mar-2024].
- [18] C. Torrón-Fernández-Blanco, E. Ferrer-Novella, O. Ruiz-Moreno, y F. M. Honrubia-López, "«Optical Coherence Tomography» en desgarro del epitelio pigmentario retiniano," *Arch Soc Esp Oftalmol*, vol. 82, núm. 4, pp. 245–249, 2007. [En línea]. Disponible en: https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S0365-66912007000400012&lng=es&nrm=iso&tlng=es. [Accedido: 20-mar-2024].
- [19] A. Bello y S. Miranda Sarabia, "Retina: Degeneración Macular relacionada con la Edad: Conceptos Actuales," *Revista de la Facultad de Medicina*, vol. 25, núm. 2, pp. 237–243, 2002. [En línea]. Disponible en: http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S0798-04692002000200013&lng=es&nrm=iso&tlng=es. [Accedido: 20-mar-2024].
- [20] D. Aliseda, L. Berástegui, y D. Aliseda Pérez De Madrid, "Retinopatía diabética," *An Sist Sanit Navar*, vol. 31, pp. 23–34, 2008. [En línea]. Disponible en: https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272008000600003&lng=es&nrm=iso&tlng=es. [Accedido: 20-mar-2024].
- [21] W. Wei, J. Southern, K. Zhu, Y. Li, M. F. Cordeiro, K. Veselkov, "Deep learning to detect macular atrophy in wet age-related macular degeneration using optical coherence tomography," *Sci Rep.*, vol. 13, 2023. <https://doi.org/10.1038/s41598-023-35414-y>.

- [22] İ. Kayadibi and G. E. Güraksın, "An Explainable Fully Dense Fusion Neural Network with Deep Support Vector Machine for Retinal Disease Determination," *Int. J. Comput. Intell. Syst.*, vol. 16, 2023. <https://doi.org/10.1007/s44196-023-00210-z>.
- [23] N. N. El-Den, A. Naglah, M. Elsharkawy, M. Ghazal, N. S. Alghamdi, H. Sandhu, H. Mahdi, A. El-Baz, "Scale-adaptive model for detection and grading of age-related macular degeneration from color retinal fundus images," *Sci Rep.*, vol. 13, 2023. <https://doi.org/10.1038/s41598-023-35197-2>.
- [24] P. Dutta, K. A. Sathi, M. A. Hossain, M. A. A. Dewan, "Conv-ViT: A Convolution and Vision Transformer-Based Hybrid Feature Extraction Method for Retinal Disease Detection," *J. Imaging*, vol. 9, 2023. <https://doi.org/10.3390/jimaging9070140>.
- [25] H. E., J. Ding, L. Yuan, "SAE-wAMD: A Self-Attention Enhanced Convolution Neural Network for Fine-Grained Classification of Wet Age-Related Macular Degeneration Using OCT Images," in *2022 Int. Conf. on Image Processing, Computer Vision and Machine Learning, ICICML 2022*, pp. 619–627. <https://doi.org/10.1109/ICICML57342.2022.10009714>.
- [26] İstanbul AREL Üniversitesi, IEEE Engineering in Medicine and Biology Society, "Scientific Meeting on Electrical-Electronics, Computer and Biomedical Engineering: 24-26 April 2019," İstanbul AREL University, Kemal Gözükara Campus, Prof. Dr. Aziz Sancar Conference Hall, 2019.
- [27] E. López-Varela, P. L. Vidal, N. O. Pascual, J. Novo, M. Ortega, "Fully-Automatic 3D Intuitive Visualization of Age-Related Macular Degeneration Fluid Accumulations in OCT Cubes," *J. Digit. Imaging*, vol. 35, pp. 1271–1282, 2022. <https://doi.org/10.1007/s10278-022-00643-6>.
- [28] W. Wang, X. Li, Z. Xu, W. Yu, J. Zhao, D. Ding, Y. Chen, "Learning Two-Stream CNN for Multi-Modal Age-Related Macular Degeneration Categorization," *IEEE J. Biomed. Health Inform.*, vol. 26, pp. 4111–4122, 2022. <https://doi.org/10.1109/JBHI.2022.3171523>.
- [29] M. M. Abdullahi, S. Chakraborty, P. Kaushik, B. S. Sami, "Detection of Dry and Wet Age-Related Macular Degeneration Using Deep Learning," 2022.
- [30] W. Feng, M. Duan, B. Wang, Y. Du, Y. Zhao, B. Wang, L. Zhao, Z. Ge, Y. Hu, "Automated segmentation of choroidal neovascularization on optical coherence tomography angiography images of neovascular age-related macular degeneration patients based on deep learning," *J. Big Data*, vol. 10, 2023. <https://doi.org/10.1186/s40537-023-00757-w>.
- [31] S. Roy, D. Sinwar, N. Dey, T. João P., M. R. S. Tavares, Eds., "Lecture Notes in Networks and Systems," vol. 680, 2022.

- [32] P. Corazza, J. Maddison, P. Bonetti, L. Guo, V. Luong, A. Garfinkel, S. Younis, M. F. Cordeiro, "Predicting wet age-related macular degeneration (AMD) using DARC (detecting apoptosing retinal cells) AI (artificial intelligence) technology," *Expert Rev. Mol. Diagn.*, vol. 21, pp. 109–118, 2021. <https://doi.org/10.1080/14737159.2020.1865806>.
- [33] A. Haq, F. A. Fariza, N. Ramadijanti, N. Sandhu, H. Mahdi, H. El-Baz, "Automatic Detection of Retinal Diseases in Optical Coherence Tomography Images using Convolutional Neural Network," in *Int. Electronics Symp.*, 2021, pp. 343–348. <https://doi.org/10.1109/IES53407.2021.9594003>.
- [34] M. Wu, Y. Lu, X. Hong, J. Zhang, B. Zheng, S. Zhu, N. Chen, Z. Zhu, W. Yang, "Classification of dry and wet macular degeneration based on the ConvNeXT model," *Front. Comput. Neurosci.*, vol. 16, 2022. <https://doi.org/10.3389/fncom.2022.1079155>.
- [35] J. Yim et al., "Predicting conversion to wet age-related macular degeneration using deep learning," *Nat. Med.*, vol. 26, pp. 892–899, 2020. <https://doi.org/10.1038/s41591-020-0867-7>.
- [36] "AngularJS," *AngularJS Documentation*, [Enlace]. Disponible en: <https://docs.angularjs.org/guide>. [Accedido: 8-jul-2025].
- [37] Python Software Foundation, "The python tutorial," *Python documentation*, 2023. Disponible en: <https://docs.python.org/3/tutorial/index.html>. [Accedido: 1-abr-2024].
- [38] AWS, "What Is Python?," *Amazon Web Services*, 2023. Disponible en: https://aws.amazon.com/what-is/python/?nc1=h_ls. [Accedido: 1-abr-2024].
- [39] MDN Web Docs, "JavaScript | MDN," [Enlace]. Disponible en: <https://developer.mozilla.org/en-US/docs/Web/JavaScript>. [Accedido: 5-abr-2024].
- [40] The PostgreSQL Global Development Group, "What is PostgreSQL?," *The PostgreSQL Global Development Group*, 2023. Disponible en: <https://www.postgresql.org/about/>. [Accedido: 6-abr-2024].
- [41] Microsoft, "Why did we build Visual Studio Code?," 2023. Disponible en: <https://code.visualstudio.com/docs/editor/whyvscode>. [Accedido: 7-abr-2024].
- [42] Keras, "About Keras," *Keras*, 2024. Disponible en: <https://keras.io/about/>. [Accedido: 22-abr-2024].
- [43] NVIDIA Corporation, "What is PyTorch?," *NVIDIA Corporation*, 2024. Disponible en: <https://www.nvidia.com/en-us/glossary/data-science/pytorch/>. [Accedido: 22-abr-2024].
- [44] Nimblework Inc., "What is Extreme Programming (XP)? - values, principles, and practices," *Nimblework*, Mar. 04, 2023. Disponible en: <https://www.nimblework.com/agile/extreme-programming-xp/>. [Accedido: 6-may-2024].

- [45] Z. Liu et al., "Swin Transformer: Hierarchical Vision Transformer using Shifted Windows," Mar. 2021. [En línea]. Disponible en: <http://arxiv.org/abs/2103.14030>.
- [46] Z. Liu et al., "Swin Transformer V2: Scaling up capacity and resolution," arXiv.org, Nov. 18, 2021. Disponible en: <https://arxiv.org/abs/2111.09883>.
- [47] Broad (Baidu Research Open-Access Dataset), "Refuge - Grand Challenge," Grand Challenge, [Enlace]. Disponible en: <https://refuge.grandchallenge.org/iChallenge-AMD>. [Accedido: 31-ago-2023].
- [48] Rakhshanda Mujib, "ARMD curated dataset 2023," Kaggle. [Enlace]. Disponible en: <https://www.kaggle.com/datasets/rakhshandamujib/armdcuration-dataset-2023>. [Accedido: 31-ago-2023].