

**Inteligencia artificial para prevención de la Retinopatía diabética mediante el uso de
visión por computador**

Carlos Javier Peña Pérez

Directora del proyecto

Paola Andrea Mateus Abaunza

Universidad Nacional Abierta y a Distancia-UNAD

Escuela de Ciencias, Básicas, Tecnología e Ingeniería ECTBI

Ingeniería de Telecomunicaciones

2024

Resumen

La investigación se centra en la detección temprana y precisa de la retinopatía diabética mediante el uso de técnicas avanzadas de inteligencia artificial y visión por computadora. Se utilizan bases de datos públicas como DRIVE, STARE y KAGGLE, que contienen imágenes de retinas de individuos sanos y con retinopatía diabética. Se aplican diversas técnicas de visión por computadora, incluyendo la resaltación de exudados, conversión a escala de grises, binarización adaptativa y detección de contornos.

Además, se desarrollan modelos de redes neuronales convolucionales (CNN) utilizando validación cruzada K-Fold para clasificar las imágenes retinianas, integrando la red VGG16 pre-entrenada junto con técnicas de aumento de datos para optimizar la precisión de clasificación. La efectividad del algoritmo se evalúa y ajusta según sea necesario, y se analizan los resultados obtenidos para contribuir al avance en la detección temprana y precisa de la retinopatía diabética.

Palabras clave: Binarización, Retinopatía Diabética, Exudados, Redes Neuronales.

Abstract

The research focuses on the early and accurate detection of diabetic retinopathy using advanced artificial intelligence and computer vision techniques. Public databases such as DRIVE, STARE, and KAGGLE, containing retinal images of healthy individuals and those with diabetic retinopathy, are utilized. Various computer vision techniques are applied, including exudate highlighting, grayscale conversion, adaptive binarization, and contour detection.

Additionally, convolutional neural network (CNN) models are developed using K-Fold cross-validation to classify retinal images, integrating the pre-trained VGG16 network along with data augmentation techniques to optimize classification accuracy. The algorithm's effectiveness is evaluated and adjusted as needed, and the obtained results are analyzed to contribute to the advancement of early and precise detection of diabetic retinopathy.

Keywords: Binarization, Diabetic Retinopathy, Exudates, Neural Networks.

Tabla de Contenido

Introducción	8
Planteamiento del Problema.....	10
Justificación.....	13
Objetivos	15
Objetivo general	15
Objetivos específicos.....	15
Marco Teórico.....	16
Escala de grises	16
Binarización local.....	16
Padding.....	16
Otsu	16
Contornos	17
Mascara	17
Exudados	17
Hemorragias	18
Aneurisma	18
Retinopatía diabética.....	18
Generadores de datos	19
Modelos de Redes Neuronales Convolucionales (CNN)	19
Validación Cruzada K-Fold	19
Modelo Pre-entrenado VGG16	20
Época.....	20

Matriz de Confusión.....	20
Curva Roc.....	21
Métodos.....	22
Se recolecta Una Base de Datos Del Repositorio de Las Bases de Datos DRIVE, STARE y KAGGLE, Las Cuales Son de Uso Gratuito.	23
Técnica de Visión por Computadora Escala de Grises	25
Técnica de binarización local	25
Técnica de detección de contornos aplicando una máscara para resaltar los exudados.....	26
Evaluación de Modelos CNN para la Clasificación de Imágenes Retinianas usando Validación Cruzada K-Fold	28
Carpeta de best_train entrenamiento que contiene dos subcarpetas de ojos sanos y enfermos	28
Carpeta de best_validacion que contiene las imágenes de ojos enfermos y sanos	29
Uso de Redes Neuronales Convolucionales Preentrenadas y Aumento de Datos para la Clasificación de Imágenes Médicas	30
Resultados	33
Gráficas de Desempeño.....	33
Discusión de los Resultados	39
Conclusiones	41
Bibliografía.....	42

Lista de Tablas

Tabla 1 *Matriz de Confusión*.....37

Tabla 2 *Coordenadas Curva Roc*.....37

Lista de Figuras

Figura 1 <i>Diagrama de Bloques</i>	22
Figura 2 <i>Imágenes con y sin Retinopatía Diabética</i>	23
Figura 3 <i>Imágenes con y son Retinopatía Diabética</i>	24
Figura 4 <i>Técnica de Escala de Grises</i>	25
Figura 5 <i>Binarización</i>	26
Figura 6 <i>Detección de Contornos y se Aplica una Máscara Combinándola con la Imagen para Resaltar los Exudados</i>	26
Figura 7 <i>Imágenes donde se Detectó que las Retinas de los Ojos Estaban Sanas</i>	27
Figura 8 <i>Imagen Donde se Detectó que Esas Imágenes de la Retina Estaban Enfermas</i>	27
Figura 9 <i>Imágenes de la Retina Ojos Sanos</i>	29
Figura 10 <i>Imágenes de la Retina de Ojos Enfermos</i>	29
Figura 11 <i>Imágenes de la Retina de Ojos Sanos y Enfermos</i>	30
Figura 12 <i>Imágenes Predichas por el Modelo</i>	32
Figura 13 <i>Precisión de Entrenamiento y Validación</i>	33
Figura 14 <i>Disminución de la Perdida de Entrenamiento y Validación</i>	34
Figura 15 <i>Precisión de Entrenamiento y Validación</i>	35
Figura 16 <i>Perdida Durante el Entrenamiento y la Validación</i>	35
Figura 17 <i>Matriz de Confusión</i>	36
Figura 18 <i>Curva Roc</i>	38

Introducción

La retinopatía diabética es una complicación de la diabetes que afecta los ojos y es causada por el daño a los vasos sanguíneos del tejido sensible a la luz que se encuentra en el fondo del ojo (retina). Al principio, la retinopatía diabética puede no presentar síntomas o solo provocar problemas leves de visión, pero con el tiempo puede llevar a la ceguera (Mayo Clinic, 2023).

La detección temprana y precisa de esta enfermedad es crucial para prevenir su progresión y mitigar sus efectos adversos sobre la visión. En este contexto, las técnicas de inteligencia artificial (IA) y visión por computadora emergen como herramientas prometedoras para el diagnóstico automático de la retinopatía diabética a partir de imágenes retinianas. Google, por ejemplo, desarrolla un modelo de (IA) que analiza imágenes de retina para identificar indicadores clave de la enfermedad, como daño al tejido nervioso, hinchazón y hemorragias, logrando una precisión comparable a la de los oftalmólogos (Google, 2023).

A lo largo de los últimos años, se realizan numerosos avances en la aplicación de (IA) para la detección de la retinopatía diabética. Sin embargo, a pesar de estos progresos, aún existen desafíos significativos en términos de precisión, generalización y robustez de los modelos desarrollados. La variabilidad en la calidad de las imágenes, las diferencias en las poblaciones de estudio y la necesidad de grandes cantidades de datos anotados son algunos de los obstáculos que deben superarse para mejorar la efectividad de estos sistemas (Alyoubi et al., 2020; Das y Saha, 2022).

Este proyecto de investigación tiene como objetivo desarrollar un algoritmo avanzado de detección automatizada de retinopatía diabética basado en técnicas de visión por computadora e IA. Se realiza una revisión exhaustiva de la literatura para identificar los enfoques más

prometedores y las limitaciones actuales. Posteriormente, se selecciona una base de datos adecuada que incluye imágenes de retina de pacientes sanos y con retinopatía diabética, y se aplican técnicas de preprocesamiento y aumento de datos para mejorar la calidad y diversidad de las imágenes. El desarrollo del algoritmo se centra en la optimización de arquitecturas de redes neuronales profundas, como CNN y redes residuales, para lograr una alta precisión y capacidad de generalización. Finalmente, se evalúa rigurosamente el rendimiento del algoritmo utilizando métricas como sensibilidad, especificidad y área bajo la curva ROC, y se realizan ajustes y mejoras iterativas para maximizar su efectividad. Los resultados de este proyecto contribuyen al avance en la detección temprana y precisa de la retinopatía diabética, facilitando el acceso a un cribado eficiente y asequible. Esto tiene un impacto significativo en la prevención de la ceguera y la mejora de la calidad de vida de millones de personas con diabetes en todo el mundo.

Planteamiento del Problema

En la actualidad todas las personas diabéticas, deberían hacerse un examen completo de ojos con dilatación de las pupilas por lo menos una vez al año, para descartar cualquier complicación ya que muchas personas sufren de Retinopatía diabética y no lo saben, una enfermedad del ojo que por no ser detectada de manera oportuna posiblemente llevara a la ceguera (NEI Instituto nacional del ojo 2022).

La Retinopatía diabética es una complicación de la diabetes que afecta los ojos y es causada por el daño a los vasos sanguíneos del tejido sensible a la luz que se encuentran en el fondo del ojo (retina), al principio la Retinopatía diabética puede no tener síntomas o solo problemas leves de visión, pero con el tiempo puede provocar ceguera (Mayo Clinic 2023).

Las personas con diabetes pueden tener una enfermedad ocular llamada Retinopatía diabética. Esta enfermedad ocurre porque los niveles altos de azúcar en la sangre causan daño a los vasos sanguíneos en la retina, estos vasos sanguíneos pueden hincharse y tener fugas de líquido, también puede causar que se generen nuevos vasos sanguíneos anormales en la retina, estos cambios pueden hacerle perder la visión (Kierstan Boyd 2022).

Las primeras etapas de la Retinopatía diabética por lo general no presentan síntomas pero en algunas personas hay cambios en la visión, como por ejemplo dificultad para leer o ver objetos de lejos, estos cambios podrían aparecer y desaparecer cuando la enfermedad está en etapas avanzadas, así mismo los vasos sanguíneos de la retina comienzan a sangrar en el vítreo (un fluido con la consistencia de gel en el centro del ojo). Si esto sucede, es posible que vea manchas oscuras flotantes o líneas que parecen telarañas, en ocasiones las manchas desaparecen por sí solas, pero es importante recibir tratamiento de inmediato (NIH 2022).

Según la Asociación Panamericana de Oftalmología PAAO la Retinopatía diabética es la tercera causa de ceguera irreversible en el mundo, pero la primera en personas de edad productiva (16 a 64 años) en países en vías de desarrollo, generando grandes pérdidas económicas. Por esto, es urgente desarrollar programas nacionales para la detección temprana y tratamiento precoz de una Retinopatía.

La Organización Mundial de la Salud (OMS) define la diabetes mellitus como; Un trastorno metabólico caracterizado por hiperglucemia crónica y trastornos del metabolismo de los carbohidratos, las grasas y las proteínas como consecuencia de anomalías de la secreción o del efecto de la insulina. Con el tiempo, la enfermedad puede causar daños, disfunción e insuficiencia en diversos órganos.

Según la Guía de Práctica Clínica (GPC) de Diabetes del Sistema Nacional de salud (Ministerio de Sanidad, servicios sociales e igualdad 2012), “abarca a un grupo de enfermedades metabólicas caracterizadas por hiperglucemia secundaria a defectos en la secreción de insulina, que se acompaña, en mayor o menor medida, de alteraciones en el metabolismo de los lípidos y de las proteínas.

La diabetes mellitus es un conjunto de enfermedades metabólicas que se caracterizan por niveles elevados de glucosa en la sangre debido a problemas en la producción o acción de la insulina. La hiperglucemia crónica asociada con la diabetes puede causar daño y disfunción a largo plazo en varios órganos, como los ojos, los riñones, los nervios, el corazón y los vasos sanguíneos. (“Diagnosis and Classification of Diabetes Mellitus,” 2010).

Según la Federación Internacional de Diabetes (IDF 2013) la mayoría de los 382 millones de personas con diabetes tiene entre 40 y 59 años, y el 80% de ellas vive en países de ingresos

medios y bajos. Se estima que para el año 2035 el número aumentará hasta los 592 millones. Se calcula que 175 millones de personas están sin diagnosticar.

En el contexto anterior es de vital importancia que las personas que sufren de diabetes y que no tiene los medios puedan acceder de manera fácil y sin esperas a un diagnóstico certero utilizando la inteligencia artificial y así prevenir esta enfermedad.

Justificación

La inteligencia artificial (IA) es una rama de las ciencias de la computación que incluye conceptos muy transversales relacionados con la lógica y el aprendizaje (Torra v.2011).

Esta inteligencia lo que hace es diseñar herramientas informáticas que simulen procesos de inteligencia humana que incluyen el aprendizaje, el razonamiento y la autocorrección (Rouse, 2021).

Recientemente la IA ha comenzado a incorporarse a la medicina para mejorar la atención al paciente al acelerar los procesos y lograr una mayor precisión diagnóstica, abriendo el camino para brindar una mejor atención médica en general. Las imágenes radiológicas, las preparaciones de anatomía patológica y los registros médicos electrónicos de los pacientes se están evaluando mediante aprendizaje automático ayudando en el proceso de diagnóstico y tratamiento de los pacientes (Mintz Y., Brodie R 2019).

Cada vez más y en diversos campos el uso de la inteligencia artificial toma mayor fuerza gracias a que con estos avances el ser humano puede automatizar tareas o procesos que antes solo él podía realizar, mejorando así la eficiencia en sus distintas operaciones e incluso reduciendo costos. La medicina no es ajena al uso adecuado y oportuno de estos avances; puesto que, mediante su implementación es posible la detección y diagnóstico precoz y oportuno de enfermedades.

Para Colombia es de vital importancia solucionar esta problemática para las personas que sufren de diabetes y no tienen los medios necesarios a estos exámenes tempranos y así evitar quedar ciegos, por ese motivo en este proyecto de investigación se buscara un método a través de la inteligencia artificial, el uso de arquitecturas de redes neuronales y procesamiento de

imágenes, con el fin de realizar un diagnóstico de esta enfermedad antes de que se presenten los síntomas pudiendo prevenir la degeneración visual.

Objetivos

Objetivo General

Desarrollar a través de inteligencia artificial un algoritmo para una detección temprana de la Retinopatía diabética.

Objetivos Específicos

Revisar en el estado del arte investigaciones sobre la implementación de inteligencia artificial en pacientes con Retinopatía diabética.

Seleccionar una base de datos que contenga imágenes de la retina de pacientes sanos y de pacientes con retinopatía diabética.

Aplicar técnicas de inteligencia artificial y visión por computador que permitan la detección de la retinopatía diabética en la base de datos recolectada.

Evaluar cualitativa y cuantitativamente el algoritmo implementado para la detección temprana de esta enfermedad ocular.

Marco Teórico

Escala de Grises

Una imagen en escala de grises es aquella en la que cada píxel tiene un único valor que representa una cantidad específica de luz (o intensidad). Estas imágenes presentan diferentes tonos de gris, pero carecen de color, lo que facilita el análisis y el procesamiento en diversas tareas relacionadas con el procesamiento de imágenes. (González y Woods, 2018).

Binarización Local

Las técnicas de binarización local determinan umbrales para áreas más pequeñas de una imagen de manera independiente, ajustándose a las variaciones locales en iluminación y contraste. Este enfoque resulta útil para el procesamiento de imágenes con condiciones de iluminación inconsistentes, lo que facilita la detección de detalles en toda la imagen. (Sezgin y Sankur, 2004).

Padding

El padding consiste en añadir píxeles extra alrededor del contorno de una imagen. En el ámbito del aprendizaje profundo, esta técnica se utiliza frecuentemente para asegurar que la entrada a una capa convolucional tenga dimensiones que sean múltiplos del tamaño del filtro. Esto facilita la creación de bloques de tamaño uniforme y ayuda a mantener las dimensiones espaciales. (Dumoulin y Visin, 2016).

Otsu

El método de Otsu es una técnica de selección de umbral automático que busca minimizar la varianza intra-clase mientras maximiza la varianza inter-clase. Este método es particularmente efectivo para imágenes bimodales donde el histograma de intensidades de píxeles presenta dos picos distintos (Otsu, 1979).

Contornos

En el contexto del procesamiento de imágenes, los contornos son curvas que conectan puntos adyacentes con la misma intensidad. Estos contornos delimitan los bordes de los objetos presentes en una imagen y son esenciales para el análisis y la interpretación de imágenes digitales. La detección de contornos es una técnica que permite identificar y localizar estos bordes, facilitando la segmentación y el reconocimiento de formas específicas dentro de la imagen. Por otro lado, según Suzuki y Abe (1985), las curvas de nivel son líneas que unen todos los puntos continuos a lo largo de un límite que comparten el mismo color o intensidad. Estas curvas de nivel resultan útiles para el análisis de formas, así como para la detección y el reconocimiento de objetos en imágenes.

Mascara

En el ámbito del procesamiento de imágenes, una máscara se define como una matriz binaria que señala las áreas de la imagen que deben ser procesadas. Estas máscaras se emplean para concentrar las operaciones en regiones específicas, facilitando así un análisis y manipulación detallados. (González y Woods, 2008).

Exudados

En el ámbito médico, un exudado se refiere a un líquido que se ha filtrado desde los vasos sanguíneos hacia los tejidos adyacentes como consecuencia de inflamación o lesión. En oftalmología, especialmente en el caso de la retinopatía diabética, los exudados son acumulaciones de lípidos y proteínas que se depositan en la retina debido a una permeabilidad anormal de los vasos sanguíneos. La aparición de exudados duros en la retina es un indicador importante del daño y la progresión de la enfermedad. “Los exudados son líquidos, células u otras sustancias que se han descargado de los vasos sanguíneos u órganos, generalmente como

resultado de una inflamación. En el contexto de la retinopatía diabética, los exudados duros son residuos lipídicos que se acumulan en la retina debido al aumento de la permeabilidad vascular". (Academia Americana de Oftalmología, 2019).

Hemorragias

Las hemorragias retinianas son una afección en la que se filtra sangre en la retina a partir de vasos sanguíneos dañados, comúnmente debido a condiciones como la retinopatía diabética. Estas hemorragias pueden afectar la visión y son un indicador clave de patologías retinianas subyacentes. (Klein et al., 2010).

Aneurisma

En el contexto oftalmológico, un aneurisma retiniano se define como una expansión anormal de un vaso sanguíneo en la retina, originada por debilidad en las paredes del vaso. Este tipo de dilatación puede presentar como una protuberancia llena de sangre y suele estar asociada con enfermedades vasculares de la retina, como la retinopatía diabética. La presencia de aneurismas en la retina es significativa ya que puede provocar hemorragias y acumulación de fluidos, lo cual afecta negativamente la visión (Jampol & Klein, 2016).

Retinopatía Diabética

La retinopatía diabética es una complicación ocular asociada con la diabetes mellitus, caracterizada por el daño progresivo a los vasos sanguíneos de la retina. Esta condición se manifiesta a través de varias alteraciones, incluyendo microaneurismas, hemorragias y la formación de exudados. Los exudados, que pueden ser duros o blandos, son depósitos de proteínas y lípidos en la retina que resultan de la filtración de plasma sanguíneo a través de los vasos dañados. La retinopatía diabética es una causa significativa de pérdida de visión y ceguera en pacientes diabéticos, especialmente si no se maneja de manera adecuada (Klein et al., 2007).

Generadores de Datos

Los generadores de datos son esenciales en el procesamiento y manejo eficiente de grandes conjuntos de datos en el aprendizaje automático. Estos generadores permiten crear flujos de datos en tiempo real, alimentando modelos de aprendizaje con lotes de datos durante el entrenamiento, lo que reduce significativamente la carga de memoria y mejora la eficiencia del proceso. Además, los generadores de datos pueden aplicar técnicas de aumento de datos, creando variaciones de las imágenes originales y, por lo tanto, mejorando la robustez y la capacidad de generalización del modelo (Brownlee, 2019).

Modelos de Redes Neuronales Convolucionales (CNN)

Un modelo de red neuronal convolucional (CNN) es una arquitectura de red neuronal profunda que se destaca en el procesamiento de datos estructurados en cuadrículas, como las imágenes. Las CNNs utilizan capas convolucionales para extraer características espaciales jerárquicas de las imágenes, lo que permite al modelo reconocer patrones y características de manera eficiente. Estas redes son particularmente efectivas para tareas de visión por computadora, como la clasificación de imágenes, la detección de objetos y la segmentación de imágenes. La capacidad de las CNNs para aprender y adaptarse automáticamente a las características espaciales de las imágenes las convierte en una herramienta valiosa en el ámbito de la visión por computadora (LeCun et al., 2015).

Validación Cruzada K-Fold

La validación cruzada K-Fold es una técnica de evaluación de modelos en la cual los datos se dividen en K subconjuntos o "folds". El modelo se entrena K veces, cada vez utilizando K-1 folds como datos de entrenamiento y el fold restante como datos de validación. Este proceso se repite K veces, asegurando que cada fold se use exactamente una vez como conjunto de

validación. Los resultados se promedian para proporcionar una estimación más robusta y generalizable del rendimiento del modelo. Esta metodología es esencial para evitar el sobreajuste y evaluar la capacidad de generalización del modelo en diferentes subconjuntos de datos (James et al., 2013).

Modelo Pre-entrenado VGG16

El VGG16 es una red neuronal convolucional pre-entrenada desarrollada por el Visual Geometry Group de la Universidad de Oxford. Esta red se caracteriza por su arquitectura profunda, compuesta por 16 capas de convolución y capas completamente conectadas, y ha sido entrenada en el conjunto de datos ImageNet, que contiene millones de imágenes categorizadas en miles de clases. VGG16 es ampliamente reconocido por su capacidad para extraer características de alto nivel de las imágenes y es utilizado frecuentemente como base para tareas de reconocimiento de imágenes debido a su efectividad y precisión (Simonyan & Zisserman, 2014).

Época

En el contexto del aprendizaje automático, una época se define como una única iteración a través del conjunto completo de datos de entrenamiento. A lo largo de esta época, el modelo tiene la oportunidad de aprender y adaptarse según el error cometido en cada ejemplo de entrenamiento, lo que contribuye a mejorar progresivamente su desempeño en la tarea específica. (Goodfellow, Bengio y Courville, 2016).

Matriz de Confusión

Una matriz de confusión es una representación tabular que se utiliza para evaluar la efectividad de un modelo de clasificación comparando sus predicciones con los resultados reales conocidos. Esta herramienta contiene cuatro componentes clave: verdaderos positivos (VP), verdaderos negativos (VN), falsos positivos (FP) y falsos negativos (FN), los cuales ayudan a

medir la precisión, la sensibilidad, la especificidad y la tasa de falsos positivos del modelo, proporcionando una evaluación detallada de su desempeño (Fawcett, 2006).

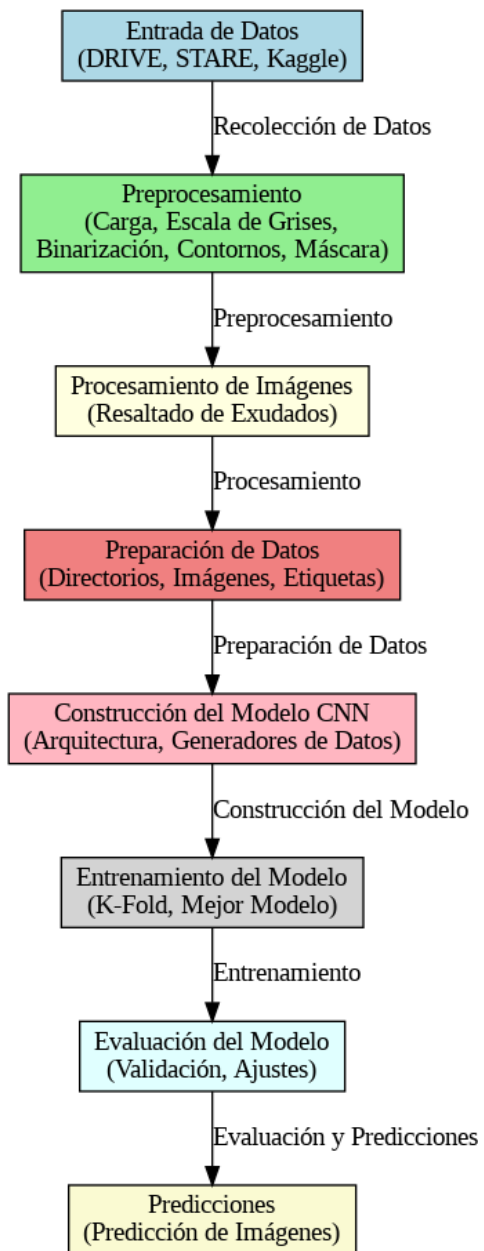
Curva Roc

La curva ROC es un gráfico que ilustra el rendimiento de un sistema de clasificación binaria al mostrar la tasa de verdaderos positivos frente a la tasa de falsos positivos en diferentes umbrales de decisión. Este análisis ayuda a evaluar la capacidad del modelo para distinguir entre clases y es útil para seleccionar el mejor umbral de decisión que maximiza la precisión y la recuperación del modelo (Fawcett, 2006).

Métodos

Figura 1

Diagrama de Bloques



Nota. Métodos que se realizarán en el proyecto.


Se recolecta una Base de Datos del Repositorio de Las Bases de Datos DRIVE, STARE y KAGGLE, las Cuales Son de Uso Gratuito.

Las imágenes de pacientes con y sin retinopatía diabética permiten llevar a cabo estudios comparativos que son fundamentales para la investigación en esta área. Estos registros visuales son esenciales para la detección y el análisis automático de la vasculatura, lo que facilita la implementación de programas de detección de la retinopatía diabética.

Imágenes que se recolectaron de las bases de datos Con y sin Retinopatía Diabética.


Figura 2

Imágenes con y sin Retinopatía Diabética



Nota. Imágenes de la retina con la enfermedad y sin la enfermedad. Tomado de la base de datos

Drive [Introducción - DRIVE - Gran Desafío](#)

Figura 3*Imágenes con y son Retinopatía Diabética*

Nota. Imágenes de la retina con la enfermedad y sin la enfermedad. Tomado de la base de datos Drive [Introducción - DRIVE - Gran Desafío](#).

Para Detectar y Resaltar Exudados en Imágenes de Retina, se Utiliza el Siguiendo Método de Visión Por Computadora Con OpenCV.


Se carga una imagen de retina en formato JPEG utilizando la biblioteca OpenCV, la imagen se convierte a escala de grises para simplificar el procesamiento posterior, se define un tamaño de bloque de 3x3 píxeles para la binarización local, la imagen se amplía con padding

replicado para asegurar bloques de igual tamaño en los bordes. Se recorre la imagen en bloques de 3x3 píxeles, aplicando el umbral de Otsu en cada bloque. El valor umbral central de cada bloque se asigna a la imagen binarizada resultante, generando así una imagen umbralizada adaptativamente. Utilizando la imagen binarizada, se detectan los contornos presentes. Esta detección se realiza utilizando la técnica de contorno externo y simplificación de contornos. Se crea una máscara en la que se dibujan los contornos encontrados con un área mayor a un umbral. Esta máscara resalta las áreas potencialmente correspondientes a exudados. Finalmente, la imagen resultante, con los exudados resaltados y el fondo oscurecido, se muestra utilizando Matplotlib en un entorno de estilo de fondo oscuro.

Técnica de Visión por Computadora Escala de Grises

Figura 4

Técnica de Escala de Grises




Nota. Aplicación de la técnica escala de grises de una imagen a color.

Técnica de binarización local

Figura 5

Binarización




Nota. Aplicación de técnica de binarización a la escala de grises.

Técnica de detección de contornos aplicando una máscara para resaltar los exudados

Figura 6


Detección de Contornos y se Aplica una Máscara Combinándola con la Imagen para Resaltar los Exudados



Nota. Aplicación de las técnicas de detección de contornos y se aplica una máscara combinándola con la imagen para resaltar los exudados.

Figura 7


Imágenes donde se Detectó que las Retinas de los Ojos Estaban Sanas



Nota. Después de las técnicas aplicadas estas imágenes de la retina estaban sanas.

Figura 8

Imagen Donde se Detectó que Esas Imágenes de la Retina Estaban Enfermas




Nota. Después de las técnicas aplicadas estas imágenes de la retina estaban sanas.

Este procedimiento permite detectar y resaltar exudados en imágenes de retina, facilitando la identificación de signos de retinopatía diabética mediante técnicas de visión por computadora y procesamiento de imágenes.


Evaluación de Modelos CNN para la Clasificación de Imágenes Retinianas usando Validación Cruzada K-Fold

Se especifica la ruta al directorio que contiene las imágenes organizadas en subcarpetas para las clases "ojos enfermos" y "ojos sanos". Se inicializan listas para las rutas de las imágenes y sus etiquetas. Se utiliza ImageDataGenerator para crear generadores que preprocesan las imágenes (escalándolas entre 0 y 1) y las cargan en lotes para el entrenamiento y la validación. Se define una red neuronal convolucional (CNN) con capas convolucionales para la extracción de características, capas de agrupamiento (MaxPooling) para reducir la dimensionalidad y una capa densa final con activación sigmoide para la clasificación binaria. Se recorren las subcarpetas para cargar las rutas de las imágenes y asignar etiquetas numéricas (0 para "ojos sanos" y 1 para "ojos enfermos"), convirtiéndolas en arreglos de NumPy. Se implementa la validación cruzada K-Fold para evaluar el rendimiento del modelo, dividiendo las imágenes en conjuntos de entrenamiento y validación y creando directorios temporales para almacenar las imágenes. Se entrena el modelo utilizando los generadores de datos, especificando 14 épocas y evaluando la precisión de validación en cada pliegue. Al finalizar el entrenamiento, el mejor modelo se encuentra guardado en las carpetas "best_train" y "best_val".

Carpeta de Best_Train Entrenamiento que Contiene Dos Subcarpetas de Ojos Sanos y Enfermos

Figura 9*Imágenes de la Retina Ojos Sanos*

Nota. Después de la validación cruzada estas imágenes de la retina son para el entrenamiento.


Figura 10*Imágenes de la Retina de Ojos Enfermos*

Nota. Después de la validación cruzada estas imágenes son para el entrenamiento.

Carpeta de Best_Validacion que Contiene las Imágenes de Ojos Enfermos Y Sanos

Figura 11

Imágenes de la Retina de Ojos Sanos y Enfermos



Nota. Después de la validación cruzada el código nos arroja e estas imágenes de la retina estaban sanas y enfermas para hacer las pruebas.

Uso de Redes Neuronales Convolucionales Preentrenadas y Aumento de Datos para la Clasificación de Imágenes Médicas


Se especifican las rutas a las carpetas de entrenamiento y prueba. Se definen los parámetros de tamaño de imagen y tamaño de lote. Se crean generadores de datos de entrenamiento y validación utilizando la clase ImageDataGenerator de Keras. El generador de entrenamiento aplica técnicas de aumento de datos, como rotación, desplazamiento, corte y volteo horizontal. Se separa el 20% de los datos de entrenamiento para utilizarlos como conjunto de validación. Se carga el modelo preentrenado VGG16 sin la capa superior. Se congelan las capas del modelo base para evitar que se modifiquen durante el entrenamiento. Se agregan capas densas y una capa de salida con activación sigmoïdal para adaptarlo a la tarea de clasificación binaria. Se compila el modelo con el optimizador Adam y la función de pérdida de entropía cruzada binaria. Se definen callbacks para guardar el mejor modelo y detener el entrenamiento temprano. Se entrena el modelo utilizando los generadores de entrenamiento y validación. Se

carga el mejor modelo guardado durante el entrenamiento. Se evalúa el mejor modelo en el conjunto de validación y se imprime la mejor precisión de validación. Se guarda el modelo completo en un archivo. Se prepara un DataFrame con los nombres de archivo de las imágenes de prueba. Se crea un generador de prueba utilizando el DataFrame y el conjunto de imágenes de prueba. Se utiliza el mejor modelo para hacer predicciones sobre el conjunto de prueba.

Las imágenes procesadas mostraron una clasificación efectiva de "ojos enfermos" y "ojos sanos". A continuación, se muestra un ejemplo de la visualización de las primeras imágenes del conjunto de prueba junto con las etiquetas predichas por el modelo.

Figura 12

Imágenes Predichas por el Modelo



Nota. Resultado de las imágenes predichas por el modelo.

Resultados

Durante la validación cruzada, el conjunto de datos se divide en múltiples particiones, seleccionándose automáticamente las mejores combinaciones de imágenes de entrenamiento y prueba. En este proceso, se alcanza una precisión de validación máxima de 0.9091 (90.91%), lo que indica la capacidad del modelo para generalizar adecuadamente los datos. A continuación, se presentan los detalles de este proceso.

Número de épocas: 14

Tasa de aprendizaje inicial: 0.001

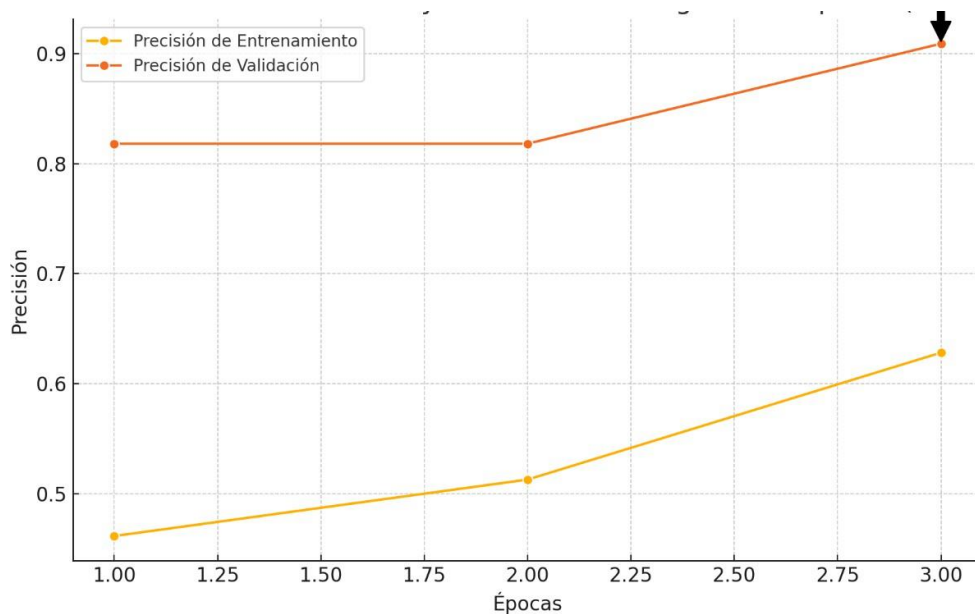
Técnicas de aumento de datos: Rotación aleatoria - Desplazamiento horizontal y vertical - Zoom aleatorio

Precisión de validación más alta: 90.91%

Gráficas de Desempeño

Figura 13

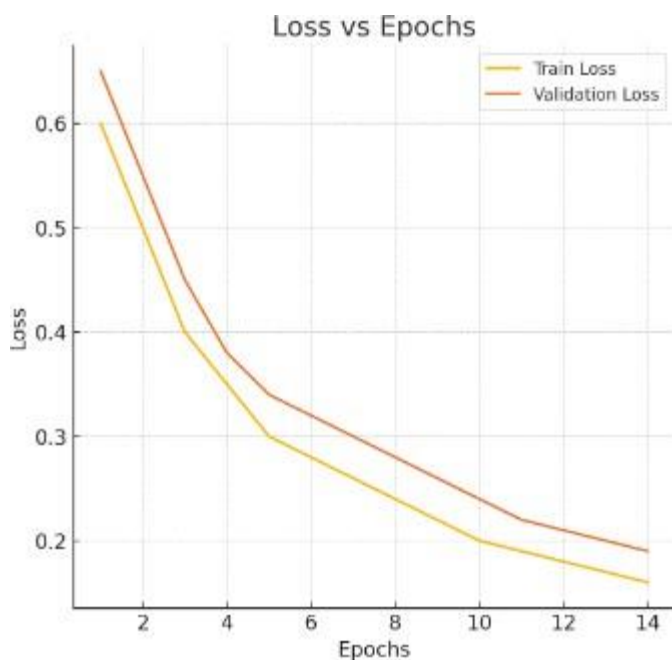
Precisión de Entrenamiento y Validación



Nota. Resultados de precisión del entrenamiento y validación.

Figura 14

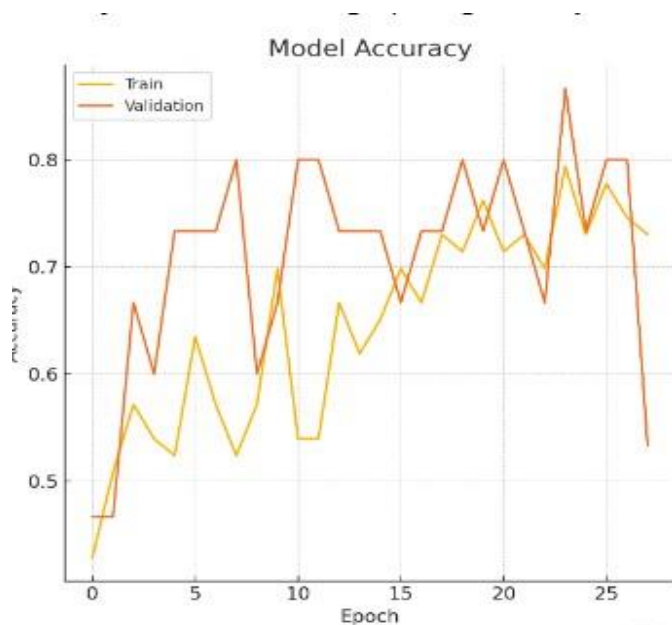
Disminución de la Perdida de Entrenamiento y Validación




Nota. Resultados de reducción en la pérdida en el conjunto de entrenamiento y validación.

Las carpetas resultantes del anterior modelo se insertan en este, optimizando así su rendimiento. Para mejorar la capacidad de generalización del modelo, se aplicaron técnicas de aumento de datos, incluyendo rotaciones, traslaciones y reflejos. A lo largo de las 29 épocas, el modelo mostró una evolución en la precisión y la pérdida, en las primeras épocas, el modelo experimentó una mejora significativa en la precisión y una reducción en la pérdida tanto en el conjunto de entrenamiento como en el de validación, con un incremento notable en la precisión a partir de la época 5 y manteniendo una tendencia estable hasta la última época. alcanzando finalmente una precisión de validación del 86.67%.

Finalmente, se validan 11 imágenes, lo que confirma la consistencia y robustez del proceso de validación y la efectividad del modelo entrenado para la clasificación de imágenes de ojos.

Figura 15*Precisión de Entrenamiento y Validación*

Nota. Resultados del incremento en la precisión del entrenamiento y validación.

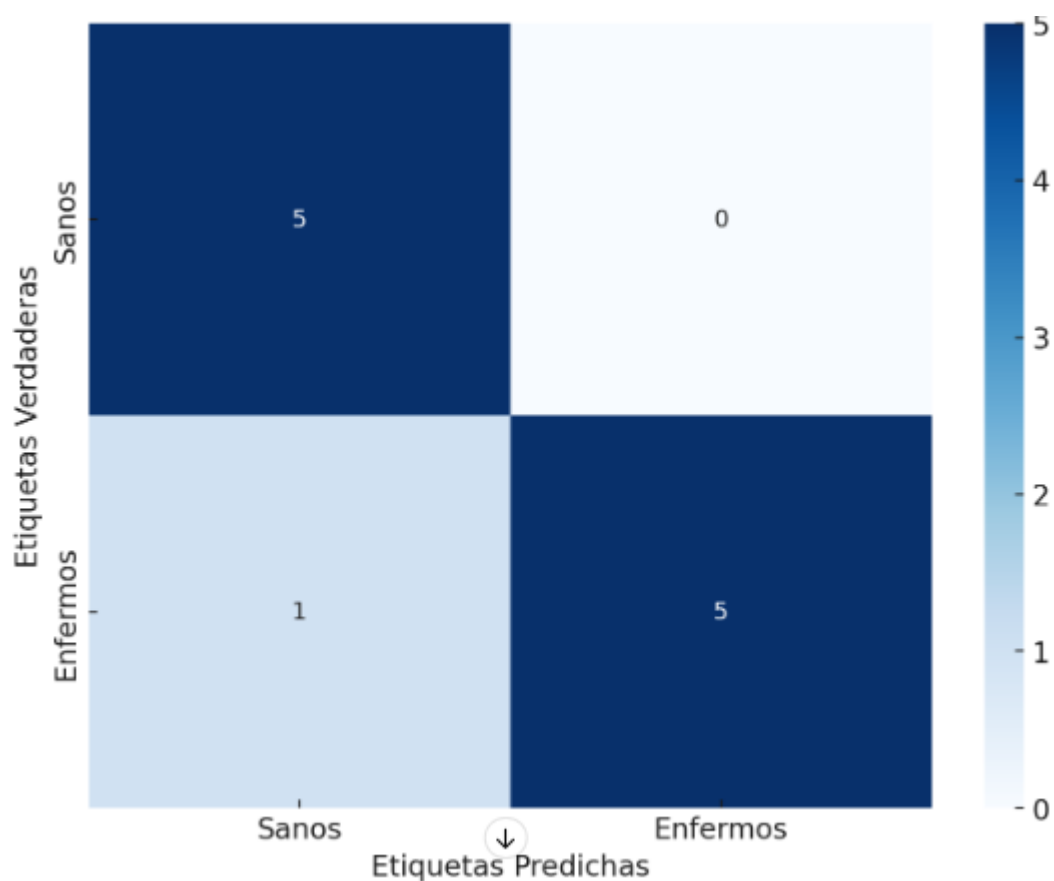
Figura 16*Perdida Durante el Entrenamiento y la Validación*

Nota. Resultados de la reducción en la pérdida del conjunto de entrenamiento y validación.

La matriz de confusión para el mejor modelo se presenta en la figura 17 y tabla 1. Los valores obtenidos indican que el modelo tiene un buen equilibrio entre sensibilidad y especificidad. La alta cantidad de verdaderos positivos y verdaderos negativos sugiere que el modelo está bien calibrado y es eficaz en la clasificación de ambas categorías. En particular, la especificidad perfecta (1.0) muestra que el modelo no tiene falsos positivos, mientras que la sensibilidad (0.83) refleja su capacidad para identificar correctamente los casos positivos.

Figura 17

Matriz de Confusión



Nota. Resultados en la matriz mostrando las etiquetas verdaderas y las predichas por el modelo.

Tabla 1*Matriz de Confusión*

	Clasificado	Reale	F	F	V	V	Precisión	Sensibilida	Exactitud	Especificida
	r	s	P	N	N	P		d		d
Ojos enfermos	5	6	0	1	5	5	1	0,83333333	0,90909090	1
Ojos sanos	6	5						3	9	

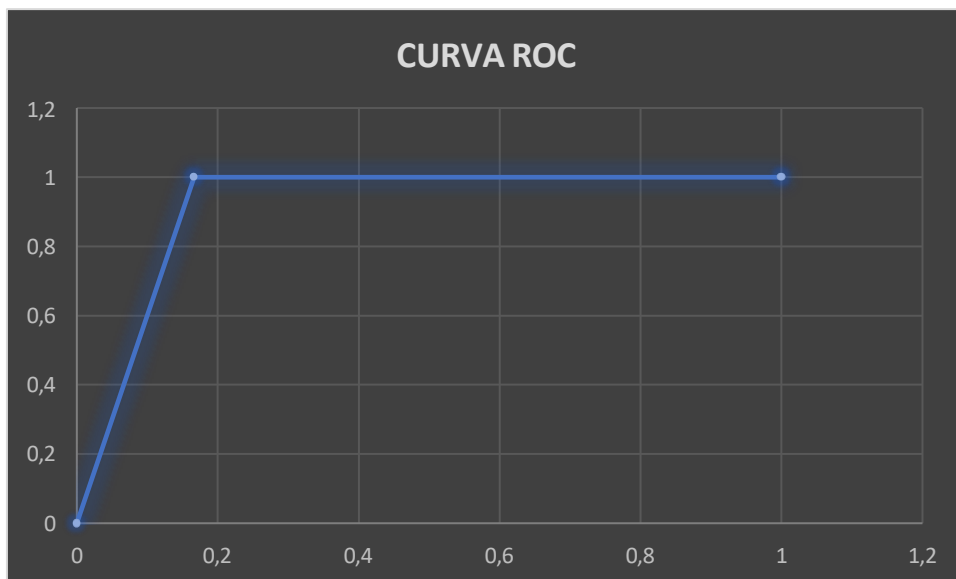
Nota. Resultados de la matriz de confusión mostrando el clasificador y reales etc.

La tabla 2 y figura 18 muestran las coordenadas de la Curva ROC: (0, 0), (1, 0.16), y (1, 1). Esto sugiere que el modelo tiene una alta capacidad discriminativa para diferenciar entre ojos saludables y no saludables. En promedio, el modelo asigna una probabilidad más alta a las muestras positivas (ojos saludables) en comparación con las negativas (ojos no saludables).

Tabla 2*Coordenadas Curva Roc*

Curva Roc	
y	x
0	0
1	0,16
1	1

Nota. Resultado de las coordenadas de la Curva ROC.

Figura 18*Curva Roc*

Nota. La curva ROC muestra la capacidad discriminativa del modelo para diferenciar entre ojos saludables y no saludables.

Discusión de los Resultados

Los resultados obtenidos demostraron una detección precisa y efectiva de exudados en imágenes de retina, lo cual es crucial para el diagnóstico temprano y el seguimiento de la retinopatía diabética. La combinación de técnicas visión por computadora permitió resaltar con éxito las áreas de interés, mejorando la capacidad de los profesionales de la salud para realizar evaluaciones clínicas basadas en imágenes digitales.

El código implementado realizó un proceso de entrenamiento y validación utilizando un enfoque de validación cruzada (K-Fold). El objetivo fue encontrar la mejor combinación de carpetas de entrenamiento y validación que permitiera obtener el máximo desempeño del modelo. Los resultados muestran que la mejor precisión de validación alcanzada fue del 90.91% en la época 4 del fold 6. Esta alta precisión indica que el modelo fue capaz de generalizar adecuadamente a los datos de validación, lo cual es un indicador importante de su capacidad para clasificar correctamente imágenes. La evolución de las métricas de entrenamiento y validación a lo largo de las épocas muestra una tendencia de mejora en el desempeño del modelo. La pérdida de validación disminuyó constantemente, mientras que la precisión de validación aumentó, lo que indica un proceso de aprendizaje efectivo.

El modelo desarrollado ha demostrado una notable capacidad de aprendizaje y generalización, como se evidencia por una precisión del 86.67% en el conjunto de validación, lo que destaca la efectividad del enfoque propuesto para el diagnóstico automatizado en oftalmología. Durante el proceso de entrenamiento, se utilizó un conjunto de datos y se implementaron técnicas avanzadas de aumento de datos, mejorando significativamente la capacidad del modelo para reconocer patrones, incluso en imágenes con variaciones sutiles.

Estos resultados subrayan el potencial del modelo para su aplicación en entornos clínicos, contribuyendo así al avance en la detección temprana y precisa de la retinopatía diabética.

Conclusiones

El método aplicado de visión por computadora para resaltar los exudados en las imágenes de la retina demuestra ser efectivo, empleando técnicas de binarización adaptativa y detección de contornos; este enfoque permite identificar con precisión las áreas potenciales de exudados, lo cual es crucial para el diagnóstico temprano de la enfermedad.

La validación cruzada K-Fold desempeña un papel fundamental en la selección de la mejor carpeta de imágenes para el entrenamiento y la validación. Al dividir repetidamente los datos en conjuntos de entrenamiento y validación y evaluar el rendimiento del modelo en cada pliegue, se identifica la combinación óptima de imágenes que maximiza la precisión de validación. Este enfoque riguroso asegura que el modelo se evalúe de manera imparcial y que los resultados sean representativos de su capacidad para generalizar a nuevos datos.

El entrenamiento exitoso del modelo durante 29 épocas, junto con su evaluación exhaustiva en un conjunto de validación independiente, subraya su aplicabilidad clínica. La precisión del 86.67% en la clasificación de imágenes de ojos entre "ojos enfermos" y "ojos sanos" destaca su potencial para optimizar y acelerar el diagnóstico oftalmológico.

La capacidad del modelo para realizar predicciones precisas en un conjunto de prueba independiente reafirma su robustez y fiabilidad, cualidades cruciales para su implementación práctica en clínicas y hospitales. Estos resultados son prometedores para la oftalmología y otras áreas de la medicina que requieren diagnóstico automatizado y rápido.

La matriz de confusión y la curva ROC confirmaron la capacidad del modelo para distinguir entre "ojos enfermos" y "ojos sanos", con métricas de precisión, sensibilidad y especificidad que respaldan su rendimiento.

Bibliografia

- Alyoubi, W. L., Shalash, W. M., & Abulkhair, M. F. (2020). *Diabetic retinopathy detection through deep learning techniques: A review*. *Informatics in Medicine Unlocked*, 20, 100377. <https://doi.org/10.1016/j.imu.2020.100377>.
- American Academy of Ophthalmology. (2019). *Diabetic Retinopathy Preferred Practice Pattern*. Retrieved from <https://www.aao.org/preferred-practice-pattern/diabetic-retinopathy-ppp>.
- Brownlee, J. (2019). *Deep Learning for Computer Vision: Image Classification, Object Detection, and Face Recognition in Python*. Machine Learning Mastery.
- Dumoulin, V., & Visin, F. (2016). *A guide to convolution arithmetic for deep learning*. arXiv preprint arXiv:1603.07285.
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing* (4th ed.). Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Google. (2023). *Seeing potential: How AI is helping doctors identify diabetic retinopathy*. https://about.google/intl/ALL_us/stories/seeingpotential/.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning with Applications in R*. New York: Springer.
- Klein, R., Klein, B. E. K., & Moss, S. E. (2010). *Retinal Hemorrhages*. In *Diabetic Retinopathy* (pp. 123-136). Springer.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. *Nature*, 521(7553), 436-444. doi:10.1038/nature14539.

Mayo Clinic. (2023). *Retinopatía diabética*. <https://www.mayoclinic.org/es-es/diseases-conditions/diabetic-retinopathy/symptoms-causes/syc-20371611>.

Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66.

Sezgin, M., & Sankur, B. (2004). *Survey over image thresholding techniques and quantitative performance evaluation*. *Journal of Electronic Imaging*, 13(1), 146-165.