

Anabel Moreno López

**DETECCIÓN Y CLASIFICACIÓN AUTOMATIZADA DE LA RETINOPATÍA
DIABÉTICA MEDIANTE EL APRENDIZAJE PROFUNDO Y EL
PROCESAMIENTO DE IMÁGENES**

TRABAJO DE FIN DE GRADO

**Dirigido por
Dr. Hatem Abdellatif Fatahallah Ibrahim Mahmoud**

Grado en Ingeniería Biomédica



UNIVERSITAT ROVIRA I VIRGILI

**Tarragona
(2024)**

ÍNDICE

Agradecimientos	4
Abstract	5
Abreviaturas	6
1. Introducción	7
2. Diabetes Mellitus	9
2.1 Datos Epidemiológicos	10
2.2 Enfermedades Asociadas a la Diabetes Mellitus	11
2.2.1 Complicaciones Microvasculares.....	11
2.2.2 Complicaciones Macrovasculares	12
2.2.3 Complicaciones Metabólicas.....	12
3. Retinopatía Diabética.....	13
3.1 Clasificación Retinopatía Diabética	14
3.1.1 Retinopatía Diabética No Proliferante	14
3.1.2 Retinopatía Diabética Proliferante	16
3.2 Detección y Diagnóstico	17
3.2.1 Oftalmoscopia Directa e Indirecta.....	17
3.2.2 Retinografía.....	17
3.2.3 Angiografía con Fluoresceína	17
3.2.4 Avances Tecnológicos: Procesamiento de Imágenes e Inteligencia Artificial	17
4. Aprendizaje Automático (Machine Learning).....	18
4.1. Redes Neuronales Convolucionales.....	19
5. Objetivos.....	20
6. Primera Parte: Clasificación Según Calidad	21
6.1 Selección de Muestras	21
6.2 Entrenamiento de Muestras	22
6.3 Código Detección de Calidad.....	24
6.4 Resultados Clasificación Calidad	30
6.4.1 Resultados Clasificación Calidad Train	31
6.4.2 Resultados Clasificación Calidad Test.....	32
6.5 Discusión Resultados.....	33
7. Segunda Parte: Clasificación Retinopatía Diabética	35
7.1 Máscara Greyscale Para Resaltar Exudados	42
7.2 Máscara Para Resaltar Neovascularización	45
7.3 Hipótesis.....	46
7.4 Desarrollo Nuevo Modelo	50
7.5 Modelo de Clasificación	52
7.6 Resultados del Modelo de Clasificación	54

7.7 Código Modelo de Clasificación.....	56
8. CONCLUSIÓN	59
Referencias.....	61

Agradecimientos

En primer lugar, quiero expresar mi más sincero agradecimiento al Dr. Hatem Abdellatif Fatahallah Ibrahim Mahmoud, mi profesor y tutor, por su guía, apoyo y paciencia a lo largo de todo este proyecto. Su dedicación y conocimiento han sido fundamentales para la realización de este trabajo, y siempre le estaré agradecida por su valiosa contribución a mi formación académica y personal.

Asimismo, quiero extender mi gratitud a la Universidad Rovira i Virgili por haberme brindado un ambiente acogedor y por haberme proporcionado todas las herramientas, recursos y oportunidades necesarios para mi desarrollo tanto personal como profesional.

En tercer lugar, quiero expresar mi más sincera gratitud a mi familia y amigos cercanos. Gracias por estar siempre a mi lado, por creer en mí incluso en los momentos en que yo misma dudaba. Su apoyo constante durante estos cuatro años, ha sido un pilar esencial que me ha sostenido y dado fuerzas para seguir adelante, especialmente en aquellos momentos difíciles en los que la incertidumbre y el desánimo parecían apoderarse de mí.

Finalmente, pero no por ello menos importante, quiero hacer una pausa para reconocerme a mí misma. Agradezco la determinación y el coraje que he mostrado en cada paso de este camino, la fuerza que he encontrado incluso en los momentos de incertidumbre. Este difícil camino ha sido un reflejo de mi resiliencia y de mi capacidad para superar los desafíos. Me enorgullece haber llegado hasta aquí, y esta culminación no solo es un logro académico, sino también un reflejo de mi crecimiento personal. Agradezco a la persona que soy hoy, por no rendirse nunca y por encontrar siempre la motivación para seguir persiguiendo mis sueños.

Abstract

La Retinopatía Diabética (RD) es una de las principales complicaciones de la Diabetes Mellitus (DM) y una de las causas más comunes de ceguera en adultos a nivel mundial. A medida que la DM progresa, los pacientes pueden desarrollar diversos grados de RD, los cuales se manifiestan a través de cambios patológicos en la retina. Un diagnóstico y clasificación precisos de la RD son esenciales para implementar tratamientos oportunos y efectivos, que pueden prevenir o retrasar la pérdida de visión.

Este proyecto tiene como objetivo desarrollar algoritmos de aprendizaje profundo para clasificar automáticamente las imágenes retinianas según el grado de severidad de la retinopatía diabética. Utilizando un conjunto de datos de imágenes de fondo de ojo previamente clasificado, el proyecto se enfoca en la aplicación de técnicas avanzadas de procesamiento de imágenes para identificar y analizar características clave de la retina.

El procesamiento de imágenes es crucial en este contexto. Mediante técnicas de segmentación y análisis de características, se pueden identificar áreas específicas como la neovascularización y los exudados, que son indicadores clave para determinar la progresión de la RD y permiten una evaluación detallada del estado de la enfermedad.

El objetivo principal es crear una herramienta informática que apoye a los oftalmólogos en la detección y seguimiento de la retinopatía diabética, proporcionando una evaluación más objetiva y rápida del estado de la enfermedad. Aunque los resultados obtenidos aún no cumplen completamente con los estándares de precisión requeridos por la comunidad médica y científica, este proyecto representa un primer paso hacia el desarrollo de un sistema de apoyo que podría contribuir significativamente a mejorar la precisión del diagnóstico y la eficiencia en el tratamiento.

Abreviaturas

CAD: Cetoacidosis diabética
CNN: Redes neuronales convolucionales
DM: Diabetes mellitus
DM1: Diabetes mellitus tipo 1
DM2: Diabetes mellitus tipo 2
DR-0: Ausencia de retinopatía diabética
DR-1: Retinopatía diabética no proliferativa leve
DR-2: Retinopatía diabética no proliferativa moderada
DR-3: Retinopatía diabética no proliferativa severa
DR-4: Retinopatía diabética proliferativa
EAP: Enfermedad arterial periférica
EMD: Edema macular diabético
IA: Inteligencia artificial
IDF: International Diabetes Federation
IRMAs: Anormalidades microvasculares intrarretinianas
ML: Machine learning
RD: Retinopatía diabética
RDNP: Retinopatía diabética no proliferativa
RDP: Retinopatía diabética proliferativa
SGD: Stochastic Gradient Descent
SHH: Síndrome hiperglucémico hiperosmolar
VEGF: Factor de crecimiento endotelial vascular

1. Introducción

La Retinopatía Diabética (RD) es una complicación microvascular crónica asociada con la Diabetes Mellitus (DM), que afecta a los vasos sanguíneos de la retina y es una de las principales causas de ceguera prevenible a nivel global, especialmente entre pacientes con diabetes de larga evolución. Esta enfermedad se manifiesta en una serie de grados de severidad, desde alteraciones leves hasta formas proliferativas avanzadas que pueden llevar a la pérdida significativa de visión si no se trata adecuadamente. La detección temprana y precisa de los diferentes estadios de RD es crucial para la prevención de su progresión, optimizando el manejo clínico y las intervenciones terapéuticas.

Este proyecto se centra en el desarrollo y aplicación de técnicas avanzadas para la clasificación automatizada de imágenes retinianas con el objetivo de identificar y categorizar los niveles de retinopatía diabética. La metodología adoptada se estructura en dos fases interrelacionadas que utilizan enfoques complementarios de machine learning y procesamiento de imágenes.

La primera fase del proyecto implica la implementación de un modelo de clasificación basado en redes neuronales convolucionales, específicamente la arquitectura ResNet18, para evaluar la calidad de las imágenes de fondo de ojo. ResNet18, una red preentrenada conocida por su eficacia en la extracción y clasificación de características visuales, se ajusta para discernir imágenes de alta calidad de aquellas que no cumplen con los estándares necesarios para un análisis preciso. Este proceso de clasificación permite filtrar las imágenes, garantizando que solo aquellas que presentan calidad adecuada sean sometidas a un análisis más profundo en la siguiente etapa. La calidad de las imágenes es crítica para asegurar que los datos utilizados en la detección de RD sean precisos y representativos.

En la segunda fase, se aplica un conjunto de técnicas avanzadas de procesamiento de imágenes para identificar características patológicas específicas asociadas con la RD en las imágenes filtradas. El procesamiento incluye técnicas de segmentación y análisis de características que permiten detectar y cuantificar elementos claves como la neovascularización y los exudados. Estos indicadores son esenciales para evaluar el grado de severidad de la RD.

El procesamiento de imágenes para la detección de exudados utiliza técnicas de umbralización y filtrado para destacar áreas específicas en las imágenes retinianas. Estas áreas se identifican mediante el procesamiento de imágenes en escala de grises y análisis de bordes, lo que ayuda a calcular su extensión en píxeles. Por otro lado, la detección de neovascularización se realiza a través de la conversión de imágenes a espacio de color HSV y la aplicación de máscaras específicas para identificar áreas de neovascularización, cruciales para clasificar las etapas más avanzadas de la RD.

El enfoque combinado de un modelo de machine learning para la clasificación de calidad de imágenes y técnicas avanzadas de procesamiento de imágenes proporciona una solución integral para la detección y clasificación de la retinopatía diabética. Este enfoque no solo mejora la precisión diagnóstica, sino que también facilita un análisis más objetivo y eficiente de las imágenes retinianas.

Este proyecto ha sido realizado con el apoyo y orientación de la Universitat Rovira i Virgili y, en particular, del Dr. Hatem Abdellatif Fatahallah Ibrahim Mahmoud. Su guía ha sido fundamental en el desarrollo del proyecto, aportando tanto en los aspectos técnicos como en la estructura de la investigación.

El objetivo final es mejorar la precisión en la detección y clasificación de la retinopatía diabética, contribuyendo al desarrollo de herramientas que puedan ser implementadas en entornos clínicos. La implementación de un sistema automatizado y eficiente representa un avance significativo en la medicina preventiva, facilitando intervenciones tempranas y reduciendo el riesgo de ceguera en pacientes diabéticos.

2. Diabetes Mellitus

La diabetes mellitus es una enfermedad metabólica crónica que se caracteriza por niveles elevados de glucosa en la sangre (hiperglucemia) debido a defectos en la secreción de insulina, en la acción de la insulina o en ambas. Esta enfermedad crónica ha sido reconocida desde la antigüedad, pero ha experimentado un incremento alarmante en su prevalencia en las últimas décadas. Este aumento se debe a factores como el envejecimiento de la población, el cambio en los hábitos alimentarios, el sedentarismo y el aumento de la obesidad. [1]

Existen diferentes formas de diabetes mellitus, clasificadas principalmente en diabetes tipo 1, diabetes tipo 2, diabetes gestacional y otros tipos menos comunes, como la diabetes monogénica y la secundaria a enfermedades endocrinas [2].

La diabetes tipo 1 (DM1), también conocida como diabetes insulino dependiente, es una enfermedad autoinmune en la cual el sistema inmunitario del cuerpo ataca y destruye las células beta del páncreas que producen insulina [3]. Este tipo de diabetes constituye aproximadamente el 5-10% de todos los casos de diabetes y suele manifestarse en la infancia o la adolescencia; requiriendo un tratamiento de por vida con insulina [4].

La diabetes tipo 2 (DM2) es la forma más común y representa cerca del 90-95% de los casos de diabetes [5]. Se caracteriza por la resistencia a la insulina y una deficiencia relativa en su secreción. La DM2 está fuertemente correlacionada con factores de riesgo modificables, como la obesidad, el estilo de vida sedentario y la dieta poco saludable. A menudo se diagnostica en la edad adulta, aunque cada vez es más común en personas jóvenes debido a los cambios en los estilos de vida. [6]

La diabetes gestacional se refiere a la diabetes diagnosticada por primera vez durante el embarazo, que no es claramente una diabetes preexistente. Esta condición aumenta el riesgo de complicaciones tanto para la madre como para el bebé y puede predisponer al desarrollo de DM2 en el futuro. [7]

Otros tipos de diabetes mellitus incluyen aquellos menos frecuentes, algunos de los cuales se asocian a patrones de herencia determinados (diabetes tipo MODY, de herencia autosómica dominante) o a alteraciones cromosómicas (síndrome de Down, síndrome de Klinefelter), a enfermedades del páncreas exocrino (pancreatitis, fibrosis quística, neoplasias), o a estados como el embarazo (diabetes gestacional). También existen diabetes inducidas por fármacos o tóxicos, así como diabetes secundarias a infecciones. [8]

2.1 Datos Epidemiológicos

En cuanto a los datos epidemiológicos, la diabetes mellitus constituye uno de los mayores desafíos de salud pública a nivel mundial debido a su alta prevalencia y las graves complicaciones asociadas [9]. De acuerdo con el informe más reciente de la International Diabetes Federation (IDF), en 2021 se estimaba que aproximadamente 537 millones de adultos, con edades comprendidas entre 20 y 79 años, vivían con diabetes a nivel global. Esta cifra representa una prevalencia global del 10.5%, lo que significa que aproximadamente 1 de cada 10 personas en el mundo padece esta enfermedad. [10]

La diabetes mellitus no solo es un problema de salud significativo por su prevalencia, sino también por el impacto de sus complicaciones crónicas. Las personas con diabetes tienen un riesgo considerablemente mayor de desarrollar enfermedades cardiovasculares, neuropatías, retinopatías y enfermedades renales, que pueden llevar a una disminución importante en la calidad de vida y un aumento en la mortalidad. [10]

Las proyecciones epidemiológicas sugieren que la situación empeorará en las próximas décadas. Se estima que para el año 2045, el número de adultos con diabetes aumentará a aproximadamente 783 millones, lo que representará un incremento del 46% en solo 24 años. Esta proyección indica que la prevalencia de diabetes aumentará a 12.2% de la población adulta global, es decir, 1 de cada 8 adultos vivirá con diabetes para 2045. [11]

Este aumento proyectado está impulsado por varios factores, el envejecimiento de la población, la urbanización, y los cambios en los estilos de vida, tales como dietas poco saludables y la falta de actividad física. Para enfrentar esta creciente crisis de salud pública, es crucial implementar estrategias efectivas de prevención y diagnóstico, incluyendo la promoción de estilos de vida saludables y la mejora en el acceso a servicios de atención médica adecuados. [12]

La creciente prevalencia de la diabetes subraya la necesidad urgente de avances en la detección temprana y el tratamiento de la enfermedad, así como de estrategias innovadoras para su manejo a nivel global. [12]

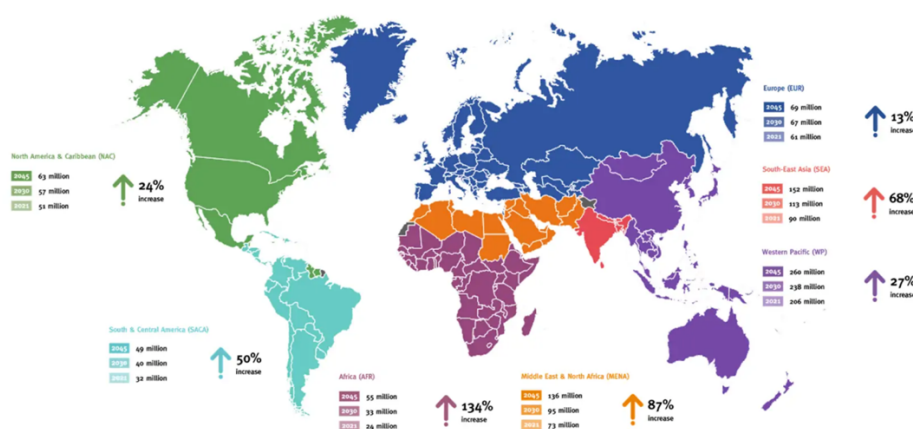


Figura 1. Mapa con los datos epidemiológicos de la diabetes mellitus, y su incremento por años [10].

2.2 Enfermedades Asociadas a la Diabetes Mellitus

La diabetes mellitus, es una enfermedad metabólica crónica caracterizada por hiperglucemia persistente, que puede llevar al desarrollo de diversas complicaciones que afectan múltiples sistemas del cuerpo. Estas complicaciones pueden ser agudas o crónicas y tienen un impacto significativo en la calidad de vida del paciente. [1]

La diabetes mellitus se asocia con una serie de enfermedades y condiciones que se agrupan principalmente en complicaciones microvasculares, macrovasculares y metabólicas.

2.2.1 Complicaciones Microvasculares

Las complicaciones microvasculares resultan de la afectación de los pequeños vasos sanguíneos y pueden llevar a una serie de condiciones severas [13].

- **Retinopatía Diabética:** la retinopatía diabética es una de las principales causas de ceguera en adultos en el mundo desarrollado. Se estima que aproximadamente 34.6 millones de personas en todo el mundo sufren de retinopatía diabética, y cerca del 10% de estos casos llevan a una pérdida significativa de visión [14]. La enfermedad se clasifica en dos etapas: retinopatía diabética no proliferativa (RDNP) y retinopatía diabética proliferativa (RDP). La RDNP se caracteriza por la presencia de microaneurismas y hemorragias en la retina, mientras que la RDP implica el crecimiento anormal de vasos sanguíneos que pueden causar hemorragias vítreas y desprendimiento de retina. [14]
- **Nefropatía Diabética:** la nefropatía diabética es una complicación renal que afecta aproximadamente al 30% de las personas con diabetes tipo 1 y al 40% de las personas con diabetes tipo 2 [15]. Esta condición se caracteriza por la progresiva pérdida de función renal, que puede llevar a insuficiencia renal crónica y requerir diálisis o trasplante renal. Los principales indicadores de nefropatía incluyen la presencia de albumina en la orina (microalbuminuria) y la disminución del filtrado glomerular. [16]
- **Neuropatía Diabética:** la neuropatía diabética afecta a aproximadamente 50% de las personas con diabetes y puede presentarse en diversas formas, como neuropatía periférica, neuropatía autonómica y neuropatía proximal [17]. Los síntomas incluyen dolor, entumecimiento, debilidad muscular y problemas en el control de las funciones corporales automáticas, como la regulación del ritmo cardíaco y la digestión. La neuropatía diabética periférica es particularmente preocupante debido a su asociación con úlceras en los pies y un mayor riesgo de amputaciones. [18]

2.2.2 *Complicaciones Macrovasculares*

Las complicaciones macrovasculares involucran la afectación de los grandes vasos sanguíneos y están asociadas con un aumento significativo en la morbilidad cardiovascular [19].

- **Enfermedad Cardiovascular:** la diabetes mellitus se asocia con un riesgo aumentado de enfermedad cardiovascular, incluyendo enfermedad coronaria, infarto de miocardio y accidente cerebrovascular. Los pacientes diabéticos tienen un riesgo 2 a 4 veces mayor de desarrollar enfermedad cardiovascular en comparación con la población general. La aterosclerosis acelerada en personas con diabetes se debe a factores como la hipertensión, dislipidemia y la presencia de inflamación crónica. [20]
- **Enfermedad Arterial Periférica:** la enfermedad arterial periférica (EAP) es una condición donde las arterias que suministran sangre a las extremidades se estrechan y obstruyen, lo que puede causar dolor en las piernas al caminar (claudicación intermitente) y aumentar el riesgo de úlceras y amputaciones [21]. La prevalencia de la EAP es significativamente mayor en personas con diabetes, con estudios mostrando que hasta el 30% de los pacientes diabéticos pueden presentar EAP [22].

2.2.3 *Complicaciones Metabólicas*

Las complicaciones metabólicas de la diabetes pueden afectar diversos aspectos del metabolismo y la salud general del paciente [23].

- **Cetoacidosis Diabética (CAD):** la cetoacidosis diabética es una complicación aguda y potencialmente mortal que ocurre principalmente en diabetes tipo 1, aunque también puede ocurrir en tipo 2. Se caracteriza por una combinación de hiperglucemia severa, cetonuria y acidosis metabólica. La CAD requiere intervención médica urgente para corregir los desequilibrios electrolíticos y restaurar los niveles de insulina. [24]
- **Síndrome Hiperglucémico Hiperosmolar (SHH):** el síndrome hiperglucémico hiperosmolar es otra complicación aguda que ocurre principalmente en diabetes tipo 2, y se presenta con niveles extremadamente altos de glucosa en sangre sin cetosis significativa. El SHH puede llevar a deshidratación severa y alteraciones del estado mental, requiriendo tratamiento intensivo para corregir el desequilibrio de líquidos y electrolitos. [25]

3. Retinopatía Diabética

Una de las enfermedades asociadas a la diabetes mellitus, es la retinopatía diabética (RD), una complicación ocular de la DM que afecta la retina, la capa de tejido en el fondo del ojo responsable de convertir la luz en señales nerviosas que son enviadas al cerebro. La RD es una de las principales causas de ceguera en adultos, y su prevalencia está aumentando en todo el mundo debido al incremento de la diabetes mellitus. [26]

La retinopatía diabética se desarrolla cuando los niveles elevados de glucosa en sangre causan daño a los pequeños vasos sanguíneos de la retina. Estos vasos pueden presentar microaneurismas, obstrucciones y hemorragias. A medida que la enfermedad progresa, pueden formarse nuevos vasos sanguíneos anormales (neovascularización), que son frágiles y propensos a romperse, causando hemorragias en el humor vítreo y desprendimientos de retina, lo que puede resultar en pérdida significativa de visión. [27]

La progresión y severidad de la retinopatía diabética están influenciadas por varios factores de riesgo. Uno de los factores más importantes es la duración de la diabetes; cuanto más tiempo una persona ha tenido diabetes, mayor es el riesgo de desarrollar RD. El control glucémico es otro factor crucial, niveles altos y fluctuantes de glucosa en sangre aumentan el riesgo de daño a los vasos sanguíneos de la retina. [28]

La hipertensión arterial es otro factor de riesgo significativo. La presión alta puede dañar los vasos sanguíneos en general y, en combinación con la hiperglucemia, acelera el daño a los vasos retinianos. La dislipidemia, que se refiere a niveles anormales de lípidos en sangre, también contribuye al riesgo de RD; niveles elevados de colesterol y triglicéridos pueden exacerbar los problemas vasculares en la retina. [28]

Como también, el embarazo, que puede empeorar la retinopatía diabética en mujeres con diabetes preexistente. Además, el tabaquismo y un estilo de vida sedentario pueden incrementar el riesgo de complicaciones microvasculares, incluyendo la RD. Factores genéticos también juegan un papel crucial, ya que algunas personas pueden tener una predisposición hereditaria a desarrollar complicaciones diabéticas. [28]

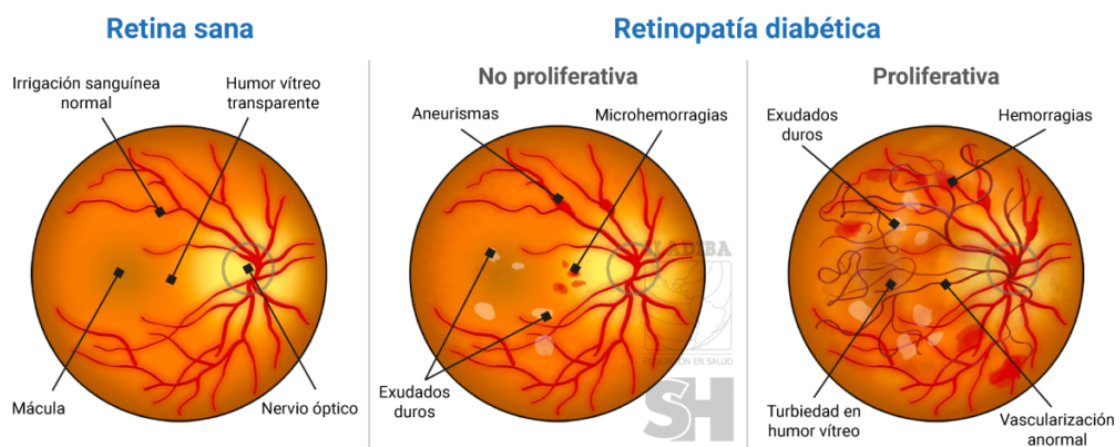


Figura 2. Comparación de una retina sana con los diferentes estadios de retinopatía diabética. Se observan los cambios vasculares y las lesiones características en cada etapa [29].

3.1 Clasificación Retinopatía Diabética

La retinopatía diabética es una complicación microvascular de la diabetes que afecta a los vasos sanguíneos de la retina. Su clasificación se basa en la gravedad de las alteraciones observadas en el fondo de ojo y se divide en dos etapas principales: la retinopatía diabética no proliferativa (RDNP) y la retinopatía diabética proliferativa (RDP). [26]

3.1.1 Retinopatía Diabética No Proliferante

La retinopatía diabética no proliferativa (RDNP), también conocida como retinopatía de fondo, es la fase inicial de la retinopatía diabética, en la que los vasos sanguíneos del ojo comienzan a perder sangre o líquido debido a la hiperglucemia mantenida [26]. Esta fuga de líquido produce inflamación de la retina o la formación de depósitos llamados exudados. La RDNP se caracteriza por una serie de cambios bioquímicos y anatómicos que provocan el daño progresivo de los pequeños vasos retinianos [30].

Aproximadamente uno de cada tres pacientes con diabetes tipo 1 o tipo 2 presenta algún grado de RDNP, aunque en la mayoría de los casos no afecta significativamente la visión. Sin embargo, cuando la visión se ve comprometida, generalmente es debido a la aparición de otras patologías, como edema macular, isquemia macular o ambas [31].

Esta fase se subdivide en tres grados de severidad:

Retinopatía Diabética No Proliferante Leve

En esta etapa, la alteración más temprana y característica es la presencia de microaneurismas, pequeñas dilataciones saculares en los capilares retinianos que pueden ser detectadas mediante una fundoscopia o una angiografía con fluoresceína. A medida que avanza la enfermedad, estos microaneurismas pueden romperse, produciendo pequeñas hemorragias intrarretinianas que suelen localizarse en las capas profundas de la retina. El riesgo de pérdida visual en esta fase es bajo, y la visión suele permanecer intacta, aunque ya existen indicios de daño en la microvasculatura [32][33].




Figura 3. Retinopatía diabética no proliferante leve.

Retinopatía Diabética No Proliferante Moderada

Esta fase se caracteriza por un aumento en el número de microaneurismas y la aparición de exudados duros y manchas algodinosas. Los exudados duros son depósitos de lípidos que se forman cuando las proteínas y los lípidos se filtran desde los vasos sanguíneos dañados hacia la retina. Las manchas algodinosas, también conocidas como exudados blandos, son áreas de isquemia retinal que resultan de la obstrucción de los capilares, lo que lleva a la muerte de las células ganglionares en la capa de fibras nerviosas de la retina. Adicionalmente, pueden aparecer venas en "rosario" (dilataciones venosas focales), lo que indica un deterioro progresivo de la perfusión retiniana. En esta etapa, el riesgo de pérdida visual comienza a aumentar debido al desarrollo de edema macular, una acumulación de líquido en la mácula que afecta la visión central. [32][33]



Figura 4. Retinopatía diabética no proliferante moderada, donde aparecen microaneurismas, microhemorragias y exudados [33].

Retinopatía Diabética No Proliferante Severa

En esta etapa avanzada, la retina presenta múltiples hemorragias intrarretinianas, microaneurismas, venas en "rosario", y un número significativo de manchas algodinosas, indicando una isquemia retinal severa. La clasificación "severa" se basa en la "regla de los 4-2-1": presencia de hemorragias en los cuatro cuadrantes de la retina, dilatación venosa en dos o más cuadrantes, y anomalías microvasculares intrarretinianas (IRMAs) en al menos un cuadrante. Las IRMAs son vasos anormales que se desarrollan en respuesta a la hipoxia, y aunque no son verdaderos neovasos, indican un estado avanzado de la enfermedad. La probabilidad de progresión hacia la retinopatía diabética proliferativa (RDP) en el siguiente año es de aproximadamente 50.2%, lo que subraya la importancia de un manejo intensivo en esta etapa. [32][33]




Figura 5. Retinopatía diabética severa. Se pueden ver microhemorragias en llama e intrarretinianas en los cuatro cuadrantes. Además, se ven exudados duros y microaneurismas [33].

3.1.2 Retinopatía Diabética Proliferante

La retinopatía diabética proliferativa (RDP) es la fase más avanzada y peligrosa de la retinopatía diabética, caracterizada por la aparición de neovascularización, es decir, la formación de nuevos vasos sanguíneos anormales en la superficie de la retina o del nervio óptico. Esta etapa se desarrolla como respuesta al cierre generalizado de los vasos sanguíneos, lo que impide un flujo sanguíneo adecuado y provoca una isquemia retiniana severa. En un intento por restaurar el suministro de sangre, la retina produce factores proangiogénicos, como el factor de crecimiento endotelial vascular (VEGF), que estimulan la formación de estos neovasos. Sin embargo, los nuevos vasos son frágiles y propensos a romperse, lo que puede resultar en hemorragias vítreas, causando una pérdida súbita y significativa de la visión que puede reducirse a solo la percepción de luz. [32][33]

Además de las hemorragias vítreas, la proliferación de neovasos suele ir acompañada de la formación de tejido fibroso, que al contraerse puede provocar un desprendimiento de retina traccional, una condición crítica que requiere intervención quirúrgica urgente debido al alto riesgo de ceguera. La RDP también puede llevar al desarrollo de glaucoma neovascular si los neovasos crecen en el ángulo de la cámara anterior del ojo, obstruyendo el drenaje del humor acuoso y causando una presión intraocular elevada, lo que podría provocar una pérdida irreversible de la visión. Esta etapa avanzada de la retinopatía diabética representa una amenaza significativa tanto para la visión central como para la periférica, y sin un manejo adecuado, puede llevar a una ceguera total. [32][33]




Figura 6. Retinopatía proliferante donde se observan claramente los neovasos papilares [33].




Figura 7. Retinopatía proliferante. Existe proliferación fibrovascular con tracción retiniana y sobre la papila [33].

3.2 Detección y Diagnóstico

El diagnóstico temprano y el tratamiento adecuado de la retinopatía diabética son esenciales para prevenir la pérdida de visión. Para lograr una detección efectiva, se utilizan varias técnicas diagnósticas, cada una con sus propias ventajas y aplicaciones. [34]

3.2.1 Oftalmoscopia Directa e Indirecta

La oftalmoscopia es una técnica fundamental para examinar el fondo del ojo. La oftalmoscopia directa utiliza un oftalmoscopio manual para visualizar directamente la retina, lo que permite una evaluación detallada de las estructuras retinianas, aunque su campo de visión es limitado. En contraste, la oftalmoscopia indirecta ofrece una visión más amplia de la retina mediante el uso de una lente condensadora y una fuente de luz. Esta técnica proporciona una imagen más panorámica, facilitando la evaluación de áreas extensas de la retina y la detección de lesiones que podrían ser difíciles de ver con la oftalmoscopia directa. [35]

3.2.2 Retinografía

La retinografía es otra herramienta valiosa que implica la captura de fotografías del fondo de ojo. Esta técnica permite documentar y monitorear la progresión de la retinopatía diabética a lo largo del tiempo, ofreciendo imágenes detalladas que ayudan en la evaluación de los cambios retinianos. La retinografía es útil para registrar la evolución de la enfermedad y para comparar imágenes en consultas sucesivas. [36]

3.2.3 Angiografía con Fluoresceína

Por otra parte, la angiografía con fluoresceína es un procedimiento de diagnóstico avanzado, que proporciona una visión detallada de los vasos sanguíneos retinianos. En este procedimiento, se inyecta un tinte fluorescente en la circulación sanguínea del paciente, y se utilizan cámaras especializadas para capturar imágenes en serie de la retina mientras el tinte circula por los vasos. Esto permite la identificación de alteraciones vasculares, como fugas y obstrucciones, que son características clave de la retinopatía diabética. [34][37]

3.2.4 Avances Tecnológicos: Procesamiento de Imágenes e Inteligencia Artificial

Finalmente, una herramienta avanzada de gran relevancia para el diagnóstico temprano de la retinopatía diabética es el procesamiento de imágenes. Con los continuos avances tecnológicos, el campo de la oftalmología ha experimentado innovaciones significativas. Actualmente, los sistemas automatizados de detección de retinopatía diabética emplean algoritmos de aprendizaje profundo para analizar imágenes del fondo de ojo. Estos sistemas son capaces de identificar con alta precisión signos de la enfermedad, detectando patrones complejos y características sutiles que podrían pasar desapercibidos para el ojo humano. Este enfoque impulsado por inteligencia artificial no solo mejora la exactitud del diagnóstico, sino que también facilita el cribado masivo, permitiendo una detección temprana en poblaciones más amplias. [38]

4. Aprendizaje Automático (Machine Learning)

El aprendizaje automático (Machine Learning, ML) es una subdisciplina de la inteligencia artificial que se enfoca en el desarrollo de algoritmos y modelos capaces de aprender y hacer predicciones o decisiones basadas en datos. A diferencia de los sistemas programados de manera explícita para realizar una tarea específica, los modelos de aprendizaje automático se entrenan con grandes volúmenes de datos, permitiéndoles identificar patrones, relaciones y tendencias subyacentes sin intervención humana directa. [39]

En el contexto de la retinopatía diabética, el aprendizaje automático ofrece una solución prometedora para abordar el desafío del diagnóstico automatizado. Los algoritmos de ML pueden procesar imágenes de fondo de ojo y, tras un adecuado entrenamiento, pueden clasificar estas imágenes en diferentes categorías según el grado de afectación, desde la ausencia de retinopatía hasta los estados más avanzados. Este enfoque no solo mejora la velocidad y eficiencia del diagnóstico, sino que también puede aumentar la precisión, superando en algunos casos a la evaluación manual realizada por especialistas. [40]

El aprendizaje automático se basa en varios tipos de modelos, entre los cuales destacan los modelos supervisados, no supervisados y de refuerzo [41]. En el caso de la clasificación de imágenes, como en el diagnóstico de retinopatía diabética, los modelos supervisados son los más utilizados. Estos modelos se entrenan con un conjunto de datos etiquetado, donde las imágenes de entrada están asociadas a una clase específica (por ejemplo, un determinado grado de retinopatía). A través de este proceso de entrenamiento, el modelo ajusta sus parámetros internos para minimizar el error en la clasificación de nuevas imágenes. [42]

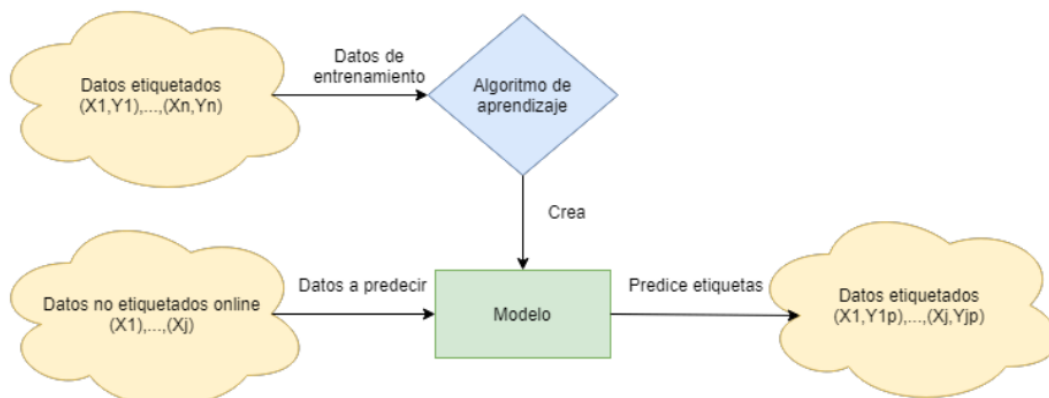


Figura 8. Esquema general de un modelo de aprendizaje automático supervisado (Machine Learning) [43].

4.1. Redes Neuronales Convolucionales

Uno de los enfoques más efectivos dentro del aprendizaje automático para tareas de clasificación de imágenes es el uso de Redes Neuronales Convolucionales (CNN). Las CNN son un tipo de red neuronal profunda especialmente diseñada para procesar datos con una estructura de grilla, como las imágenes. Estas redes destacan por su capacidad para capturar características locales esenciales en las imágenes como bordes, texturas y formas, a través de la aplicación de filtros convolucionales. Estos filtros actúan sobre pequeñas regiones de la imagen, extrayendo características relevantes que se combinan en capas sucesivas para formar representaciones más abstractas y complejas [44][45].

El proceso de convolución y subsampling, característico de las CNN, permite que estas redes sean particularmente eficaces en la identificación de patrones en imágenes, facilitando la distinción entre diferentes clases de objetos o características presentes en las imágenes. A medida que las capas de la red se profundizan, las características capturadas por los filtros se vuelven más complejas y específicas, permitiendo que la red aprenda representaciones jerárquicas de la información visual [44][45].

En el contexto de la clasificación de retinopatía diabética, las CNN son especialmente útiles debido a su capacidad para detectar sutiles anomalías en las imágenes de fondo de ojo, como microaneurismas, exudados o hemorragias, que son indicativos de distintos grados de la enfermedad. A través del entrenamiento en un conjunto de imágenes etiquetadas, la CNN aprende a asociar patrones visuales específicos con las diferentes categorías de retinopatía [44][45].

El uso de CNN preentrenadas, como ResNet18, es una estrategia ampliamente utilizada en proyectos de aprendizaje automático enfocados en la clasificación de imágenes. ResNet18, una red residual profunda, ha sido entrenada previamente en grandes conjuntos de datos, como ImageNet, que contiene millones de imágenes de diversas categorías. Este preentrenamiento dota a la red de una base sólida de características generales, que pueden ser adaptadas o refinadas para tareas específicas mediante un proceso conocido como *fine-tuning* [44][45].

La ventaja de utilizar una red preentrenada como ResNet18 radica en la capacidad de transferir el conocimiento previamente adquirido a nuevas tareas específicas, como la clasificación de retinopatía diabética. Este enfoque no solo reduce la necesidad de grandes volúmenes de datos específicos de la nueva tarea, sino que también disminuye el tiempo requerido para entrenar el modelo, logrando aun así un rendimiento elevado. En este proyecto, se implementará y ajustará una CNN basada en ResNet18, optimizándola para la clasificación automática de las imágenes de fondo de ojo en diferentes grados de retinopatía diabética, contribuyendo así a la mejora del diagnóstico. [44][45]

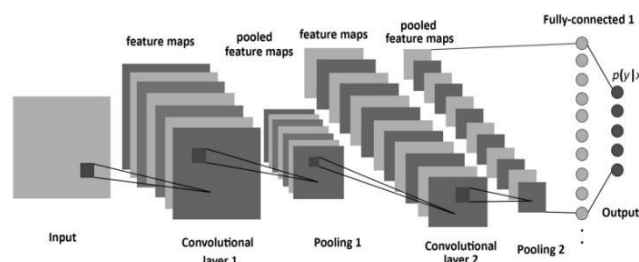


Figura 9. Redes neuronales convolucionales aplicadas en el procesamiento de imagen [46].

5. Objetivos

El presente Trabajo de Fin de Grado tiene como objetivo principal desarrollar un modelo avanzado de clasificación de imágenes retinianas utilizando técnicas de aprendizaje profundo, específicamente la arquitectura ResNet18. Este modelo se enfocará en clasificar automáticamente las imágenes de retina según su calidad, asegurando que solo aquellas que cumplan con los criterios de nitidez y claridad sean sometidas a un análisis posterior. La clasificación precisa de estas imágenes es esencial para garantizar que los datos utilizados en la detección y evaluación de la retinopatía diabética sean confiables y representativos.

Otro objetivo fundamental es optimizar la precisión del modelo, ajustando su rendimiento a lo largo del proceso de entrenamiento para alcanzar un alto nivel de exactitud en la clasificación de imágenes. Este enfoque busca asegurar que el modelo pueda generalizar adecuadamente cuando se le presenten nuevos conjuntos de datos, demostrando así su capacidad para aplicarse en situaciones reales.

Además, se aplicarán técnicas avanzadas de procesamiento de imágenes para mejorar la identificación y cuantificación de características patológicas clave presentes en las imágenes retinianas, tales como la neovascularización y los exudados. Estas técnicas permitirán un análisis más detallado y preciso del estado de la retinopatía diabética, proporcionando una base sólida para la clasificación de la severidad de la enfermedad.

La validación del modelo se llevará a cabo utilizando un conjunto independiente de imágenes de prueba. Esta fase es crucial para evaluar la robustez y fiabilidad del modelo en condiciones que simulan su aplicación en el mundo real, confirmando así su utilidad en el diagnóstico clínico.

Finalmente, este trabajo pretende contribuir al desarrollo de herramientas diagnósticas que puedan asistir a los profesionales de la salud en la detección temprana y el tratamiento adecuado de la retinopatía diabética. Al integrar el modelo de clasificación con los métodos avanzados de procesamiento de imágenes, se busca mejorar los resultados clínicos y reducir la carga de esta enfermedad a nivel global, proporcionando una solución eficiente y objetiva para el diagnóstico automatizado de enfermedades oculares.

6. Primera Parte: Clasificación Según Calidad

En esta primera parte del proyecto de fin de grado, se aborda el proceso de clasificación según calidad de las distintas imágenes de retina. Esta fase preliminar es esencial para asegurar que las imágenes empleadas en el entrenamiento y evaluación del modelo de detección de retinopatía diabética sean de alta calidad y adecuadamente representativas de las características necesarias para una clasificación precisa. El objetivo primordial es desarrollar un sistema que permita clasificar las imágenes en distintas categorías de calidad, con el fin de garantizar que únicamente aquellas que cumplan con los estándares establecidos sean utilizadas en el modelo final.

6.1 Selección de Muestras

En el marco de este Trabajo de Fin de Grado, se ha procedido a la adquisición de dos conjuntos de datos consistentes en carpetas que contienen imágenes de retina. La primera de estas carpetas, denominada “TRAIN”, contiene en su interior un total de 10.000 imágenes retinianas; estas imágenes han sido previamente clasificadas por un equipo de médicos especialistas en oftalmología pertenecientes al Instituto California Healthcare Foundation; que han clasificado y etiquetado meticulosamente el nivel de retinopatía diabética de cada una de las imágenes en un archivo Excel, facilitando así la etapa de entrenamiento de nuestro sistema de detección.

En segundo lugar, tendremos el conjunto de imágenes almacenadas en la carpeta “TEST”, que incluye en su interior un total de 5.000 imágenes adicionales. El objetivo final será lograr una clasificación de estas imágenes con el mayor grado de precisión posible, evaluando el rendimiento del modelo en condiciones similares a las que se encontraría en un entorno clínico real.




Figura 10. Comparación número de imágenes en las carpetas “TEST” y “TRAIN”.

6.2 Entrenamiento de Muestras

Tras la descarga y revisión inicial de ambos conjuntos de datos, se observó que, tanto en la carpeta “TRAIN” como en la carpeta “TEST”, había un número significativo de imágenes que presentaban problemas de enfoque o baja calidad general. Estos defectos visuales podrían comprometer la exactitud y fiabilidad del análisis realizado por el modelo, conduciendo a errores en la clasificación de los niveles de retinopatía diabética.

Es por ello, que dedujimos que uno de los primeros pasos críticos en este proyecto sería el desarrollo de un algoritmo, utilizando PyTorch, que permitiese detectar y filtrar automáticamente las imágenes de baja calidad. Este proceso de preselección es esencial para garantizar que solo aquellas imágenes con la resolución y claridad necesarias serían utilizadas en el entrenamiento y la evaluación del modelo. De esta manera, se minimizará el impacto de los artefactos visuales y se optimizará la precisión del sistema de detección de retinopatía diabética, acercándonos al objetivo de construir una herramienta fiable y eficaz para el diagnóstico clínico automatizado.

A partir de esta deducción, procederemos a la creación de una tercera carpeta denominada “ENTRENAR_FOTOS”, la cual contendrá dos subcarpetas denominadas “BUENA_CALIDAD” y “MALA_CALIDAD”.




Figura 11. Carpeta “ENTRENAR_FOTOS” con sus dos subcarpetas “BUENA_CALIDAD” y “MALA_CALIDAD”.

En cada una de estas dos subcarpetas se han incluido manualmente 100 imágenes, seleccionadas de manera meticulosa en función de criterios de calidad visual. Esta selección manual nos permitirá identificar y clasificar las imágenes que consideramos óptimas para el entrenamiento del futuro modelo, diferenciándolas de aquellas cuya calidad podría comprometer la precisión y eficacia del sistema.

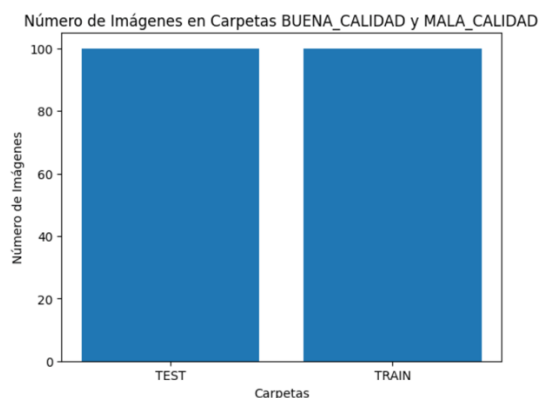


Figura 12. Comparación número de imágenes en las carpetas “BUENA_CALIDAD” y “MALA_CALIDAD”.

Imágenes en la carpeta ENTRENAR_FOTOS /BUENA_CALIDAD




Figura 13. Imágenes seleccionadas para entrenar el modelo de “BUENA_CALIDAD”.

Imágenes en la carpeta ENTRENAR_FOTOS /MALA_CALIDAD




Figura 13. Imágenes seleccionadas para entrenar el modelo de “MALA_CALIDAD”.

6.3 Código Detección de Calidad

```
# Transformaciones para las imágenes
transform = transforms.Compose([
    transforms.Resize((224, 224)),
    transforms.ToTensor(),
])

# Cargar los datos de entrenamiento y validación
dataset = datasets.ImageFolder(ruta_entrenar_fotos,
transform=transform)
train_size = int(0.8 * len(dataset))
val_size = len(dataset) - train_size
train_dataset, val_dataset = random_split(dataset, [train_size,
val_size])
train_loader = DataLoader(train_dataset, batch_size=32, shuffle=True)
val_loader = DataLoader(val_dataset, batch_size=32, shuffle=True)

# Definir el modelo (por ejemplo, un modelo de clasificación
preentrenado como ResNet)
model = models.resnet18(weights='IMAGENET1K_V1')
num_ftrs = model.fc.in_features
model.fc = torch.nn.Linear(num_ftrs, 2)

# Mover el modelo a la GPU si está disponible
device = torch.device("cuda:0" if torch.cuda.is_available() else
"cpu")
model = model.to(device)

# Definir la función de pérdida y el optimizador
criterion = nn.CrossEntropyLoss()
optimizer = optim.SGD(model.parameters(), lr=0.001, momentum=0.9)

# Función para entrenar el modelo
def train_model(model, criterion, optimizer, train_loader, val_loader,
epochs=10):
    for epoch in range(epochs):
        model.train()
        running_loss = 0.0
        for images, labels in train_loader:
            images, labels = images.to(device), labels.to(device)
            optimizer.zero_grad()
            outputs = model(images)
            loss = criterion(outputs, labels)
            loss.backward()
            optimizer.step()
            running_loss += loss.item()

        print(f'Epoch {epoch+1}, Loss:
{running_loss/len(train_loader)}')
        evaluate_model(model, val_loader)

# Función para evaluar el modelo
def evaluate_model(model, val_loader):
    model.eval()
    correct = 0
    total = 0
    with torch.no_grad():
        for images, labels in val_loader:
            images, labels = images.to(device), labels.to(device)
```

```
outputs = model(images)
_, predicted = torch.max(outputs.data, 1)
total += labels.size(0)
correct += (predicted == labels).sum().item()

print(f'Validation Accuracy: {100 * correct / total}%')

# Entrenar el modelo
train_model(model, criterion, optimizer, train_loader, val_loader,
epochs=10)
```

Código 1. Código detección de calidad

Este código es una implementación práctica de un modelo de clasificación de imágenes utilizando técnicas avanzadas de Deep Learning, específicamente una red neuronal convolucional preentrenada, ResNet-18. La idea central es ajustar este modelo para clasificar imágenes de retina según su calidad, un paso crucial en la evaluación automatizada de imágenes médicas.

El proceso comienza con la preparación de las imágenes. Dado que las redes neuronales tienen restricciones en cuanto al tamaño de entrada, las imágenes se redimensionan a 224x224 píxeles. Luego, se convierten en tensores, una estructura de datos esencial para manejar los datos en PyTorch. Este preprocesamiento asegura que las imágenes sean compatibles con el modelo ResNet-18 y optimiza su manipulación en el entorno de aprendizaje profundo.

Las imágenes se organizan en dos conjuntos: uno para entrenamiento y otro para validación. Esto es fundamental para que el modelo no solo aprenda de los datos, sino que también sea capaz de generalizar su conocimiento a nuevas imágenes. La división del conjunto de datos garantiza que un 80% de las imágenes se usen para entrenar el modelo, mientras que el 20% restante se reserva para validar su rendimiento.

El modelo elegido, ResNet-18, es una red preentrenada en el conjunto de datos ImageNet, lo que significa que ya tiene conocimiento previo de una amplia gama de características visuales. Sin embargo, la última capa del modelo se reemplaza por una nueva que se adapta a la tarea específica de este proyecto: clasificar imágenes en dos categorías (imágenes de buena y mala calidad). Este ajuste fino del modelo preentrenado es una práctica común y eficiente en Deep Learning, especialmente cuando se trabaja con conjuntos de datos limitados o tareas específicas.

El modelo se entrena utilizando una función de pérdida de entropía cruzada, que mide la discrepancia entre las predicciones del modelo y las etiquetas reales de las imágenes. El optimizador utilizado es el Stochastic Gradient Descent (SGD), configurado con una tasa de aprendizaje baja y un término de momento. Estas configuraciones permiten que el modelo ajuste sus parámetros de manera gradual y estable, reduciendo el riesgo de sobreajuste.

Durante el proceso de entrenamiento, el modelo se ajusta iterativamente a los datos de entrenamiento. En cada época, el modelo procesa todas las imágenes, ajustando sus pesos en función del error observado, para mejorar su capacidad de predicción. Tras cada época de entrenamiento, el modelo se evalúa utilizando el conjunto de validación, lo que

proporciona una métrica inmediata de su rendimiento fuera del conjunto de datos de entrenamiento.

Finalmente, el modelo entrenado es evaluado en términos de precisión sobre el conjunto de validación, proporcionando una indicación de su capacidad para generalizar y realizar predicciones precisas sobre nuevas imágenes. Esta validación es esencial para asegurar que el modelo no solo memoriza los datos de entrenamiento, sino que también es capaz de desempeñarse bien en datos no vistos anteriormente.

Al finalizar el proceso de entrenamiento, el modelo exhibió una mejora progresiva y notable en su capacidad para clasificar la calidad de las imágenes de retina a lo largo de las 10 épocas. Desde los primeros momentos del entrenamiento, se evidenció una reducción significativa en la función de pérdida, que descendió de 0.8784 en la primera época a un impresionante 0.0083 en la última. Esta disminución refleja cómo el modelo fue ajustando sus parámetros internos para adaptarse cada vez mejor a la tarea de distinguir imágenes de retina de alta calidad de aquellas que no alcanzaban los estándares requeridos para un diagnóstico fiable.

Simultáneamente, la precisión de validación experimentó un aumento sustancial, pasando rápidamente de un 77.5% en la primera época a un 92.5% en la segunda. Este avance temprano indicó que el modelo estaba captando eficazmente las características clave que determinan la calidad de las imágenes, permitiéndole clasificar correctamente una mayor proporción de ellas con cada iteración. Este incremento en la precisión culminó en la quinta época, donde el modelo alcanzó una precisión perfecta del 100%, demostrando su capacidad para identificar con absoluta exactitud las imágenes que cumplían con los criterios de calidad necesarios.

No obstante, en las épocas subsiguientes se observaron pequeñas fluctuaciones tanto en la pérdida como en la precisión, con la precisión estabilizándose en un sólido 97.5% en las últimas épocas. Esta estabilidad sugiere que el modelo había alcanzado un nivel óptimo de generalización, donde podía mantener un alto rendimiento incluso cuando se le presentaban nuevas imágenes de prueba. Este equilibrio es fundamental, ya que un modelo que generaliza bien es capaz de aplicar lo aprendido durante el entrenamiento a nuevos datos, un aspecto crítico en aplicaciones médicas donde la variabilidad en la calidad de las imágenes puede ser considerable.

La constante disminución de la pérdida y la estabilización de la precisión en un nivel elevado subrayan la eficacia del modelo para evaluar la calidad de las imágenes retinianas, un factor crucial para garantizar que las imágenes utilizadas en el diagnóstico de la retinopatía diabética sean adecuadas para un análisis clínico preciso. En resumen, este progreso a lo largo del entrenamiento refleja no solo la capacidad del modelo para aprender y mejorar, sino también su potencial para servir como una herramienta valiosa en la evaluación de la calidad de las imágenes médicas, optimizando así la fiabilidad del diagnóstico en entornos clínicos.

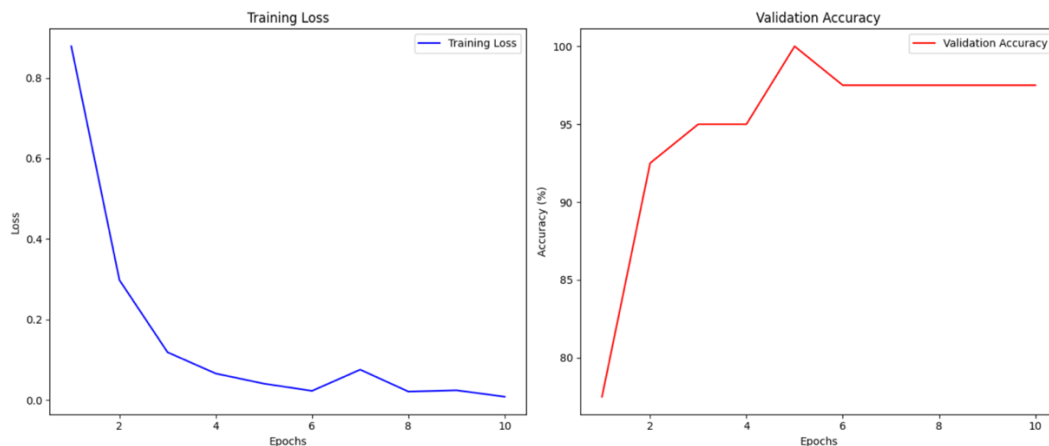


Figura 14. Curvas de aprendizaje de una red neuronal ResNet18 para la clasificación de imágenes según calidad.

A continuación, y considerando los resultados obtenidos junto con la alta fiabilidad demostrada por el modelo en su aplicación práctica, hemos decidido proceder con la clasificación autónoma de la calidad de las imágenes en dos conjuntos de datos: la carpeta “TRAIN”, que contiene 10.000 imágenes, y la carpeta “TEST”, que incluye 5.000 imágenes.

Para llevar a cabo esta clasificación, se creará una estructura de carpetas organizada de la siguiente manera: se establecerán dos carpetas principales, denominadas “CLASIFICACIÓN_CALIDAD_TRAIN” y “CLASIFICACIÓN_CALIDAD_TEST”. Donde dentro de cada una de estas carpetas principales, se generarán dos subcarpetas específicas, basadas en el nivel de calidad determinado por el modelo. Las subcarpetas estarán designadas como “CLASIFICACIÓN_BUENA_CALIDAD” para las imágenes que el modelo clasifique como de alta calidad, y “CLASIFICACIÓN_MALA_CALIDAD” para aquellas identificadas como de baja calidad o no adecuadas para el análisis.

Esta estructura permitirá una organización clara y sistemática de las imágenes, facilitando la revisión y el análisis posterior de los resultados de clasificación realizados por el modelo.




Figura 15. Carpeta “CLASIFICACIÓN_CALIDAD_TEST” y “CLASIFICACIÓN_CALIDAD_TRAIN” con sus dos subcarpeta “CLASIFICACION_BUENA_CALIDAD” y “CLASIFICACION_MALA_CALIDAD” respectivamente.

Una vez creadas las dos carpetas, el paso final consiste en ejecutar el código que se encargará de clasificar automáticamente cada imagen según su nivel de calidad, mostrando los resultados en tiempo real. Este proceso se fundamenta en la implementación de un modelo de Machine Learning previamente entrenado, basado en la arquitectura ResNet18, ajustado específicamente para diferenciar entre imágenes de buena y mala calidad. El flujo de trabajo incluye la carga y preprocesamiento de cada imagen, seguido de la predicción de su calidad utilizando el modelo. Las imágenes se organizan en carpetas específicas según su clasificación, lo que permite una estructura de datos más ordenada y eficiente.

Este enfoque no solo optimiza el conjunto de datos al descartar automáticamente las imágenes que no cumplen con los estándares de calidad necesarios para los análisis posteriores, sino que también mejora de manera significativa la eficacia y precisión en el diagnóstico automatizado de la retinopatía diabética. Esto garantiza que solo se empleen imágenes de alta calidad en la detección y evaluación de la enfermedad, aumentando la fiabilidad y robustez del sistema en un contexto clínico.

```
Imagen 13437_left.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13437_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13440_right.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13440_left.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13441_left.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13441_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13444_left.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13444_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 1344_left.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 1344_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13451_left.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13451_right.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13455_left.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13455_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13460_left.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13460_right.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13462_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13461_left.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13461_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13462_left.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13463_left.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13463_right.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13466_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13466_left.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13467_right.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13467_left.jpeg clasificada como CLASIFICACION_MALA_CALIDAD
Imagen 13468_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13468_left.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13464_left.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
Imagen 13464_right.jpeg clasificada como CLASIFICACION_BUENA_CALIDAD
```

Figura 16. Captura demostrativa de la clasificación automática de cada imagen según calidad.

6.4 Resultados Clasificación Calidad

Finalmente, solo nos queda verificar que el proceso de clasificación se está llevando a cabo de manera correcta. Una de las formas más simples y efectivas de hacerlo es inspeccionar manualmente la carpeta correspondiente y comprobar que las imágenes han sido clasificadas correctamente según su calidad. Este paso es crucial para asegurarnos de que el modelo está funcionando de acuerdo con las expectativas y que la clasificación de las imágenes en las subcarpetas de buena y mala calidad es precisa y consistente. Este tipo de verificación manual es fundamental para validar el desempeño del sistema antes de proceder con su aplicación en un entorno clínico o de investigación.

Como podemos observar, efectivamente, el modelo está realizando la clasificación de manera correcta. Al inspeccionar las carpetas designadas, se puede confirmar que las imágenes han sido organizadas adecuadamente según su calidad. Este resultado confirma que el sistema de Machine Learning está operando conforme a lo previsto, clasificando con precisión las imágenes en las categorías de buena y mala calidad. Esta verificación visual respalda la fiabilidad del modelo y garantiza que el proceso de filtrado de imágenes cumple con los estándares necesarios para su uso en el diagnóstico automatizado de la retinopatía diabética.

6.4.1 Resultados Clasificación Calidad Train

Imágenes en la carpeta CLASIFICACIÓN_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD





Figura 17. Carpeta “CLASIFICACIÓN_BUENA_CALIDAD” con 10 imágenes demostrativas de como el sistema está clasificando adecuadamente las imágenes “TRAIN” de buena calidad conforme a lo previsto.



Imágenes en la carpeta CLASIFICACIÓN_CALIDAD_TRAIN/CLASIFICACION_MALA_CALIDAD





Figura 18. Carpeta “CLASIFICACIÓN_MALA_CALIDAD” con 10 imágenes demostrativas de como el sistema está clasificando adecuadamente las imágenes “TRAIN” de mala calidad conforme a lo previsto.

6.4.2 Resultados Clasificación Calidad Test

Imágenes en la carpeta CLASIFICACIÓN_CALIDAD_TEST/CLASIFICACION_BUENA_CALIDAD





Figura 19. Carpeta “CLASIFICACIÓN_BUENA_CALIDAD” con 10 imágenes demostrativas de como el sistema está clasificando adecuadamente las imágenes “TEST” de buena calidad conforme a lo previsto.

Imágenes en la carpeta CLASIFICACIÓN_CALIDAD_TEST/CLASIFICACION_MALA_CALIDAD





Figura 20. Carpeta “CLASIFICACIÓN_MALA_CALIDAD” con 10 imágenes demostrativas de como el sistema está clasificando adecuadamente las imágenes “TEST” de mala calidad conforme a lo previsto.

6.5 Discusión Resultados

Como resultado final, observamos la importancia crítica de este primer paso en el proceso de filtrado de imágenes. Este hallazgo subraya cómo la inclusión de un número tan significativo de imágenes de mala calidad podría haber comprometido la efectividad de nuestro programa de detección de retinopatía diabética.

La presencia de imágenes defectuosas en el conjunto de datos tiene el potencial de introducir errores y reducir la precisión del modelo; llegando a afectar negativamente al introducir ruido y sesgo, lo que lleva a una disminución en la precisión del diagnóstico y la capacidad del modelo para identificar correctamente los diferentes niveles de retinopatía diabética.

Por lo tanto, este primer paso de clasificación y filtrado se revela como fundamental para asegurar que el sistema de detección opere con datos de alta calidad. La eliminación de imágenes defectuosas no solo optimiza el proceso de entrenamiento del modelo, sino que también mejora la precisión y la fiabilidad del diagnóstico automatizado, garantizando que las evaluaciones de retinopatía diabética sean lo más precisas y efectivas posible.

De acuerdo con los datos obtenidos, del total de imágenes de la carpeta "TRAIN", de las 10000 imágenes que tenía en su interior; 6513 han sido clasificadas como imágenes de buena calidad, y 3487 han sido detectadas como no aptas por su calidad; o lo que viene siendo lo mismo, aproximadamente el 65.13% de las imágenes se clasificaron como de "Buena Calidad", y el 34.87% como de "Mala Calidad". Esto significa que aproximadamente 1 de cada 3 imágenes en la carpeta "TRAIN" fue clasificada de mala calidad, y, por lo tanto, no apta para continuar con el proceso.

Cantidad de imágenes en la carpeta TRAIN (Buena Calidad): 6513
 Cantidad de imágenes en la carpeta TRAIN (Mala Calidad): 3487




Figura 21. Gráfico comparativo que muestra la cantidad de imágenes en la carpeta "TRAIN" clasificadas automáticamente como de buena o mala calidad.

Lo mismo sucede en la carpeta “TEST”, del total de imágenes de la carpeta (5000 en total), 3369 han sido clasificadas como de buena calidad, y, por lo tanto, 1631 como de mala calidad. Lo que vendría siendo lo mismo, a que aproximadamente 1 de cada 3 imágenes (o el 32.62%) se clasificó como de mala calidad.

Cantidad de imágenes en la carpeta TEST (Buena Calidad): 3369
Cantidad de imágenes en la carpeta TEST (Mala Calidad): 1631

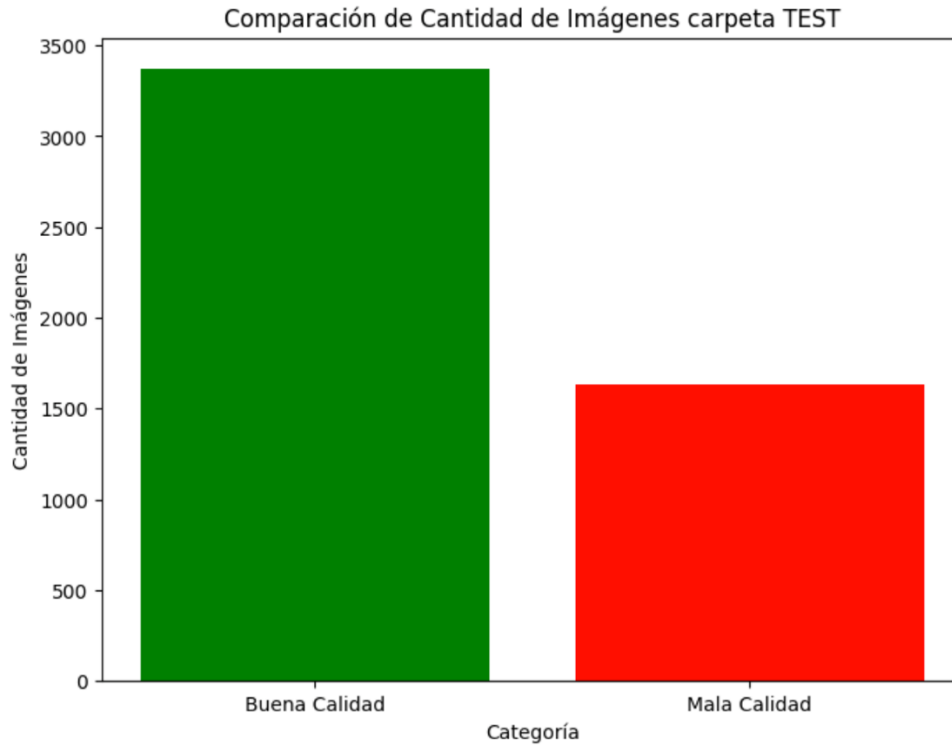


Figura 22. Gráfico comparativo que muestra la cantidad de imágenes en la carpeta "TEST" clasificadas automáticamente como de buena o mala calidad.

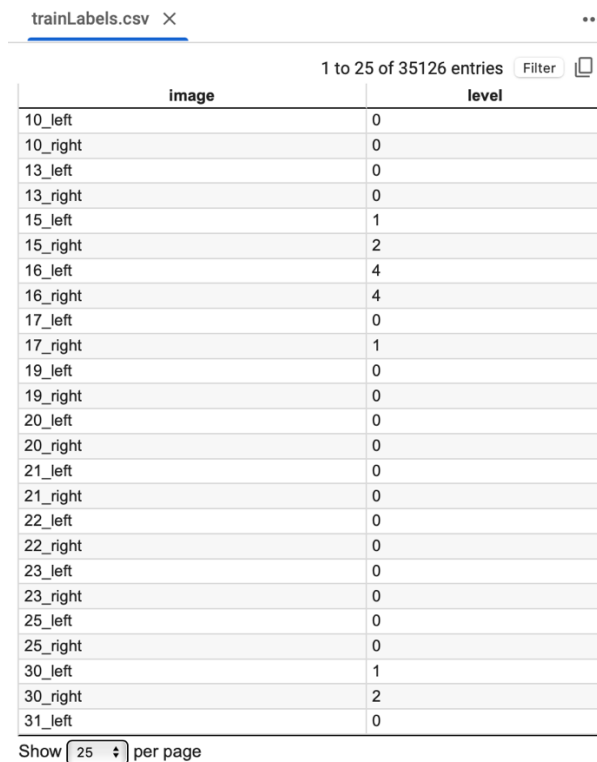
7. Segunda Parte: Clasificación Retinopatía Diabética

En esta segunda fase del trabajo de fin de grado, nos centramos en el análisis del archivo Excel asociado a las imágenes contenidas en la carpeta “TRAIN”. Este archivo es esencial para la validación de nuestro conjunto de datos, ya que proporciona una clasificación detallada y meticulosa realizada por profesionales médicos.

El archivo Excel se estructura en dos columnas principales que son fundamentales para nuestro análisis. La primera columna, denominada "image", enumera los nombres de las imágenes que se encuentran en la carpeta “TRAIN”. Esta lista está ordenada de acuerdo con criterios específicos, como el ojo (derecho o izquierdo) y el nivel de severidad de la retinopatía, lo cual permite una identificación precisa y organizada de las imágenes en el conjunto de datos.

La segunda columna denominada "level", se clasifica el nivel de retinopatía diabética para cada imagen, utilizando una escala que va del 0 al 4. Esta escala proporciona una visión detallada de la severidad de la retinopatía diabética, donde:

- **Nivel 0 (DR-0)** indica ausencia de retinopatía diabética.
- **Nivel 1 (DR-1)** corresponde a retinopatía diabética leve.
- **Nivel 2 (DR-2)** denota retinopatía diabética moderada.
- **Nivel 3 (DR-3)** representa retinopatía diabética severa.
- **Nivel 4 (DR-4)** se refiere a la retinopatía diabética proliferativa.



trainLabels.csv X

1 to 25 of 35126 entries Filter

image	level
10_left	0
10_right	0
13_left	0
13_right	0
15_left	1
15_right	2
16_left	4
16_right	4
17_left	0
17_right	1
19_left	0
19_right	0
20_left	0
20_right	0
21_left	0
21_right	0
22_left	0
22_right	0
23_left	0
23_right	0
25_left	0
25_right	0
30_left	1
30_right	2
31_left	0

Show 25 per page

Figura 23. Archivo Excel con la clasificación de cada una de las imágenes de la carpeta “TRAIN”.

De aquí, lo primero que queremos obtener será un nuevo archivo Excel con las imágenes filtradas, ya que únicamente queremos entrenar el modelo con las imágenes que han sido clasificadas como de buena calidad. Para ello, crearemos dos rutas, la primera con el archivo Excel original y la segunda ruta será las imágenes de “TRAIN” que previamente han sido clasificadas como de buena calidad. Por lo tanto, solamente aquellas que hayan sido clasificadas de buena calidad se adjuntarán en el nuevo archivo Excel denominado “trainLabels_buenacalidad.csv”.

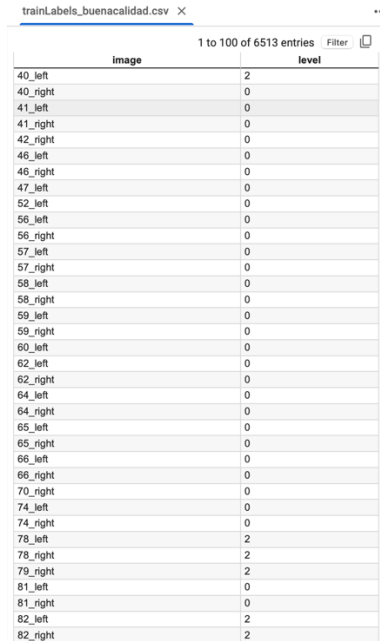


image	level
40_left	2
40_right	0
41_left	0
41_right	0
42_right	0
46_left	0
46_right	0
47_left	0
52_left	0
56_left	0
56_right	0
57_left	0
57_right	0
58_left	0
58_right	0
59_left	0
59_right	0
60_left	0
62_left	0
62_right	0
64_left	0
64_right	0
65_left	0
65_right	0
66_left	0
66_right	0
70_right	0
74_left	0
74_right	0
78_left	2
78_right	2
79_right	2
81_left	0
81_right	0
82_left	2
82_right	2

Figura 24. Nuevo archivo Excel con la clasificación de cada una de las imágenes de la carpeta “TRAIN” que han sido previamente filtradas por el modelo de calidad de imágenes.

Una vez generado el nuevo archivo Excel denominado “trainLabels_buenacalidad”, procederemos a clasificar las imágenes según las categorías de niveles de retinopatía diabética. Este paso es crucial para la preparación de datos destinados al entrenamiento de modelos de aprendizaje profundo. Para ello, se creará un nuevo directorio titulado “CLASIFICACION_RETINOPATIA_PYTORCH”. Dentro de este directorio, se establecerán subcarpetas correspondientes a los diferentes grados de retinopatía diabética, que abarcarán desde DR-0 (ausencia de retinopatía diabética) hasta DR-4 (retinopatía diabética proliferativa). Esta organización de datos permitirá una gestión eficiente y un etiquetado adecuado, facilitando el proceso de entrenamiento y evaluación del modelo de aprendizaje automático.

- ▼ **CLASIFICACION_RETINOPATIA_PYTORCH**
 - ▶ **DR-0**
 - ▶ **DR-1**
 - ▶ **DR-2**
 - ▶ **DR-3**
 - ▶ **DR-4**

Figura 25. Carpeta “CLASIFICACION_RETINOPATIA_PYTORCH” con sus 5 subcarpetas dependiendo de la gravedad de la enfermedad

Finalmente, desarrollaremos un script que procesará la segunda columna del archivo, denominada “level”, para clasificar y organizar las imágenes en función de su nivel de retinopatía diabética. Este código automatizado moverá cada imagen a su correspondiente subcarpeta dentro del directorio “CLASIFICACION_RETINOPATIA_PYTORCH”. La implementación de este script garantizará una correcta organización de las imágenes, facilitando su posterior utilización en el entrenamiento de modelos de aprendizaje profundo.

```

Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6134_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6134_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6136_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6136_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6136_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6136_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6138_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6138_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6139_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-2/6139_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6139_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-2/6139_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6144_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6144_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6144_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6144_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6148_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6148_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6148_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6148_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6155_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6155_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6158_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6158_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6158_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6158_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6163_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-2/6163_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6163_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6163_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6165_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-1/6165_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6167_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6167_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6167_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6167_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6168_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6168_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6168_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-2/6168_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6175_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-1/6175_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6175_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-1/6175_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6182_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6182_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6182_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6182_right.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6183_left.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6183_left.jpeg
Copiado: /content/gdrive/MyDrive/CLASIFICACION_CALIDAD_TRAIN/CLASIFICACION_BUENA_CALIDAD/6183_right.jpeg a /content/gdrive/MyDrive/CLASIFICACION_RETINOPATIA_PYTORCH/DR-0/6183_right.jpeg
  
```

Figura 26. Captura demostrativa de la clasificación automática de cada imagen según la gravedad de la enfermedad.

Una vez completado el script, las imágenes serán organizadas en cinco directorios distintos, cada uno correspondiente a un nivel específico de retinopatía diabética. Además, se implementará una función que generará una impresión en pantalla del número total de imágenes en cada directorio, así como una representación gráfica de estos datos mediante un gráfico de barras. Al finalizar este proceso, se observará una disparidad significativa en la distribución de imágenes: se registrarán 4,947 imágenes en la categoría DR-0 (ausencia de retinopatía diabética) en comparación con únicamente 44 imágenes en la categoría DR-4 (retinopatía diabética proliferativa). Esta desproporción en el número de muestras entre las clases ha presentado desafíos considerables en el desarrollo del modelo de aprendizaje automático, dificultando la capacidad del modelo para aprender de manera efectiva y precisa los distintos niveles de retinopatía diabética.

```

Retinopatía diabética DR-0: 4947 imágenes
Retinopatía diabética DR-2: 902 imágenes
Retinopatía diabética DR-1: 518 imágenes
Retinopatía diabética DR-3: 102 imágenes
Retinopatía diabética DR-4: 44 imágenes
  
```

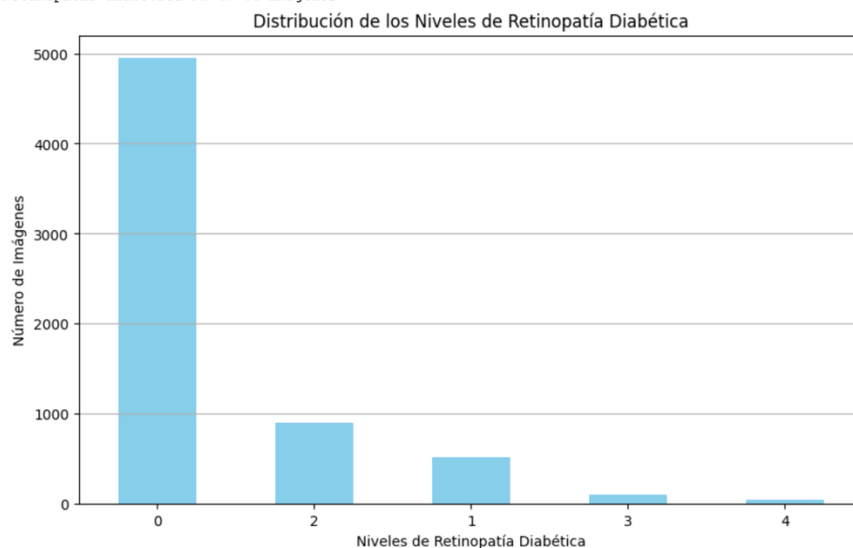


Figura 27. Gráfico ilustrativo de la distribución de los diversos niveles de retinopatía diabética.

Esta desproporción en el número de muestras entre las clases, demostró en la primera prueba del modelo ResNet18, unos resultados desafortunados:

El modelo mostró una pérdida de 0.8482 al finalizar la primera época de entrenamiento. La precisión en el conjunto de validación fue del 76.52%, lo que indica un rendimiento aceptable general en las predicciones. Sin embargo, al examinar la matriz de confusión y el informe de clasificación, se identificaron áreas significativas de preocupación.

La matriz de confusión reveló que el modelo clasificó correctamente 997 imágenes en la categoría DR-0 (ausencia de retinopatía diabética), pero no identificó ninguna imagen en las categorías DR-1 a DR-4. Este resultado se reflejó en el informe de clasificación, donde las métricas de precisión, recall y F1-score para DR-1, DR-2, DR-3 y DR-4 fueron todas 0.00. En contraste, para DR-0, las métricas fueron relativamente altas, con una precisión de 0.77 y un recall perfecto de 1.00.

Estas métricas sugieren que, mientras el modelo es efectivo para identificar la ausencia de retinopatía (DR-0), tiene dificultades significativas para clasificar correctamente las imágenes de las categorías de retinopatía más graves. Este desequilibrio en el rendimiento resalta la necesidad de ajustar el modelo, posiblemente mediante técnicas para abordar el desbalance de clases y mejorar así, la capacidad del modelo para clasificar bien cada una de las categorías de retinopatía diabética.

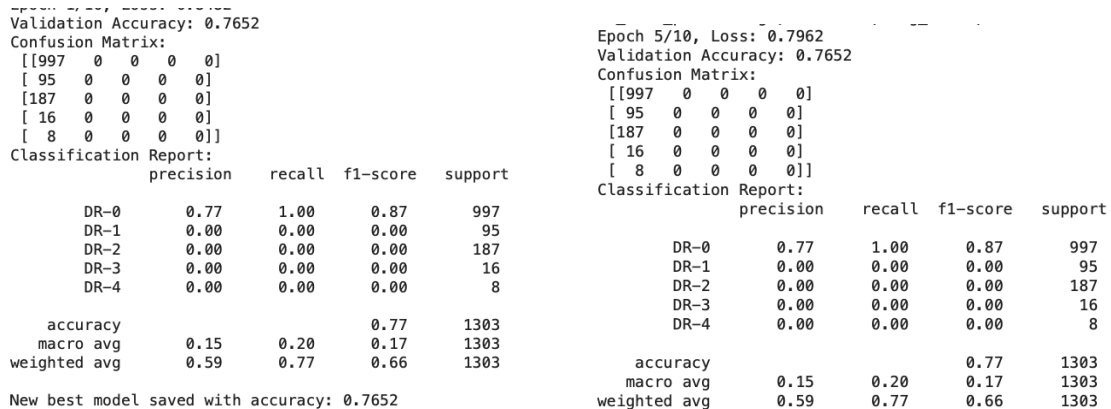


Figura 28. Imagen demostrativa del resultado negativo del modelo de aprendizaje automatizado.

A pesar de los esfuerzos realizados para mejorar el desempeño del modelo, ninguna de las estrategias implementadas logró resolver los problemas identificados. Entre las técnicas intentadas se incluyeron:

- **Re-muestreo de Datos:** se intentó aplicar tanto el sobre-muestreo de las clases minoritarias como el sub-muestreo de las clases mayoritarias para equilibrar el número de muestras entre las distintas categorías de retinopatía. El objetivo era que el modelo tuviera una representación más equitativa de cada clase durante el entrenamiento.
- **Ponderación de Clases:** se ajustaron los pesos de las clases en la función de pérdida para dar mayor importancia a las clases menos representadas, buscando que el modelo prestara más atención a las categorías minoritarias durante el proceso de aprendizaje.
- **Ajuste de Hiperparámetros:** se realizaron ajustes en los hiperparámetros del modelo, como la tasa de aprendizaje, el número de capas y neuronas, y otros parámetros relevantes, con el fin de mejorar la capacidad del modelo para aprender características relevantes de todas las clases.
- **Aumento de Datos:** se aplicaron técnicas de aumento de datos para generar variaciones de las imágenes existentes, con el propósito de mejorar la robustez del modelo y aumentar la diversidad del conjunto de entrenamiento.
- **Transferencia de Aprendizaje y Fine-Tuning:** se utilizaron modelos preentrenados y se ajustaron (fine-tuning) para adaptar sus características a la tarea específica de clasificación de retinopatía diabética, con la esperanza de aprovechar el conocimiento previo adquirido por el modelo en grandes conjuntos de datos.
- **Regularización:** se implementaron técnicas de regularización, como la deserción (dropout) y la regularización L2, para evitar el sobreajuste y mejorar la capacidad de generalización del modelo.
- **Validación Cruzada:** se aplicó la validación cruzada para evaluar el modelo de manera más robusta y asegurarse de que el desempeño observado no fuera una coincidencia debido a la partición específica del conjunto de datos.

A pesar de estos esfuerzos, la recreación de la matriz de confusión continuó revelando los mismos problemas: el modelo mantenía un buen desempeño en la clasificación de la categoría DR-0, pero seguía fallando en la identificación de las clases de retinopatía más graves (DR-1 a DR-4). Este patrón recurrente subraya que el problema principal radica en el desbalance de clases y en la dificultad del modelo para aprender de las categorías minoritarias, sugiriendo que se requiere una revisión más profunda de las estrategias utilizadas o la implementación de métodos adicionales para abordar estos desafíos.

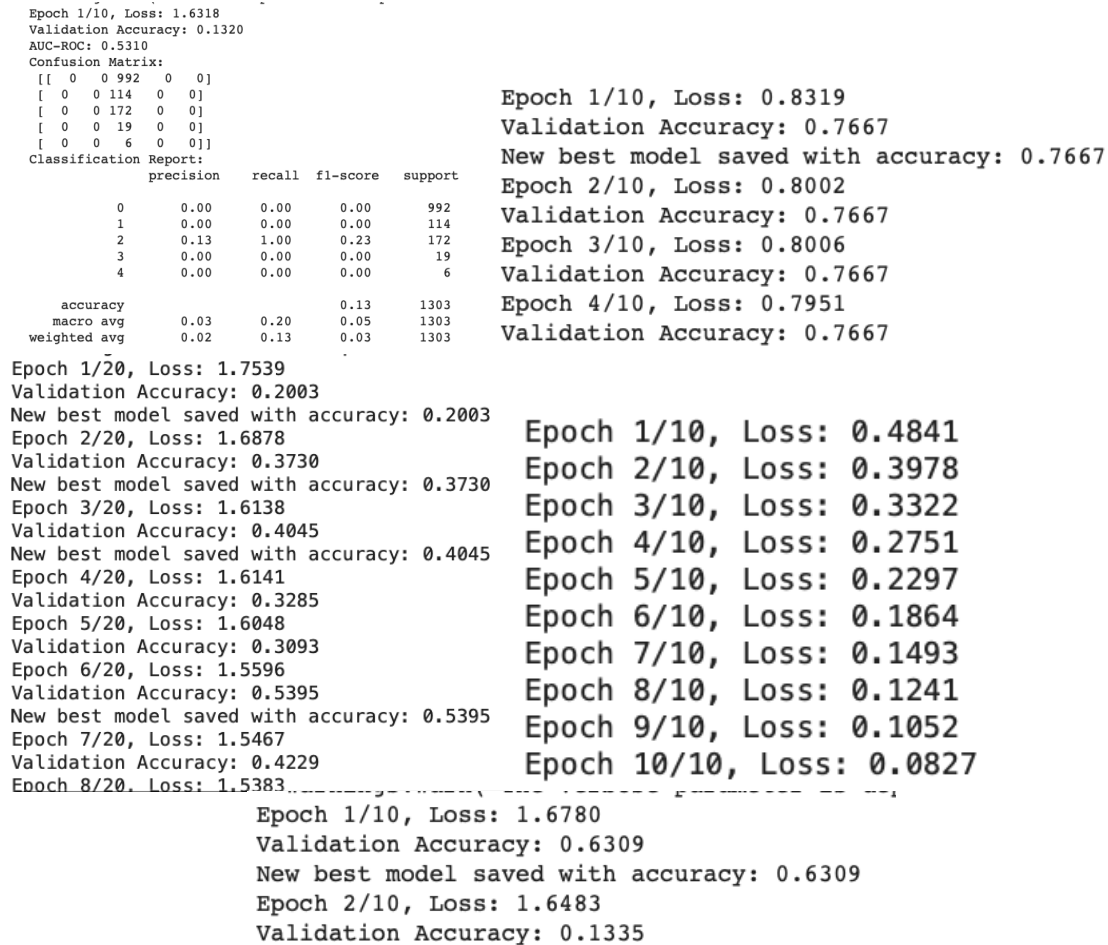


Figura 29. Conjunto de imágenes que demuestran el resultado negativo del modelo de aprendizaje automatizado.

Dado que ninguna de las múltiples estrategias implementadas logró superar los problemas persistentes en el desempeño del modelo, se decidió que, en esta segunda fase del trabajo, el enfoque se centrará principalmente en el procesamiento de imágenes. A pesar de los numerosos intentos realizados, que incluyeron técnicas como el re-muestreo de datos, la ponderación de clases, el ajuste de hiperparámetros, el aumento de datos, y otros métodos, los problemas relacionados con la desproporción de clases y el rendimiento deficiente en las categorías minoritarias persistieron.

Por lo tanto, se llevará a cabo una serie de pruebas centradas en el procesamiento de imágenes para mejorar la eficacia del modelo. Esto implicará la aplicación de diversas técnicas de preprocesamiento, tales como el uso de máscaras para resaltar características específicas y la ajuste de umbrales para optimizar la segmentación y la calidad de las imágenes. El objetivo es refinar el conjunto de datos y crear representaciones más informativas que puedan ayudar al modelo a aprender y generalizar mejor.

Este enfoque tiene como finalidad mitigar los problemas derivados del desbalance entre clases y mejorar la capacidad del modelo para diferenciar entre los distintos niveles de retinopatía diabética. Al mejorar la calidad y relevancia de las imágenes a través del procesamiento, se espera que el modelo pueda entrenarse de manera más efectiva y lograr una mayor precisión en la clasificación de las imágenes de fondo de ojo. La implementación de estas técnicas permitirá abordar las deficiencias anteriores y avanzar en el desarrollo de un modelo más robusto y preciso.




Figura 30. Imágenes etiquetadas con el número de imagen y el grado de retinopatía diabética.

7.1 MÀSCARA Greyscale Para Resaltar Exudados

En la etapa inicial del procesamiento de imágenes, se empleará una máscara en escala de grises. Este enfoque se selecciona específicamente para el análisis de imágenes de retinopatía diabética proliferativa, ya que se anticipa que permitirá resaltar de manera significativa las manchas de exudados presentes en las imágenes. La conversión a escala de grises facilita la visualización y el análisis de áreas afectadas al mejorar el contraste entre las regiones de interés y el fondo, lo que es fundamental para identificar características clave que el modelo debe aprender para clasificar de manera precisa los distintos niveles de retinopatía diabética.

Al examinar imágenes específicas (como las imágenes 1, 3 y 4), se observa que las manchas de exudados se destacan claramente cuando se aplica la máscara en escala de grises. Este resalte de las características patológicas es indicativo de que, al aplicar este método de forma consistente y calcular con precisión la intensidad de los píxeles en las áreas de interés, es posible mejorar significativamente tanto la detección como la clasificación de la retinopatía diabética.

Además, la utilización de la escala de grises permitirá un análisis más detallado de la progresión de la enfermedad, al proporcionar una visualización clara de las características patológicas y facilitar la evaluación de su impacto en la retina. Este enfoque no solo optimiza el rendimiento del modelo en términos de precisión y fiabilidad, sino que también contribuye a una comprensión más profunda de los cambios visuales asociados con diferentes grados de la enfermedad.




Figura 31. Imágenes con retinopatía diabética proliferante pasadas por un filtro de greyscale.

Este tipo de máscara será, por lo tanto, imprescindible para la detección de exudados en imágenes retinianas. Con este propósito, se desarrollará un código que identifique las zonas más claras en las imágenes como exudados y calcule su área. De acuerdo con esta hipótesis, únicamente las imágenes que presenten retinopatía diabética deberían mostrar áreas resaltadas como exudados. Por consiguiente, aquellas imágenes en las que se observe un área mínima de exudados se clasificará como retinopatía diabética sin evidencia significativa (DR-0).

Además, la capacidad de medir el área de los exudados permitirá clasificar más específicamente los diferentes grados de retinopatía diabética. Las imágenes con áreas de exudados más grandes se asociarán con formas avanzadas de la enfermedad, como la retinopatía diabética proliferativa (DR-4) o la retinopatía diabética no proliferativa severa (DR-3). En contraste, las imágenes con áreas de exudados más pequeñas se clasificarán como retinopatía diabética no proliferativa moderada (DR-2) o leve (DR-1).

Este enfoque de segmentación y cuantificación proporciona una metodología robusta para la clasificación de la retinopatía diabética. La implementación efectiva de este código mejorará la precisión del diagnóstico y contribuirá a una mejor planificación del tratamiento y manejo de la enfermedad.

PACIENTE: 42442_right | Nivel de Retinopatía: DR-4 | Área de Exudados Destacados: 53707 píxeles




Figura 32. Imagen demostrativa del proceso de identificación del área de exudados.

PACIENTE: 38136_right | Nivel de Retinopatía: DR-0 | Área de Exudados Destacados: 433 píxeles




Figura 33. Imagen demostrativa del proceso de identificación del área de exudados.

7.2 Máscara Para Resaltar Neovascularización

Otra de las máscaras empleadas en el análisis de imágenes se focaliza en la identificación de las ramificaciones vasculares en la retina. Esta técnica utiliza procesamiento de imágenes para resaltar las estructuras venosas, proporcionando una visualización detallada de las ramificaciones y la densidad vascular presente en la retina.

El análisis de las características vasculares, como el grosor y la densidad de las venas, resulta esencial para la evaluación de la retinopatía diabética. En particular, se ha observado que en las imágenes clasificadas como DR-4, un estadio avanzado de la retinopatía diabética, las venas presentan un grosor y una densidad significativamente mayores en comparación con los niveles menos avanzados de la enfermedad. Este fenómeno se debe a la presencia de neovascularización proliferativa, un indicador crítico de la progresión de la enfermedad.

La neovascularización proliferativa es una respuesta patológica en la que se forman nuevos vasos sanguíneos anómalos en la retina como resultado de la hipoxia crónica. Estos nuevos vasos suelen ser frágiles y están asociados con el aumento del grosor de las venas y una mayor complejidad en las ramificaciones vasculares. La evaluación precisa de estas características estructurales es crucial para determinar la gravedad de la retinopatía diabética.

La máscara diseñada para resaltar estas características vasculares es, por lo tanto, una herramienta invaluable para la identificación y evaluación de los diferentes estadios de la retinopatía diabética. Al proporcionar una visualización clara de las alteraciones vasculares, esta técnica ayuda a mejorar la precisión del diagnóstico y la evaluación de la progresión de la enfermedad.




Figura 34. Imagen original e imagen con los colores destacados para identificar el área de neovascularización.

7.3 Hipótesis

Con la hipótesis bien definida, el siguiente paso consiste en acceder a la carpeta que inicialmente diferenciamos según los niveles de retinopatía, habiendo sido clasificada correctamente gracias a las etiquetas del archivo Excel. A continuación, procederemos a examinar cada imagen individualmente en estas carpetas para calcular el área de exudados y el área de neovascularización presentes en cada una de las imágenes. Estos datos se promediarán para establecer un rango de referencia que se utilizará para la detección de exudados y neovascularización en imágenes nuevas que aún no han sido clasificadas. Este proceso permitirá ajustar los parámetros de detección y mejorar la precisión del modelo en la clasificación automática de imágenes retinianas.




Figura 35. Carpeta “CLASIFICACION_RETINOPATIA_PYTORCH” con sus 5 subcarpetas dependiendo de la gravedad de la enfermedad

Imagen: 4130_left.jpeg | Área de Exudados Destacados: 92901 píxeles
Imagen: 4130_left.jpeg | Área de Exudados: 92901 píxeles



Imagen: 39164_right.jpeg | Área de Exudados Destacados: 81858 píxeles
Imagen: 39164_right.jpeg | Área de Exudados: 81858 píxeles



Figura 36. Proceso para identificar el promedio de área de exudados de cada uno de los distintos niveles de retinopatía diabética

Una vez finalizado el proceso de obtención del promedio del área de exudados para cada uno de los niveles de retinopatía diabética, los resultados se mostrarán en pantalla y se representarán mediante un gráfico de barras.

Como resultado, se observa que el nivel de retinopatía diabética proliferativa (DR-4) presenta la mayor media de píxeles con exudados resaltados, con un promedio de 85070,25 píxeles por imagen. Este hallazgo destaca la gravedad de este nivel en términos de afectación retinal. Le sigue la retinopatía diabética no proliferativa (DR-3), con 72839,55 píxeles resaltados en promedio.

A continuación, se observa una marcada disminución en el nivel DR-2, con un promedio de 48618,97 píxeles resaltados, lo que indica una menor presencia de exudados en comparación con los niveles más avanzados. El nivel DR-1 sigue esta tendencia a la baja, con un promedio de 32207,47 píxeles resaltados, lo cual es característico de una fase temprana de la enfermedad.

Finalmente, el nivel DR-0, que corresponde a la ausencia de retinopatía diabética, presenta un promedio de 11106,22 píxeles resaltados. Aunque este valor debería ser cercano a cero, dado que no se espera la presencia de exudados en este nivel, el promedio refleja la posible influencia de ruido en las imágenes o de variaciones mínimas que afectan el cálculo.

Este análisis subraya la variabilidad en la distribución de los exudados a través de los distintos niveles de retinopatía diabética y destaca la importancia de un tratamiento meticuloso de los datos para optimizar la precisión del modelo en la clasificación de la enfermedad.




Figura 37. Gráfico ilustrativo de la distribución de los distintos niveles de retinopatía diabética, con el promedio del área de exudados resaltado.

Llevaremos a cabo el mismo proceso, pero en esta ocasión nos enfocaremos en calcular el promedio del área de neovascularización en lugar de exudados, con el fin de analizar y comparar los resultados en relación con los diferentes niveles de retinopatía diabética.

PACIENTE: 5032_right | Nivel de Patología: DR-4 | Área de Neovascularización: 1988088 píxeles




Figura 38. Proceso para identificar el promedio de área de neovascularización de cada uno de los distintos niveles de retinopatía diabética

Como resultado del análisis, obtendremos que el área promedio de neovascularización en el nivel de retinopatía diabética proliferativa (DR-4) es de 1.767913,86 píxeles resaltados. Este hallazgo es consistente con la naturaleza avanzada de esta etapa de la enfermedad, donde la neovascularización es más prominente y extensa.

Le sigue el nivel de retinopatía diabética no proliferativa severa (DR-3), con un promedio de 1.467722,12 píxeles resaltados. Aunque en menor medida que en DR-4, la cantidad significativa de neovascularización en DR-3 indica un alto grado de afectación y un riesgo elevado de progresión a niveles más avanzados.

A continuación, observamos una disminución notable en el nivel DR-2, con un promedio de 1.079091,29 píxeles resaltados. Este descenso refleja una menor incidencia de neovascularización en comparación con los niveles más graves, acorde con la naturaleza moderada de esta etapa de la enfermedad.

El nivel DR-1 presenta un promedio de 893039,75 píxeles resaltados, indicando una menor presencia de neovascularización en esta fase temprana de la retinopatía diabética.

Finalmente, el nivel DR-0, que corresponde a la ausencia de retinopatía diabética, muestra un promedio de 637913,86 píxeles resaltados. Aunque se espera que en este nivel, que debería mostrar una ausencia de neovascularización, el número de píxeles destacados aún puede ser relativamente alto debido a la presencia de venas y otras estructuras vasculares que pueden influir en el conteo de píxeles resaltados.

Este análisis proporciona una visión detallada de la distribución de neovascularización a través de los diferentes niveles de retinopatía diabética, subrayando la importancia de considerar estos datos para ajustar y mejorar los modelos de clasificación y diagnóstico de la enfermedad.




Figura 39. Gráfico ilustrativo de la distribución de los distintos niveles de retinopatía diabética, con el promedio del área de neovascularización resaltado.

7.4 Desarrollo Nuevo Modelo

Con la hipótesis planteada, procederemos al desarrollo de un nuevo modelo automatizado para la clasificación de imágenes en función del nivel de retinopatía diabética. Este modelo analizará las imágenes de manera secuencial, evaluando tanto los exudados como el área de neovascularización para determinar la probabilidad de presencia de retinopatía diabética.

En primera instancia, se realizará un cálculo exhaustivo de los píxeles destacados en cada imagen, considerando tanto los exudados como las áreas de neovascularización. Basado en estos cálculos, el modelo estimará la probabilidad de retinopatía diabética en cada imagen. Para validar la precisión del modelo antes de aplicarlo a la carpeta de imágenes de prueba, llevaremos a cabo una prueba preliminar utilizando la carpeta de entrenamiento.

En esta fase, crearemos una nueva carpeta denominada “TRAIN IMÁGENES RESTANTES” que contendrá un total de 4585 imágenes. Estas imágenes serán seleccionadas específicamente para asegurar que el modelo no haya tenido acceso previo a ninguna información contenida en ellas. Posteriormente, la carpeta “TRAIN_IMÁGENES_RESTANTES” será procesada por el modelo de calidad, filtrando y clasificando las imágenes según su calidad.

Finalmente, se creará una subcarpeta denominada “BUENA_CALIDAD” dentro de “TRAIN_IMÁGENES_RESTANTES_CALIDAD”, en la cual se almacenarán 3213 imágenes que cumplen con los criterios de calidad establecidos. Este proceso garantizará que el modelo se ajuste adecuadamente a las imágenes nuevas y no a datos previamente conocidos.

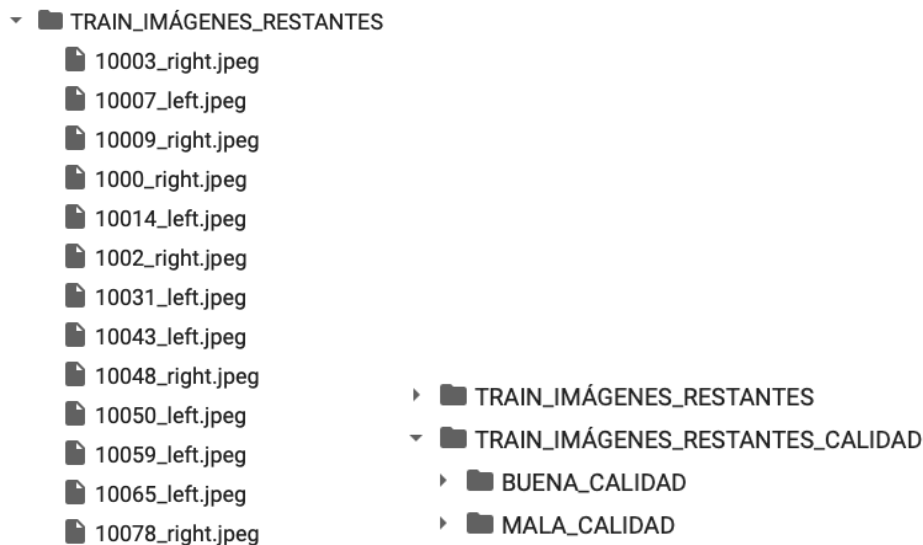


Figura 40. Carpetas “TRAIN_IMÁGENES_RESTANTES” y “TRAIN_IMÁGENES_RESTANTES_CALIDAD”

Una vez completada la clasificación de las imágenes según su calidad en la fase de entrenamiento, procederemos a organizar las imágenes restantes en función de su diagnóstico de retinopatía diabética. Para ello, crearemos una nueva carpeta denominada “TRAIN_IMAGENESRESTANTES_CLASIFICACION”. Dentro de esta carpeta, se establecerán dos subcarpetas específicas:

1. **“OJO_CON_RETINOPATÍA”**: Esta subcarpeta contendrá todas las imágenes clasificadas como afectadas por retinopatía diabética. Aquí se agruparán las imágenes que el modelo ha identificado como pertenecientes a uno de los niveles de retinopatía, desde DR-1 hasta DR-4.
2. **“OJO_SIN_RETINOPATÍA”**: En esta subcarpeta se almacenarán las imágenes clasificadas como libres de retinopatía diabética, es decir, aquellas que han sido identificadas como DR-0.

Esta organización permitirá una gestión más efectiva de las imágenes clasificadas y facilitará el análisis posterior de los resultados obtenidos por el modelo de clasificación. La separación en estas categorías ayudará a asegurar que el modelo sea entrenado y evaluado de manera adecuada, contribuyendo a una mejora continua en la precisión y rendimiento del sistema de clasificación.




Figura 41. Carpetas “TRAIN_IMAGENESRESTANTES_CLASIFICACION” con sus 2 subcarpetas “OJO_CON_RETINOPATÍA” y “OJO_SIN_RETINOPATÍA”

7.5 Modelo de Clasificación

Finalmente, procederemos a ejecutar el código utilizando nuestro modelo de clasificación. El modelo analizará las imágenes una por una y proporcionará una estimación de la probabilidad de cada nivel de retinopatía diabética para cada imagen.


Como ilustración, consideremos la imagen del paciente 10003. El modelo calculará dos métricas clave para esta imagen. La primera de ellas es el área de exudados destacados; donde en esta ocasión se han identificado 8408 píxeles de exudados. En segundo lugar, tenemos el área de neovascularización destacada, con un total de 57899 píxeles correspondientes a neovascularización. Con base en estos cálculos, el modelo estima que la probabilidad de que la imagen corresponda a la ausencia de retinopatía diabética (DR-0) es del 48.70%.

El resultado final incluirá una representación gráfica en la que se mostrarán las probabilidades calculadas para cada uno de los niveles de retinopatía diabética; y en el título se destacará el nivel con la probabilidad más alta, proporcionando una indicación clara de la clasificación más probable según el análisis del modelo.


Este proceso permitirá evaluar de manera efectiva cómo el modelo maneja las imágenes y cómo clasifica cada una en función de las características detectadas, facilitando así una revisión detallada y una evaluación de la precisión del modelo

Paciente: 10003
Área de Exudados Destacados: 8408 píxeles
Área de Neovascularización: 57899 píxeles
Clasificada como RETINA SANA. Probabilidad de DR-0: 48.70%

Paciente: 10003 - Imagen Original



DR-0: 48.70%



Probabilidades de cada nivel de retinopatía diabética:
Probabilidad de DR-0: 48.70%
Probabilidad de DR-1: 18.72%
Probabilidad de DR-2: 13.02%
Probabilidad de DR-3: 9.74%
Probabilidad de DR-4: 9.82%

Figura 42. Paciente 10003 con los resultados del nuevo modelo de clasificación.

Una vez comprobado el proceso de clasificación, el modelo procederá a evaluar imagen a imagen, calculando las áreas de exudados y neovascularización, determinando así la probabilidad de cada nivel de retinopatía diabética. Con base en estos cálculos, cada imagen se ubicará automáticamente en la carpeta correspondiente según el nivel de retinopatía con la mayor probabilidad estimada.




Figura 43. Paciente 10048 con los resultados del nuevo modelo de clasificación.

Las imágenes serán organizadas en dos subcarpetas dentro de “TRAIN_IMAGENESRESTANTES_CLASIFICACION”. Cada una de estas subcarpetas contendrá las imágenes clasificadas, proporcionando una estructura organizada que facilita el análisis y la revisión de los resultados del modelo. Este enfoque asegura que las imágenes se clasifiquen de manera eficiente y se almacenen en la carpeta adecuada, facilitando la posterior revisión y uso de los datos para entrenar y evaluar el rendimiento del modelo.

```

Imagen 2842_left.jpeg clasificada como DR-4 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 16301_left.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 17591_left.jpeg clasificada como DR-2 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 24207_right.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 20309_left.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 30432_right.jpeg clasificada como DR-4 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 13962_left.jpeg clasificada como DR-3 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 22623_right.jpeg clasificada como DR-3 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 32152_left.jpeg clasificada como DR-4 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 25265_right.jpeg clasificada como DR-3 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 12672_right.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 26518_right.jpeg clasificada como DR-1 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 19327_right.jpeg clasificada como DR-4 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 29768_right.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 29049_right.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 34484_right.jpeg clasificada como DR-3 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 2290_left.jpeg clasificada como DR-4 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 14664_right.jpeg clasificada como DR-4 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 17334_left.jpeg clasificada como DR-2 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 26750_left.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 29823_right.jpeg clasificada como DR-4 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 12933_right.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 26962_right.jpeg clasificada como DR-3 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 23665_left.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 17728_left.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 27851_right.jpeg clasificada como DR-1 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_CON_RETINOPATIA
Imagen 27077_left.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
Imagen 29618_right.jpeg clasificada como DR-0 y copiada a /content/drive/MyDrive/TRAIN_IMAGENESRESTANTES_CLASIFICACION/OJO_SIN_RETINOPATIA
    
```

Figura 44. Captura demostrativa de la clasificación automática de cada imagen según si tiene o no retinopatía diabética.

7.6 Resultados del Modelo de Clasificación

Finalmente, presentaremos un gráfico de barras que ilustrará la cantidad de imágenes en cada subcarpeta de clasificación. Este gráfico permitirá una visualización clara de la distribución de imágenes según si tiene o no retinopatía diabética.




Figura 45. Gráfico comparativo que muestra la cantidad de imágenes clasificadas según si tienen o no retinopatía diabética

Finalmente, dado que las imágenes clasificadas provienen de la carpeta "TRAIN", podemos utilizar el archivo Excel "trainLabels.csv" para comparar las clasificaciones obtenidas con las etiquetas verdaderas. Como resultado de esta evaluación, se ha logrado clasificar correctamente 2,574 imágenes, mientras que 639 imágenes fueron clasificadas incorrectamente. Esto resulta en un porcentaje de éxito del 80.11%, lo que indica una alta precisión en la clasificación realizada por el modelo.

Clasificaciones Correctas: 2574
 Clasificaciones Incorrectas: 639




Figura 46. Gráfico comparativo que muestra la cantidad de imágenes clasificadas correctamente e incorrectamente.

Finalmente, procederemos a llevar a cabo la clasificación de las imágenes en la carpeta designada como “OJO_CON_RETINOPATÍA”. Esta etapa es crucial para validar la eficacia del modelo en un contexto más realista y para evaluar su desempeño en los 4 tipos de imágenes que han sido previamente identificadas como potencialmente afectadas por retinopatía diabética.

Nivel DR-1:
 Clasificaciones Correctas: 143
 Clasificaciones Incorrectas: 33
 Total de Imágenes: 176
 Precisión: 81.25%

Nivel DR-2:
 Clasificaciones Correctas: 233
 Clasificaciones Incorrectas: 68
 Total de Imágenes: 301
 Precisión: 77.41%

Nivel DR-3:
 Clasificaciones Correctas: 68
 Clasificaciones Incorrectas: 30
 Total de Imágenes: 98
 Precisión: 69.39%

Nivel DR-4:
 Clasificaciones Correctas: 37
 Clasificaciones Incorrectas: 14
 Total de Imágenes: 51
 Precisión: 72.55%

Figura 47. Imagen demostrativa que ilustra la clasificación de las imágenes según su correcta o incorrecta asignación a cada uno de los niveles de retinopatía diabética.

Como resultado final, en esta gráfica se ilustra la magnitud del porcentaje de clasificaciones correctas e incorrectas para cada nivel de retinopatía diabética. La visualización permite comparar de manera clara y directa la eficacia del modelo en la clasificación de imágenes según el nivel de la enfermedad.




Figura 48. Gráfico comparativo que muestra la cantidad de imágenes clasificadas correctamente e incorrectamente.

7.7 Código Modelo de Clasificación

```
import cv2
import numpy as np
import matplotlib.pyplot as plt
import os

def process_exudados(img_path):
    # Cargar la imagen en color
    img = cv2.imread(img_path)

    # Verificar si la imagen se ha cargado correctamente
    if img is None:
        raise FileNotFoundError(f"La imagen no se pudo cargar desde la
ruta: {img_path}")

    # Convertir a escala de grises
    gray_img = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)

    # Aplicar un filtro de mediana para reducir el ruido
    gray_img_filtered = cv2.medianBlur(gray_img, 5)

    # Ecuilización del histograma para mejorar el contraste
    gray_img_eq = cv2.equalizeHist(gray_img_filtered)

    # Aplicar la detección de bordes para realzar detalles
    edges = cv2.Canny(gray_img_eq, 50, 150)

    # Combinar los bordes con la imagen ecualizada
    combined_img = cv2.addWeighted(gray_img_eq, 0.7, edges, 0.3, 0)

    # Umbralizar para segmentar las áreas más claras (posibles
exudados)
    _, thresh_img = cv2.threshold(combined_img, 200, 255,
cv2.THRESH_BINARY)

    # Aplicar dilatación para mejorar la visibilidad de los exudados
    kernel = np.ones((3,3), np.uint8)
    dilated_img = cv2.dilate(thresh_img, kernel, iterations=2)

    # Calcular el área de exudados destacados
    area_exudados = np.sum(dilated_img == 255)
    return area_exudados, img, combined_img

def process_neovascularizacion(img_path):
    # Cargar la imagen
    img = cv2.imread(img_path)
    # Verificar si la imagen se ha cargado correctamente
    if img is None:
        raise FileNotFoundError(f"La imagen no se pudo cargar desde la
ruta: {img_path}")

    # Convertir la imagen a espacio de color HSV
    hsv_img = cv2.cvtColor(img, cv2.COLOR_BGR2HSV)

    # Definir los rangos para los colores rojos y rosas
    lower_red1 = np.array([0, 50, 50])
    upper_red1 = np.array([10, 255, 255])
    lower_red2 = np.array([160, 50, 50])
    upper_red2 = np.array([180, 255, 255])
```

```
lower_pink = np.array([140, 50, 50])
upper_pink = np.array([170, 255, 255])

# Crear las máscaras para los colores rojos y rosas
mask_red1 = cv2.inRange(hsv_img, lower_red1, upper_red1)
mask_red2 = cv2.inRange(hsv_img, lower_red2, upper_red2)
mask_red = mask_red1 | mask_red2
mask_pink = cv2.inRange(hsv_img, lower_pink, upper_pink)

# Combinar las máscaras de rojo y rosa
combined_mask = mask_red | mask_pink

# Calcular el área de neovascularización
area_neovascularizacion = np.sum(combined_mask == 255)
return area_neovascularizacion

def calculate_probabilities(area_exudados, area_neovascularizacion):
    probabilities = {}
    for nivel in promedios_exudados:
        promedio_exudados = promedios_exudados[nivel]
        promedio_neovascularizacion =
promedios_neovascularizacion[nivel]

        # Calcular probabilidades basadas en áreas de exudados y
neovascularización
        prob_exudados = max(0, 1 - abs(area_exudados -
promedio_exudados) / promedio_exudados)
        prob_neovascularizacion = max(0, 1 -
abs(area_neovascularizacion - promedio_neovascularizacion) /
promedio_neovascularizacion)

        # Asumir que las probabilidades son la media de ambas medidas
        probabilities[nivel] = (prob_exudados +
prob_neovascularizacion) / 2

    # Normalizar para que sumen 100%
    total_prob = sum(probabilities.values())
    for nivel in probabilities:
        probabilities[nivel] = (probabilities[nivel] / total_prob) *
100

    return probabilities

def interpret_results(probabilities):
    # Obtener la probabilidad máxima y su respectivo nivel de
retinopatía
    max_level = max(probabilities, key=probabilities.get)
    max_probability = probabilities[max_level]

    # Calcular la probabilidad de tener alguna forma de retinopatía
diabética (DR-1 a DR-4)
    prob_retinopatia = 100 - probabilities['DR-0']

    # Mensaje interpretativo según el nivel de mayor probabilidad
    if max_level == 'DR-0':
        interpretacion = f"Clasificada como RETINA SANA. Probabilidad
de {max_level}: {max_probability:.2f}%"
    else:
        interpretacion = f"Probabilidad de tener retinopatía
diabética: {prob_retinopatia:.2f}%. Probabilidad de {max_level}:
{max_probability:.2f}%"
```

```

# Verificación de proximidad entre probabilidades (especialmente
entre DR-0 y DR-4)
if probabilities['DR-0'] > 40 and probabilities['DR-4'] > 40:
    interpretacion += "\nAdvertencia: Las probabilidades de DR-0
(retina sana) y DR-4 (retinopatía diabética severa) son altas. Revise
los datos de entrada o consulte con un especialista."

    return interpretacion, max_level, max_probability

# Procesar ruta específica
img_path = '/content/drive/MyDrive/TRAIN_IMAGENESRESTANTES'

# Extraer el código del paciente desde el nombre del archivo
codigo_paciente = os.path.basename(img_path).split('_')[0]

try:
    area_exudados, img_original, img_exudados =
process_exudados(img_path)
    area_neovascularizacion = process_neovascularizacion(img_path)
    # Calcular las probabilidades para la nueva imagen
    probabilidades = calculate_probabilities(area_exudados,
area_neovascularizacion)
    # Interpretar los resultados y generar el informe final
    interpretacion, max_level, max_probability =
interpret_results(probabilidades)

    # Mostrar la imagen original y la procesada
    plt.figure(figsize=(15, 6))

    # Imprimir los resultados debajo de las imágenes
    print(f'Paciente: {codigo_paciente}')
    print(f'Área de Exudados Destacados: {area_exudados} píxeles')
    print(f'Área de Neovascularización: {area_neovascularizacion}
píxeles')
    print(interpretacion)

    # Imagen original en color
    plt.subplot(1, 2, 1)
    plt.imshow(cv2.cvtColor(img_original, cv2.COLOR_BGR2RGB))
    plt.title(f'Paciente: {codigo_paciente} - Imagen Original',
fontsize=18)
    plt.axis('off')

    # Imagen procesada en escala de grises
    plt.subplot(1, 2, 2)
    plt.imshow(cv2.cvtColor(img_exudados, cv2.COLOR_GRAY2RGB))
    plt.title(f"{max_level}: {max_probability:.2f}%", fontsize=18,
color='green' if max_level == 'DR-0' else 'red')
    plt.axis('off')
    plt.show()

    # Imprimir todas las probabilidades
    print("\nProbabilidades de cada nivel de retinopatía diabética:")
    for nivel, prob in probabilidades.items():
        print(f"Probabilidad de {nivel}: {prob:.2f}%")

except FileNotFoundError as e:
    print(e)

```

Código 2. Código detección de retinopatía diabética.

8. CONCLUSIÓN

Como conclusión, en este trabajo de fin de grado se ha desarrollado un sistema de procesamiento de imágenes con el objetivo de clasificar y evaluar la retinopatía diabética mediante el uso de técnicas de machine learning y procesamiento de imágenes. Este enfoque innovador ha permitido una evaluación detallada y precisa de características clínicas críticas en imágenes retinianas, como el área de exudados y neovascularización, y ofrece una herramienta prometedora para mejorar tanto el diagnóstico como la monitorización de esta enfermedad ocular crónica.

En la primera fase del proyecto, nos enfocamos en la clasificación de la calidad de las imágenes utilizando el modelo ResNet18, una red neuronal convolucional avanzada. Tras un exhaustivo proceso de entrenamiento, el modelo demostró una mejora progresiva y notable en su capacidad para clasificar la calidad de las imágenes. Desde una función de pérdida inicial de 0.8784, se logró una disminución significativa a 0.0083 en la última época de entrenamiento. Este notable descenso en la función de pérdida, junto con una precisión de validación que alcanzó el 100% en la quinta época, demostró la capacidad del modelo para distinguir de manera efectiva entre imágenes de alta y baja calidad, garantizando que solo aquellas que cumplen con los estándares necesarios para un diagnóstico fiable sean utilizadas en el análisis.

En la segunda fase del proyecto, se abordó el desafío de la clasificación específica de la retinopatía diabética; aunque inicialmente continuamos con el modelo ResNet18, se encontraron ciertos problemas que nos llevaron a desarrollar un nuevo enfoque. Este nuevo enfoque se centró en la creación de un modelo capaz de hacer una segmentación de exudados y neovascularización utilizando técnicas de procesamiento de imágenes, como máscaras en escala de grises para los exudados y máscaras específicas para los vasos sanguíneos. Este enfoque permitió calcular el área promedio de estas características en cada nivel de retinopatía diabética, proporcionando datos cruciales para la clasificación precisa de las imágenes. Los resultados obtenidos mostraron que el 80.11% de las imágenes fueron clasificadas adecuadamente como DR-0, el 81.25% como DR-1, el 77.41% como DR-2, el 69.39% como DR-3 y el 72.55% como DR-4. Estos resultados indican una alta precisión en la detección de la enfermedad, aunque también destacan la necesidad de mejoras continuas en el sistema.

A pesar de los avances logrados, la precisión del modelo aún no alcanza los estándares óptimos requeridos por la comunidad médica y científica para una implementación completa en entornos clínicos. No obstante, este proyecto representa un avance significativo en el desarrollo de herramientas de apoyo para el diagnóstico y tratamiento de la retinopatía diabética. El sistema desarrollado no solo proporciona una base sólida para futuras investigaciones, sino que también tiene el potencial de contribuir significativamente a la mejora de la precisión diagnóstica y la eficiencia en el manejo de esta enfermedad ocular.

Este trabajo subraya el gran alcance de las tecnologías emergentes en el ámbito de la salud. Las soluciones basadas en machine learning y procesamiento de imágenes están configuradas para abordar desafíos significativos en el diagnóstico y tratamiento de enfermedades. La capacidad para automatizar y mejorar la precisión en la evaluación de condiciones como la retinopatía diabética demuestra el potencial de estas tecnologías para transformar y mejorar la atención médica.

En el futuro, se prevé que la integración de estas herramientas en prácticas clínicas no solo mejorará la precisión diagnóstica, sino que también optimizará el tratamiento y seguimiento de pacientes, elevando los estándares de atención y reduciendo la carga de enfermedades a nivel global. A medida que la tecnología continúa avanzando, podemos anticipar desarrollos aún más sofisticados que ofrecerán soluciones innovadoras para enfrentar los desafíos de la salud de manera más efectiva.

Referencias

- [1] (*Diabetes*, s/f) *Diabetes*. (s/f). Paho.org. <https://www.paho.org/es/temas/diabetes>. [consulta] 1 de septiembre del 2024.
- [2] (*¿Qué es la diabetes?*, s/f) *¿Qué es la diabetes?* (s/f). National Institute of Diabetes and Digestive and Kidney Diseases. <https://www.niddk.nih.gov/health-information/informacion-de-la-salud/diabetes/informacion-general/que-es>. [consulta] 1 de septiembre del 2024.
- [3] (*Diabetes tipo 1*, s/f) *Diabetes tipo 1*. (s/f). Medlineplus.gov. <https://medlineplus.gov/spanish/ency/article/000305.htm>. [consulta] 1 de septiembre del 2024.
- [4] (CDCespanol, 2024) CDCespanol. (2024, julio 23). *Acerca de la diabetes tipo 1*. Diabetes. <https://www.cdc.gov/diabetes/es/about/acerca-de-la-diabetes-tipo-1.html>. [consulta] 1 de septiembre del 2024.
- [5] (Mediavilla Bravo, 2002) ^[SEP]Mediavilla Bravo, J. J. (2002). la diabetes mellitus tipo 2. *Medicina Integral*, 39(1), 25–35. <https://www.elsevier.es/es-revista-medicina-integral-63-articulo-la-diabetes-mellitus-tipo-2-13025480>. [consulta] 1 de septiembre del 2024.
- [6] (*Diabetes tipo 2*, s/f) *Diabetes tipo 2*. (s/f). Medlineplus.gov. <https://medlineplus.gov/spanish/ency/article/000313.htm>. [consulta] 1 de septiembre del 2024.
- [7] (*Diabetes gestacional*, 2022) *Diabetes gestacional*. (2022, junio 11). Mayo Clinic. <https://www.mayoclinic.org/es/diseases-conditions/gestational-diabetes/symptoms-causes/syc-20355339>. [consulta] 1 de septiembre del 2024.
- [8] (Sanzana G. & Durruty A., 2016) Sanzana G., M. G., & Durruty A., P. (2016). OTROS TIPOS ESPECÍFICOS DE DIABETES MELLITUS. *Revista médica Clínica Las Condes*, 27(2), 160–170. <https://doi.org/10.1016/j.rmcl.2016.04.005>. [consulta] 1 de septiembre del 2024.
- [9] (Russo et al., 2023) Russo, M. P., Grande-Ratti, M. F., Burgos, M. A., Molaro, A. A., & Bonella, M. B. (2023). Prevalencia de diabetes, características epidemiológicas y complicaciones vasculares. *Archivos de cardiología de Mexico*, 93(1), 30. <https://doi.org/10.24875/acm.21000410>. [consulta] 1 de septiembre del 2024.
- [10] (*Datos y cifras*, 2022) *Datos y cifras*. (2022, noviembre 24). Federación Internacional de Diabetes. <https://idf.org/es/about-diabetes/diabetes-facts-figures/>. [consulta] 1 de septiembre del 2024.
- [11] (*Diabetes*, s/f) *Diabetes*. (s/f). Who.int. <https://www.who.int/es/news-room/fact-sheets/detail/diabetes>. [consulta] 1 de septiembre del 2024.
- [12] (de Sanidad et al., s/f) de Sanidad, su E. y. S. E. F. del A. y. C. E. el M., Igualdad, S. S. e., de las Comunidades Autónomas, R., & Científicas y profesionales, S. (s/f). *Estrategia en Diabetes*. Gob.es. https://www.sanidad.gob.es/areas/calidadAsistencial/estrategias/diabetes/docs/Estrategia_en_diabetes_del_SNS_Accesible.pdf. [consulta] 1 de septiembre del 2024.
- [14] Lee R, Wong TY, Sabanayagam C. Epidemiology of diabetic retinopathy, diabetic macular edema and related vision loss. *Eye Vis (Lond)*. 2015 Sep 30;2:17. doi: 10.1186/s40662-015-0026-2. PMID: 26605370; PMCID: PMC4657234.
- [15] (*Retinopatía diabética*, 2023) *Retinopatía diabética*. (2023, febrero 21). Mayo Clinic. <https://www.mayoclinic.org/es/diseases-conditions/diabetic-retinopathy/symptoms-causes/syc-2037161>. [consulta] 1 de septiembre del 2024.
- [16] (*Clinica y Anatomía Patológica de la Nefropatía Diabética*, s/f) *Clinica y Anatomía Patológica de la Nefropatía Diabética*. (s/f). Nefrologiaaldia.org. <https://www.nefrologiaaldia.org/es-articulo-clinica-y-anatomia-patologica-de-la-nefropatia-diabetica-372>. [consulta] 1 de septiembre del 2024.
- [17] Bansal V, Kalita J, Misra UK. Diabetic neuropathy. *Postgrad Med J*. 2006 Feb;82(964):95-100. doi: 10.1136/pgmj.2005.036137. PMID: 16461471; PMCID: PMC2596705.
- [18] (*Nefropatía diabética (enfermedad renal)*, 2023) *Nefropatía diabética (enfermedad renal)*. (2023, diciembre 30). Mayo Clinic. <https://www.mayoclinic.org/es/diseases-conditions/diabetic-nephropathy/symptoms-causes/syc-20354556>. [consulta] 1 de septiembre del 2024.
- [19] (Isea et al., 2012) Isea, J., Viloria, J. L., Ponte N, C. I., & Gómez M, J. R. (2012). Complicaciones macrovasculares de la diabetes mellitus: cardíacas, vasculocerebrales y enfermedad arterial periférica. *Revista de la Sociedad venezolana de endocrinología y metabolismo*, 10, 96–110. http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S1690-31102012000400013. [consulta] 1 de septiembre del 2024.
- [20] (Vinocour Fornieri & Tortós Guzmán, 2002) Vinocour Fornieri, M. V., & Tortós Guzmán, J. E. (2002). Diabetes Mellitus, una enfermedad cardiovascular. *Revista costarricense de cardiología*, 4(1), 36–44. https://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S1409-41422002000100008. [consulta] 1 de septiembre del 2024.
- [21] (“Enfermedad arterial periférica”, 2005) Enfermedad arterial periférica. (2005). *Blood, Heart and Circulation*. <https://medlineplus.gov/spanish/peripheralarterialdisease.html>. [consulta] 1 de septiembre del 2024.
- [22] Thiruvoipati T, Kielhorn CE, Armstrong EJ. Peripheral artery disease in patients with diabetes: Epidemiology, mechanisms, and outcomes. *World J Diabetes*. 2015 Jul 10;6(7):961-9. doi: 10.4239/wjd.v6.i7.961. PMID: 26185603; PMCID: PMC4499529.
- [23] Dilworth L, Facey A, Omoruyi F. Diabetes Mellitus and Its Metabolic Complications: The Role of Adipose Tissues. *Int J Mol Sci*. 2021 Jul 16;22(14):7644. doi: 10.3390/ijms22147644. PMID: 34299261; PMCID: PMC8305176.

- [24] (Brutsaert, s/f) Brutsaert, E. F. (s/f). *Cetoacidosis diabética*. Manual MSD versión para profesionales. <https://www.msmanuals.com/es-es/professional/trastornos-endocrinológicos-y-metabólicos/diabetes-mellitus-y-trastornos-del-metabolismo-de-los-hidratos-de-carbono/cetoacidosis-diabética>. [consulta] 1 de septiembre del 2024.
- [25] (Brutsaert, s/f-b) Brutsaert, E. F. (s/f-b). *Estado hiperglucémico hiperosmolar*. Manual MSD versión para profesionales. <https://www.msmanuals.com/es-es/professional/trastornos-endocrinológicos-y-metabólicos/diabetes-mellitus-y-trastornos-del-metabolismo-de-los-hidratos-de-carbono/estado-hiperglucémico-hiperosmolar>
- [26] (Shukla & Tripathy, 2023) Shukla, U. V., & Tripathy, K. (2023). *Diabetic Retinopathy*. StatPearls Publishing.
- [27] (*Diabetes y enfermedad ocular*, s/f) *Diabetes y enfermedad ocular*. (s/f). Medlineplus.gov. <https://medlineplus.gov/spanish/ency/article/001212.htm>. [consulta] 1 de septiembre del 2024.
- [28] (Castillo-Otí et al., 2020) Castillo-Otí, J. M., Cañal-Villanueva, J., García-Unzueta, M. T., Galván-Manso, A. I., Callejas-Herrero, M. R., & Muñoz-Cacho, P. (2020). Prevalencia y factores de riesgo asociados a la retinopatía diabética en Santander. Norte de España. *Atencion primaria*, 52(1), 29–37. <https://doi.org/10.1016/j.aprim.2018.10.001>. [consulta] 1 de septiembre del 2024.
- [29] (Desarrollo, 2021) Desarrollo, E. D. (2021, marzo 22). *Retinopatía en personas con diabetes - Asociación Diabetes Madrid*. Asociación Diabetes Madrid. <https://diabetesmadrid.org/retinopatia-en-personas-con-diabetes/>. [consulta] 1 de septiembre del 2024.
- [30] (*Retinopatía diabética*, 2015) *Retinopatía diabética*. (2015, abril 8). Novovisión. <https://www.clinicasnovovision.com/problemas-oculares/retinopatia-diabetica/>. [consulta] 1 de septiembre del 2024.
- [31] Corcóstegui B, Durán S, González-Albarrán MO, Hernández C, Ruiz-Moreno JM, Salvador J, Udaondo P, Simó R. Update on Diagnosis and Treatment of Diabetic Retinopathy: A Consensus Guideline of the Working Group of Ocular Health (Spanish Society of Diabetes and Spanish Vitreous and Retina Society). *J Ophthalmol*. 2017;2017:8234186. doi: 10.1155/2017/8234186. Epub 2017 Jun 14. PMID: 28695003; PMCID: PMC5488240.
- [32] (*Artículo Oftalmología_18468*, s/f) *Artículo Oftalmología_18468*. (s/f). Annalsoftalmologia.com. http://www.annalsoftalmologia.com/imprimir.php?id_articulo=18468. [consulta] 1 de septiembre del 2024.
- [33] (Aliseda & Berástegui, 2008) Aliseda, D., & Berástegui, L. (2008). Retinopatía diabética. *Anales del sistema sanitario de Navarra*, 31, 23–34. https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272008000600003. [consulta] 1 de septiembre del 2024.
- [34] (*Retinopatía diabética*, 2023) *Retinopatía diabética*. (2023, febrero 21). Mayo Clinic. <https://www.mayoclinic.org/es/diseases-conditions/diabetic-retinopathy/diagnosis-treatment/drc-20371617>. [consulta] 1 de septiembre del 2024.
- [35] (*Oftalmoscopia*, s/f) *Oftalmoscopia*. (s/f). Medlineplus.gov. <https://medlineplus.gov/spanish/ency/article/003881.htm>. [consulta] 1 de septiembre del 2024.
- [36] (Central Ocular, 2024) Central Ocular. (2024, agosto 20). *Retinografía: Qué es y cuando está indicada*. Central Ocular Clínica Oftalmológica. <https://www.centralocular.com/que-es-una-retinografia-cuando-esta-indicada-diferencias-con-angiografia/>. [consulta] 1 de septiembre del 2024.
- [37] (*Angiografía con fluoresceína*, s/f) *Angiografía con fluoresceína*. (s/f). Medlineplus.gov. <https://medlineplus.gov/spanish/ency/article/003846.ht>. [consulta] 1 de septiembre del 2024.
- [38] (S/f). Genocat.cat. https://aquas.genocat.cat/web/_content/minisite/aquas/publicacions/2023/efectividad-cribado-retinopatia-diabetica-teleoftalmologia-redets-aquas2023.pdf. [consulta] 1 de septiembre del 2024.
- [39] (Nowak, 2024) Nowak, S. (2024, marzo 21). *¿Qué es Machine Learning?* Nuclio Digital School. <https://nuclio.school/blog/que-es-machine-learning/>. [consulta] 1 de septiembre del 2024.
- [40] (S/f-b). Scoft.cat. https://www.scoft.cat/pdfs/Revista-Annals-Oftalmologia_CDS_2023_low.pdf. [consulta] 1 de septiembre del 2024.
- [41] (de los Santos, 2021) de los Santos, P. R. (2021, diciembre 2). Tipos de aprendizaje en Machine Learning: supervisado y no supervisado. *Telefónica Tech*. <https://telefonicatech.com/blog/que-algoritmo-elegir-en-ml-aprendizaje>. [consulta] 1 de septiembre del 2024.
- [42] (intelliverso.com, 2023) intelliverso.com. (2023, octubre 27). *Machine Learning: descubre que es el aprendizaje automático y su funcionamiento*. Tess Annushka. <https://intelliverso.com/inteligencia-artificial/tipos-de-aprendizaje-automatico-supervisado-no-supervisado-y-por-refuerzo/>. [consulta] 1 de septiembre del 2024.
- [43] (*Tipos de aprendizaje automático*, 2018) *Tipos de aprendizaje automático*. (2018, mayo 26). Machinelearningparatodos.com. <https://machinelearningparatodos.com/tipos-de-aprendizaje-automatico/>. [consulta] 1 de septiembre del 2024.
- [44] Fukushima, Kunihiko (1980). "Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position". *Biological Cybernetics* 36 (4): 193–202.
- [45] Ciresan, Dan; Ueli Meier; Jonathan Masci; Luca M. Gambardella; Jurgen Schmidhuber (2011). "Flexible, High Performance Convolutional Neural Networks for Image Classification". *Proceedings of the Twenty-Second international joint conference on Artificial Intelligence-Volume Volume Two* 2: 1237–1242.
- [46] (*Redes Neuronales Convolucionales: Aplicaciones en Procesamiento de Imágenes*, 2023) *Redes Neuronales Convolucionales: Aplicaciones en Procesamiento de Imágenes*. (2023, agosto 4). Data Universe. <https://data-universe.org/redes-neuronales-convolucionales-aplicaciones-en-procesamiento-de-imagenes/>. [consulta] 1 de septiembre del 2024.