

María Guadalupe Hernández Ramírez

Metodología para la detección oportuna de retinopatía hipertensiva mediante la medición automática del calibre de los vasos retinianos

2021



Universidad Autónoma de Querétaro
Facultad de Ingeniería

Metodología para la detección oportuna de retinopatía hipertensiva mediante la medición automática del calibre de los vasos retinianos

Tesis

Que como parte de los requisitos para obtener el grado Maestro en Ciencias en Inteligencia Artificial

Presenta

María Guadalupe Hernández Ramírez

Dirigido por:

Dr. Saul Tovar Arriaga

Co-Dirigido por:

Dra. Renata García Franco

Querétaro, Qro. a Abril, 2021



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Ciencias en Inteligencia Artificial

Metodología para la detección oportuna de retinopatía hipertensiva mediante la medición automática del calibre de los vasos retinianos en su emergencia en el nervio óptico

TESIS

Que como parte de los requisitos para obtener el grado de
Maestro en Ciencias en Inteligencia Artificial

Presenta:

Ing. María Guadalupe Hernández Ramírez

Dirigido por:

Dr. Saúl Tovar Arriaga

Co-Dirigido por:

Dra. Renata García Franco

SINODALES

Dr. Saúl Tovar Arriaga

Presidente

Dra. Renata García Franco

Secretario

Dr. Jesús Carlos Pedraza Ortega

Vocal

Dr. Manuel Toledano Ayala

Suplente

Dra. Stéphanie C. Thébault

Suplente

Centro Universitario, Querétaro, QRO

México.

Diciembre 2020

Dirección General de Bibliotecas de la UAQ

Esta tesis es dedicada a mi familia

Agradecimientos

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACYT) por proveer los fondos para esta investigación y mi formación como maestra en ciencias. De igual modo se agradece a la Universidad Autónoma de Querétaro y a la dirección de Investigación y Posgrado de la Facultad de Ingeniería por su valioso apoyo y proveer las facilidades para mi formación como estudiante de posgrado, así como a todos mis profesores en los cuales encontré el apoyo y el conocimiento para mi desarrollo académico, especialmente al Dr. Saul Tovar Arriaga por haber sido mi director de tesis. El presente trabajo no hubiera sido posible sin la idea y el apoyo de la Dra. Renata Garcia Franco y todo el equipo del Instituto de la Retina del Bajío. Por ultimo agradezco a mi familia y a Víctor Manuel Martínez Suárez, este logro es también de ustedes, sin su apoyo incondicional no hubiera sido posible superar este reto.

Abstract

The retina is the only organ that allows the study of blood vessels changes in a non-invasive manner. Hypertensive retinopathy can be seen in retina-fundus images, in its different degrees, being grade-one the most difficult to detect. Since the retina changes are minimal, the measurement of arteries narrowing, identified with a change in the artery-vein ratio (AVR), can be challenging. In recent years, deep neural networks have obtained the best results in classifying and segmenting medical images. A modified U-Net is proposed in this work, with bidirectional ConvLSTM blocks for artery and vein classification in fundus images. Instead of concatenating U-Net blocks, bidirectional ConvLSTM's are used to combine the extracted feature maps, which helps to keep essential characteristics that otherwise will be lost. Additionally, the use of two U-Net blocks makes training less time-consuming. We evaluated the proposed model using the DRIVE database, achieving competent performance compared to existing methods.

For additional experimentation, a database with 60 fundus images, 30 images of healthy people, and 30 images of hypertensive people was designed, where each vessel was manually labeled as vein or artery. For computing the AVR, we proposed a method that initially localizes the optic disc from the image and an algorithm to measure each vessel caliber. It was tested with the INSPIRE database, where the AVR measurements exceed those found in the literature. The final AVR results show us an average of an AVR of 0.55 in hypertensive people and an average of 0.65 in healthy people. (**Keywords:** Convolutional Neural Networks, Prediction, Hypertensive Retinopathy, Artery / Vein Ratio, Vessel Classification, ConvLSTM.)

Resumen

La retina es el único órgano que permite el estudio de los cambios en los vasos sanguíneos de forma no invasiva. La retinopatía hipertensiva se puede observar en imágenes de fondo de ojo, en sus diferentes grados, siendo el grado uno el más difícil de detectar. Dado que los cambios en la retina son mínimos, la medición del estrechamiento de las arterias, identificado con un cambio en la relación arteria-vena (AVR), puede ser un desafío. En los últimos años, las redes neuronales profundas han obtenido los mejores resultados en la clasificación y segmentación de imágenes médicas. En este trabajo se propone una U-Net modificada, con bloques ConvLSTM bidireccionales para la clasificación de arterias y venas. En lugar de concatenar bloques U-Net, se utilizan ConvLSTM bidireccionales para combinar los mapas de características extraídos, lo que ayuda a mantener las características esenciales que de otro modo se perderían. Evaluamos el modelo propuesto utilizando la base de datos DRIVE, logrando un desempeño competente en comparación con los métodos existentes. Para experimentación adicional, se diseñó una base de datos con 60 imágenes de fondo de ojo, 30 imágenes de personas sanas y 30 imágenes de personas hipertensas, donde cada vaso se etiquetó manualmente como vena o arteria. Para calcular el AVR, propusimos un método que inicialmente localiza el disco óptico de la imagen y un algoritmo para medir el calibre de cada vaso. Fue probado con la base de datos INSPIRE, donde las medidas de AVR superan las encontradas en la literatura. Los resultados finales de AVR nos muestran una media de un AVR de 0,55 en personas hipertensas y una media de 0,65 en personas sanas. (**Palabras Clave:** Redes Neuronales Convolucionales, Predicción, Retinopatía hipertensiva, Relación Arteria/Vena, Clasificación de vasos, ConvLSTM)

Abreviaturas y siglas

AVR - Arteriolar to Venular Relationship - Relación arteria y vena

CLAHE - Contrast Limited Adaptive Histogram Equalization - Ecuación de histograma adaptativo de contraste limitado

CNN - Convolutional Neural Network - Redes neuronales convolucionales

ConvLSTM - Convolutional Long Short Term Memory - Memoria a corto plazo convolucional

CRAE - Central Retinal Artery Equivalent - Equivalente de la arteria central de la retina

CRVE - Central Retinal Vein Equivalent - Equivalente de la vena central de la retina

DRIVE - Digital Retinal Images for Vessel Extraction - Imágenes digitales de retina para extracción de vasos

ECV - Enfermedades Cardiovasculares

ELU - Exponential Linear Unit - Unidad Lineal Exponencial

ENSANUT - Encuesta Nacional de Salud y Nutrición de Medio Camino

FN - False Negative - Falso Negativo

FOV - Field Of View - Campo de visión

FP - False positive - Falso positivo

GPU - Graphics Processing Unit - Unidad de procesamiento gráfico

IA - Inteligencia Artificial

INDEREB - El instituto de la Retina del Bajío

INSPIRE - Iowa Normative Set for Processing Images of the Retina - Conjunto normativo de Iowa para el procesamiento de imágenes de la retina

IVAN - Integrative Vessel Analysis - Análisis integral vasos

LSTM - Long Short Term Memory - Memoria a corto plazo

OD - Optical Disc - Disco Optico

PR - Precision Recall - Precisión Recuperación

ReLU - Rectified Linear Units - Unidad Lineal Rectificada

RGB - Red Green Blue - Rojo Verde Azul

ROC - Receiver Operating Characteristic - Característica Operativa del Receptor

ROI - Region Of interest - Región de interés

TN - True Negative - Verdadero Negativo

TP - True Positive - Verdadero Positivo

WHF - World Heart Federation - Federación Mundial del Corazón

WHO - World Health Organization - Organización Mundial de la Salud

Dirección General de Bibliotecas de la UAQ

Índice general

Agradecimientos	II
Abstract	III
Resumen	IV
Abreviaturas y siglas	v
1. Introducción	1
1.1. Hipertensión	1
1.2. Retinopatía hipertensiva	2
1.3. Descripción del problema	4
1.4. Justificación	5
1.5. Hipótesis	7
1.6. Objetivos	7
1.6.1. Objetivo general	7
1.6.2. Objetivos particulares	7
2. Antecedentes.	8
2.1. Estado del arte	8
2.2. Historia de la inteligencia Artificial	12
2.3. Aprendizaje de automático	14

2.3.1.	Aprendizaje profundo	15
2.4.	Redes neuronales artificiales	16
2.5.	Redes neuronales convolucionales (CNN)	18
2.5.1.	Capa de entrada	20
2.5.2.	Capa convolucional	20
2.5.3.	Capa de agrupación	22
2.5.4.	Capa completamente conectada	22
2.6.	Red neuronal recurrente (RNN)	23
2.6.1.	Red neuronal de memoria a corto plazo LSTM	23
2.7.	Hiperparámetros	24
2.7.1.	Funciones de activación	24
2.7.2.	Optimizador	30
3.	Metodología	31
3.1.	Adquisición de imágenes	31
3.1.1.	Base de datos DRIVE	33
3.1.2.	Base de datos INSPIRE-AVR	34
3.1.3.	Base de datos propia	34
3.2.	Procesamiento de imagen	37
3.2.1.	Normalización de datos	38
3.2.2.	Corrección de contraste	38
3.2.3.	Corrección de brillo	39
3.3.	Segmentación y clasificación de vasos sanguíneos.	40
3.3.1.	Aumento de datos.	40
3.3.2.	Arquitectura para la clasificación de vasos.	40
3.3.3.	LSTM	42
3.4.	Ejecución del algoritmo.	42
3.5.	Detección de disco óptico y determinación del ROI	43
3.6.	Medición del calibre de los vasos.	44

3.7. Calculo de la relación arteria y vena (AVR)	51
3.8. Diagnostico de retinopatía hipertensiva	55
4. Resultados y Discusión	56
4.1. Resultados de clasificación de vasos mediante la CNN	56
4.1.1. Métricas de evaluación.	56
4.1.2. Resultados Clasificación de vasos retinianos	57
4.2. Resultados de la detección de disco óptico	61
4.3. Resultados del algoritmo para la medición del calibre	62
4.4. Resultados de la medición del AVR	62
4.4.1. Medición del AVR en la base de datos DRIVE	62
4.4.2. Medición del AVR en la base de datos INSPIRE	63
4.4.3. Medición del AVR en la base de datos creada	65
5. Conclusiones y trabajo futuro	71
5.1. Trabajos futuros	73
Referencias	74
Apéndices	80
5.2. Anexos	80
5.2.1. Clasificación de todas las imágenes de la base de datos DRIVE	80
5.2.2. Artículo publicado	89
5.2.3. Requisito de manejo de la lengua inglesa	91

Índice de figuras

1.1. Imagen sana de fondo de ojo.	2
2.1. Relacion de IA, aprendizaje automático y aprendizaje profundo. Imagen propia. . .	15
2.2. Relacion de aprendizaje automático y aprendizaje profundo. Imagen propia	16
2.3. Comparación entre una neurona artificial y una natural. Imagen propia	17
2.4. Estructura de Red neuronal básica. Imagen propia	18
2.5. Arquitectura general de CNN. Imagen propia	19
2.6. Operación de convolución. Imagen propia.	21
2.7. Función de activación lineal. Imagen propia.	25
2.8. Función de activación ReLU. Imagen propia.	26
2.9. Función de activación sigmoide. Imagen propia.	27
2.10. Función de activación Sofplus. Imagen propia.	27
2.11. Función de activación ELU. Imagen propia.	28
2.12. Función de activación SELU. Imagen propia.	29
3.1. Metodología propuesta para definir los hiperparámetros y entrenar el clasificador de A/V. Imagen propia.	32
3.2. Ejemplos de imágenes de base de Datos DRIVE en la primera columna se muestran la imagen original, en la segunda la imagen segmentada y por ultimo en la tercera las imágenes clasificadas por Qureshi.	33

3.3. Ejemplos de imagen de base de Datos INSPIRE con sus mediciones de AVR hechas por dos expertos utilizando IVAN.	34
3.4. Imágenes de base de datos creada, el primer renglón muestra 3 imágenes de personas sanas, el segundo renglón muestra 3 imágenes de personas hipertensas.	36
3.5. Preprocesamiento con filtro CLAHE para mejorar la diferencia entre vena de arteria.	36
3.6. Clasificación manual de imágenes de la base de datos creada, en la primera columna se muestran las imágenes originales y en la segunda se muestra la clasificación. .	37
3.7. Aplicación de filtro CLAHE	39
3.8. Resultado de preprocesamiento de imagen. A la izquierda imagen original; a la derecha imagen preprocesada.	40
3.9. Ejemplo de extracción de parches. Dos filas superiores imágenes; dos filas inferiores etiquetas.	41
3.10. Arquitectura propuesta.	42
3.11. Proceso de detección del disco óptico: a) imagen original, b) canal verde, c) canal cyan, d) canal verde - cyan	44
3.12. Imagen etiquetada con las diferentes áreas de interés.	45
3.13. Visualización del cálculo de calibre de cada vaso.	48
3.14. Demostración de vasos colocados en los cuatro cuadrantes.	49
3.15. Demostración del cálculo del incremento en el eje x.	50
3.16. Detalle de una fotografía de fondo de ojo donde se muestran los distintos diámetros tomados para calcular el AVR.	54
4.1. Resultado de clasificación de arteria y vena de dos imágenes. Iniciando con la primera a la izquierda, imagen original; segunda imagen, preprocesamiento; tercera imagen verdad fundamental; última imagen salida clasificada	58
4.2. Rendimiento de segmentación A / V en DRIVE.	58
4.3. curva Precision-Recall para segmentación A / V en DRIVE.	59
4.4. Errores de clasificación de arteria y vena.	60
4.5. Detección de disco óptico en base propia.	61

4.6. Medición del calibre de los vasos de manera perpendicular.	62
4.7. Imágenes con AVR menor a 0.66	63
4.8. Gráfico de Bland-Altman entre el promedio de los dos observadores y el resultado del sistema propuesto.	67
4.9. Gráfico de Bland-Altman entre el promedio de los dos observadores y la bibliografía de referencia.	67

Dirección General de Bibliotecas de la UAQ

Índice de tablas

1.1. Lesiones comunes en retinopatía hipertensiva	3
4table.caption.16	
2.1. Algunos métodos de segmentación de vasos retinianos y clasificación A/V	10
2.2. Tabla de verdad de la compuerta lógica XOR.	13
3.1. AVR normal en los diferentes grados de retinopatía hipertensiva.	55
4.1. Comparación de resultados de clasificación Vena/Arteria con estado del arte en base de datos DRIVE.	60
4.2. Resultados AVR de base de datos DRIVE	64
4.3. Comparación de resultados de AVR de base de datos INSPIRE	66
4.4. AVR de personas diagnosticadas como hipertensas de la base de datos creada	69
4.5. AVR de personas diagnosticadas como sanas de la base de datos creada	70

Introducción

1.1. Hipertensión

La hipertensión tiene efectos profundos en la estructura y función del ojo. Las circulaciones de los nervios retinianos, coroideo y óptico experimentan una serie de cambios fisiopatológicos en respuesta a la presión arterial elevada, teniendo como resultado una serie de signos clínicos llamados retinopatía hipertensiva. (Wong y McIntosh, 2005) La hipertensión es un factor de riesgo importante para el desarrollo de enfermedades vasculares del ojo, de las cuales muchas de ellas pueden causar ceguera, y podría ser un factor patógeno para las enfermedades oculares no vasculares, incluidas dos de las principales causas de ceguera como el glaucoma y la degeneración macular relacionada con la edad (Wong, Ming, Cheung, Larsen, y Sharma, 2016). Uno de los hallazgos asociados a la hipertensión en las imágenes del fondo de ojo es el estrechamiento arteriolar, que puede evaluarse mediante las relaciones de diámetro arteriolar a venular (AVR).

En la Figura 1.1 se muestra una imagen en condición sana del fondo de ojo donde se pueden ver sus partes más importantes, como el nervio óptico que es donde se centrará el estudio de este trabajo. En el área del nervio óptico se puede ver las arterias y venas principales, identificando las venas por un color más oscuro al de las arterias. Las venas normalmente tienen un calibre mayor al de las arterias, teniendo una relación AVR normal de 2:3 (Brunekreef y Holgate, 2002).

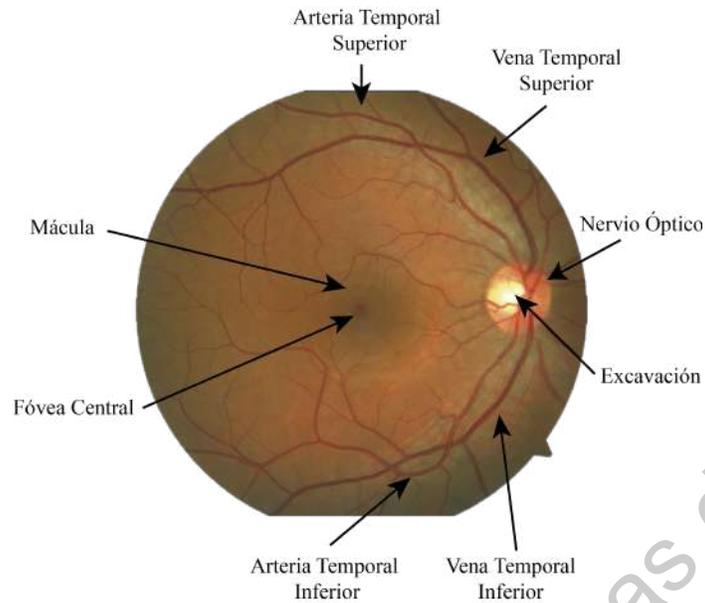


Figura 1.1: Imagen sana de fondo de ojo.

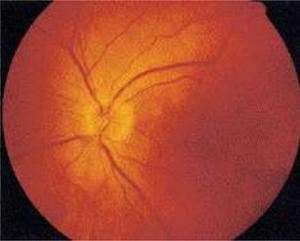
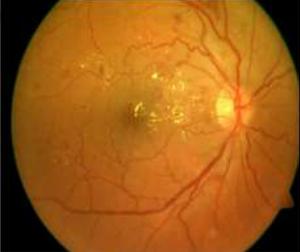
1.2. Retinopatía hipertensiva

La retinopatía hipertensiva se usa como un término global para todos los cambios del fondo de ojo causados por la presión arterial elevada que indica un daño en el órgano terminal. En la tabla 1.1 se muestran diferentes lesiones que se pueden encontrar en retinopatía hipertensiva (Tso y Jampol, 1982) (Tsukikawa y Stacey, 2020).

Una de las principales anomalías en la retinopatía hipertensiva es el estrechamiento de vasos retinianos generalizado y el cruce arteriovenoso patológico. Estos están relacionados no solo con los niveles actuales de presión arterial del paciente, sino también con los niveles medidos en el pasado, lo que sugiere que estos signos son marcadores persistentes de daño hipertensivo crónico (Leung et al., 2004), (Sharrett et al., 1999).

Por el contrario, el estrechamiento arteriolar focal, las hemorragias retinianas, los microaneurismas y las manchas de algodón se han asociado solo con la presión arterial medida de forma concurren-

Tabla 1.1: Lesiones comunes en retinopatía hipertensiva

Nombre	Descripción	Descripción gráfica
Estrechamiento de vasos.	La relación arteriola a vénula que normalmente es de 2/3 disminuye. (Wong et al., 2001)	
Hemorragias.	Pequeñas manchas de sangre que entran a las diferentes capas de la retina. (Giancardo et al., 2010)	
Exudados duros.	Es extravasación o engrosamiento de la mácula a causa de escapes de líquido de los vasos sanguíneos de la retina. (Zachariah, Wykes, y Yorston, 2016)	
Manchas de algodón.	Son áreas focales de opacidad retiniana color blanco esponjoso de forma irregular que oscurecen los vasos sanguíneos subyacentes (Reddy, Jain, Yadav, Sharma, y Bhatia, 2014)	

te, por lo que podrían representar cambios transitorios en la presión arterial (Wong et al., 2001). El estrechamiento de vasos sanguíneos también se puede usar para predecir el desarrollo posterior de la hipertensión en individuos clasificados inicialmente como normotensos, es decir el estrechamiento podría ser un marcador temprano de hipertensión manifiesta (Leung et al., 2004).

Existen diferentes propuestas para la clasificación de retinopatía hipertensiva, una de ellas es la

clasificación de Keith – Wagener – Barker (Keith, Wagener, y Barker, 1974), que propone 4 grupos de retinopatía hipertensiva como se muestra en la tabla 1.2.

Tabla 1.2: Clasificación retinopatía hipertensiva (Keith et al., 1974)

Grado	Hallazgos oftalmológicos observables	Clasificación sistémica
Grupo 1.	Estrechamiento leve a moderado o esclerosis de las arteriolas.	Presión controlable.
Grupo 2.	Estrechamiento moderado a marcado de las arteriolas. Estrechamiento local y/o generalizado de las arteriolas. Exageración del reflejo de la luz. Cruce arteriovenoso de cambio.	Hipertensión con un órgano dañado.
Grupo 3.	Estrechamiento arterial retiniano y constricción focal. Edema retiniano. Manchas de algodón. Hemorragias.	Hipertensión con más de dos órganos dañados.
Grupo 4.	Grupo 3 más papiledema.	Neuroretinopatía.

1.3. Descripción del problema

El fondo del ojo proporciona diferente información sobre la salud del ser humano, como problemas oculares o problemas de enfermedades crónicas, además de ser la única forma accesible para la visualización no invasiva del sistema cardiovascular. Esto es posible mediante la obtención de imágenes con cámaras digitales de fondo de ojo, por lo cual el fondo de ojo es un medio para estudiar cambios de las características que se hacen presentes en este tejido. Los cambios en las diferentes estructuras del fondo de ojo ocurren debido a diferentes factores, desde procesos normales como el envejecimiento hasta condiciones como la diabetes, las anomalías cardiovasculares y el hábito de fumar. Estos factores pueden provocar cambios anormales en los diámetros de los vasos, apareciendo primero en los vasos más pequeños. Los primeros cambios que se presentan son difícil de distinguir a simple vista ya que la diferencia a comparación del estado normal es

muy poca, como lo es el cambio en la relación arteria y vena (Nguyen, Wang, y Wong, 2007).

Actualmente existen características diagnósticas para varias enfermedades, como la retinopatía hipertensiva, enfermedad coronaria, degeneración macular, pero existen otros patrones que aún no tienen clasificación y podrían llegar a dar información valiosa de la salud del paciente.

Otro uso importante de la información que es visible en las imágenes del fondo de la retina se puede usar para clasificar la gravedad de la enfermedad o como parte del proceso de diagnóstico automatizado de enfermedades en temprana etapa. El tratamiento más efectivo para muchas enfermedades relacionadas con la vista es la detección temprana a través de exámenes regulares.

Algunos patrones son difíciles de detectar a simple vista, como la retinopatía hipertensiva en grado uno, ya que el único cambio visible es un estrechamiento de arterias. Para que un oftalmólogo pueda detectar este cambio, que se da por una disminución de la relación arteria y vena (AVR), es indispensable el uso de diferentes programas de edición de imágenes. La exactitud usando este métodos para el calculo del AVR no es buena, se tienen resultados con errores e imposible de crear marcadores que relacionen estas medidas con anomalías.

En los últimos años se están desarrollando sistemas de detección basados diferentes tecnologías, como redes neuronales y procesamiento de imagen, que ofrecen una solución eficaz a los problemas de imágenes médicas. Estos métodos conllevan otros problemas, como lo es la falta de datos etiquetados o el desvélnse de clases, ya que de una imagen de retina el 93% es fondo negro y solo el 7% son vasos. Por ello desarrollar una metodología basada en redes neuronales convolucionales ayudará a agilizar el proceso de detección oportuna de retinopatía hipertensiva.

1.4. Justificación

Según la WHO por sus siglas en inglés (World Health Organization) la principal causa actual de muerte a nivel mundial es por enfermedades cardiovasculares (ECV), desde el año 2000 con un incrementó el 40% desde el 2000 hasta 2017. Las enfermedades cardiovasculares afectan en

mucha mayor medida a los países de ingresos bajos y medianos: más del 80 % de las defunciones por esta causa se producen en esos países (WHF, 2019). Actualmente la World Heart Federation (WHF) estima que las ECV son la causa de 17.5 millones de muertes en todo el mundo al año, representando 31 % de muertes. Los principales factores de riesgo para las ECV son: hipertensión, tabaquismo, obesidad y sobrepeso e inactividad física (WHF, 2019).

México es el país con el índice más alto de hipertensión arterial en el mundo debido a la falta de un diagnóstico oportuno y al desconocimiento de los factores de riesgo que pueden detonar que se eleve la presión arterial. Uno de cada cuatro mexicanos adultos padecen esta enfermedad, 25.5% de la población mexicana de acuerdo con la Encuesta Nacional de Salud y Nutrición de Medio Camino 2016 (INSP, 2016). El grupo de adultos que presentan hipertensión es el de 20 a 80 años, teniendo una prevalencia alta en el grupo de 70 a 80 años. De las personas evaluadas el 40 de la población no contaba con conocimiento previo que padecía esta enfermedad, esto quiere decir que 4 de 10 personas fueron diagnosticadas con hipertensión al momento que la ENSANUT 2016 se llevó a cabo. De las personas que tenían un conocimiento previo de su condición 58.7% controlan su presión arterial y 78.3% está bajo tratamiento farmacológico (Instituto nacional de salud pública, 2016)

La retinopatía hipertensiva es el daño de los vasos retinianos causada por hipertensión, esta enfermedad no desarrolla síntomas hasta que está avanzada. En las fases iniciales se puede identificar con una disminución en el calibre vascular de la retina, siendo una forma no invasiva para estudiar la salud y la enfermedad de la microcirculación humana, además de acceso fácil gracias a la tecnología de cámaras fotográficas (Wong et al., 2016).

En los últimos años, el uso de redes neuronales ha mostrado avances significativos y resultados prometedores en la detección de patrones en imágenes, específicamente las redes neuronales convolucionales (CNN). Las CNN han sido convenientes para la clasificación y segmentación de imágenes.

1.5. Hipótesis

Una metodología basada en técnicas de Inteligencia Artificial y procesamiento de imágenes permite la medición del calibre de vasos retinianos en imágenes de fondo de ojo que diferencie a personas con hipertensión temprana de personas sanas.

1.6. Objetivos

1.6.1. Objetivo general

Desarrollar una metodología que permita la detección oportuna de retinopatía hipertensiva a partir de un modelo matemático de medición del calibre de los vasos retinianos.

1.6.2. Objetivos particulares

- Seleccionar una bases de datos de imágenes públicas de retina adecuadas para el desarrollo del proyecto.
- Realizar una base de datos con imágenes de retina de personas sanas y personas hipertensas.
- Procesar las imágenes elegidas para resaltar características buscadas en imagen de fondo de ojo utilizando algoritmos inteligentes.
- Segmentar las imágenes para la medición del calibre de venas y arterias centrales de la retina en su emergencia y ramas.
- Identificar la morfología normal y anormal de los vasos retinianos en la emergencia del nervio óptico de los diferentes grupos de personas.
- Diseñar, implementar y evaluar una metodología que permita la detección oportuna de retinopatía hipertensiva utilizando imágenes con problemática conocida para evaluar la eficiencia.

Antecedentes.

2.1. Estado del arte

Se han propuesto diferentes métodos para la segmentación de vasos retinianos y la medición de sus calibres utilizando diferentes métodos computacionales con la finalidad de tener mediciones confiables. Estos estudios han demostrado ser un buen camino para la detección de anomalías en el calibre de los vasos de la retina. Los métodos de clasificación RAV generalmente se basan en una combinación de características de la bifurcación, principalmente el color del píxel y las restricciones de conectividad para asignar una de las dos etiquetas a cada segmento de la bifurcación.

(Ruggeri, Tramontan, y Grisan, 2008) desarrollaron un sistema para calcular el AVR en el cual las imágenes se mejoran al inicio para resaltar la red de vasos, que luego se rastrea mediante un algoritmo de seguimiento de vasos. A partir de la estructura del vaso detectado, se deriva la posición del disco óptico y se determina la región dentro de la cual se medirán los datos del AVR. Los vasos dentro de esta región se clasifican como arterias o venas, su calibre se estima y el parámetro AVR se calcula finalmente. Los resultados de 20 imágenes del fondo de ojo dieron un coeficiente de correlación final de 0,88.

(Muramatsu et al., 2011) proponen un método de segmentación en dos etapas (estimación de

probabilidad y predicción dirigida) que combinan tanto el muestreo como el procesamiento basado en parches. Su enfoque aprovecha las funciones de pérdida con pesos estocásticos para detectar mejor los píxeles de vasos vagos y ambiguos. En la primera mitad, entrenan una arquitectura U-net para estimar la probabilidad del vaso de cada píxel, asignan aleatoriamente un peso a cada clase en cada iteración de entrenamiento, lo que obliga a la red a alternar entre tasas de falsos positivos más altas durante el entrenamiento, lo que evita que se atasque en un solo mínimo local. En la segunda mitad se aplica una mini-U-net, es una versión reducida de la red utilizada en la primera etapa. Se utilizan 5 bases de datos para la segmentación de vasos: DRIVE con 40 imágenes, STARE con 20 imágenes, AV-WIDE con 30 imágenes, VEVIO con 16 imágenes y CHASE-DB con 14 pares de imágenes.

(Mirsharif, Tajeripour, y Pourreza, 2013) utilizan un método de selección de características para seleccionar las funciones más discriminantes para entrenar un clasificador. En la clasificación se aplica un proceso de extracción de características específicas para separar las arterias principales de las venas, las características se extraen de los píxeles del centro de cada vaso, estos ya tienen una etiqueta que se propaga por todo el segmento del vaso debido a que las características del píxel consecutivo no cambia mucho. Para la etiqueta del vaso se usa el color diferente de la arteria y vena, este método fue desarrollado con la base de datos DRIVE, utilizando 40 imágenes y su propio conjunto de datos (13 imágenes de la retina) logrando una precisión del 90.2 y 88.2 para cada conjunto de datos respectivamente.

(Dasgupta y Singh, 2017) proponen un método de segmentación como una tarea de inferencia de etiquetas múltiples y propone un modelo basado en una CNN. El modelo logra para la segmentación automática de los vasos sanguíneos de la retina en el conjunto de datos DRIVE con una precisión de 95.33. Guo en el 2019, también propone un método basado en una red neuronal convolucional obteniendo una precisión del 96 y una sensibilidad del 75 con la base de datos DRIVE.

En 2019 Khanal propone un método compuesto por extracción de vasos, detección de discos

ópticos, clasificación de vasos, selección de vasos y medición de diámetros. El método selecciona dos pares de vasos principales en las regiones temporales superior e inferior. A diferencia de promediar los diámetros de varios vasos, la selección de un par de vasos puede potencialmente detectar adelgazamiento fovea, detectar cruces y utilizar una mayoría de pesos para etiquetar de manera correcta los píxeles centrales de los vasos. Se utiliza la base de datos DRIVE y se obtiene una sensibilidad del 0.87.

Tabla 2.1: Algunos métodos de segmentación de vasos retinianos y clasificación A/V

Autor	Año	Aplicación	Técnica
Ruggeri, <i>et al</i>	2008	Medición AVR.	Rastreo y discriminación.
Muramatsu, <i>et al</i>	2011	Medición y segmentación de vasos.	Extracción de características.
Mirsharif, <i>et al</i>	2013	Segmentación de vasos.	Clasificación de píxeles.
Xu, <i>et al</i>	2015	Clasificación A/V.	Estimación de topología, teoría de grafos.
Welikala, <i>et al</i>	2017	Clasificación A/V.	CNN.
Dasgupta, <i>et al</i>	2017	Segmentación de vasos.	Red neuronal convolucional.
Xu, <i>et al</i>	2017	Clasificación de vasos.	Clasificación de píxeles.
Xu <i>et al</i>	2018	Clasificación A/V.	CNN U-net.
Guo <i>et al</i>	2019	Segmentación de vasos.	Red neuronal convolucional.
Girard, <i>et al</i>	2019	Clasificación A/V y Medición AVR.	CNN adaptación U-net y árboles.

En los últimos años se han realizado investigaciones para la detección de la retinopatía hipertensiva utilizando métodos de inteligencia artificial, tales como aprendizaje profundo y SVM (Máquina de Soporte de Vectores). Estos estudios han demostrado ser un buen camino para la detección de anomalías en la retina, con un gran porcentaje de certeza.

Los métodos de clasificación de los vasos de la retina: arteria y vena, encontrados en la literatura se pueden clasificar en dos clases, en métodos basados en árboles y en características y los

más populares en los últimos años, basados en aprendizaje profundo.

En la primera clase encontramos trabajos como el de (Estrada et al., 2015) donde se utilizó un enfoque de estimación de topología basado en grafos, que estima la topología más probable para las etiquetas de arteria y de vena. Buscando posibles árboles partiendo de los píxeles etiquetados, usando algoritmos de búsqueda heurísticos. El algoritmo fue probado con 4 bases de datos: WIDE, AV-INSPIRE, AV-DRIVE, CT-DRIVE. Otro trabajo es el propuesto por (Xu, Ding, Abrámoff, y Cao, 2017) donde proponen una técnica de clasificación arteria y vena donde la imagen de retina es regularizada y normalizada para extraer múltiples características de los vasos sanguíneos. Se extraen diferentes características basadas en el color y textura para cada píxel y se clasifican en arteria y vena usando un clasificador kNN. Esta técnica fue probada en la base de datos DRIVE y logró una exactitud del 0.923.

Actualmente y gracias al poder de cómputo con el que hoy contamos y las bases de datos disponibles, los métodos más recurridos están basados en aprendizaje profundo. Un beneficio de estos modelos es su capacidad para realizar la extracción automática de características de los datos sin procesar, también llamada aprendizaje de características. Un método de esta clasificación es el propuesto por (Welikala et al., 2017) donde se propuso un método basado en el aprendizaje profundo para la clasificación de arterias y venas en toda la imagen de la retina. La red propuesta está formada por 6 capas, de las cuales 3 son capas convolucionales y 3 son capas completamente conectadas, la capa ReLU siguió a cada capa convolucional y las dos primeras capas completamente conectadas. Este método se evaluó en el conjunto de datos del biobanco del Reino Unido y en la base de datos pública DRIVE.

(Xu, Tan, y Xu, 2018) propusieron una red neuronal convolucional inspirada en la arquitectura U-net para la segmentación de venas y arterias en imágenes a color de la retina. La red fue entrenada y probada en el conjunto de datos pública DRIVE. La sensibilidad, especificidad y exactitud es de 0.870, 0.980, 0.832 respectivamente. Las tasas de clasificación errónea registradas fueron de 0.098 para venas y 0.237 para arterias. (Girard, Kavalec, y Cheriet, 2019) Proponen un método de clasificación A/V usando una CNN simple que clasificaba los píxeles en arteria y vena, la red

está compuesta de cinco capas convolucionales de codificación y cinco capas convolucionales de decodificación junto con conexiones de derivación. La arquitectura propuesta es una derivación de la U-net. Realiza un preprocesamiento a la imagen donde corrigen problemas de iluminación no uniforme, obteniendo 3 canales diferentes a los originales (RGB), concatenan los 3 canales nuevos a los 3 originales, teniendo una imagen de 6 canales. El método se probó en dos bases de datos DRIVE y MESSIDOR.

2.2. Historia de la inteligencia Artificial

Según Nils J. Nilsson la inteligencia artificial (IA) se podría definir como la actividad de desarrollar maquinas inteligentes, entendiéndose por inteligencia la cualidad que permite a una entidad funcionar apropiadamente y con conocimiento de su entorno. (Nilsson y Nilsson, 1998) La IA es una ciencia creada basada en otras áreas como informática, lógica, ciencias cognitivas, matemáticas, entre otras.

El nacimiento de la IA podría remontarse a 1943 cuando McCulloch propone un circuito booleano como modelo del cerebro, fue uno de los pioneros en el desarrollo de un modelo informático de una neurona artificial, elemento básico de una red neuronal, llamado umbral lógico (McCulloch y Pitts, 1994). En 1950 Alan Turing publico el test de Turing el cual podía lograr eficiencia a nivel humano en todas las actividades de tipo cognoscitivo, suficiente para engañar a un evaluador humano (Turing, 1950). En 1958 Frank Rosenblatt definió el perceptrón (un tipo de neurona), como un algoritmo de reconocimiento de patrones basado en una red de aprendizaje de dos capas (Rojas, 2013). Estas neuronas al ser conectadas con otras neuronas se denomina red neuronal, término que fue reportado hasta 1965 por Ivakhnenko y Lapa. En 1969 se dieron a conocer las debilidades de las redes neuronales, ya que ninguna de las redes existentes era útil para calcular predicadores esenciales como el XOR. Se dejó la investigación de redes neuronales hasta la gran evolución dada en 1986 cuando (Rumelhart, Hinton, y Williams, 1986) desarrollan el algoritmo de retropropagación, una red con más de una capa, el cual resuelve eficazmente el problema de la programación de XOR. Este proceso utiliza la diferencia entre el resultado producido y el resultado deseado para

cambiar los pesos de las conexiones entre las neuronas artificiales el cual es uno de los algoritmos más utilizados hasta el día de hoy (Rojas, 2013).

La compuerta XOR es una compuerta lógica que requiere dos entradas distintas para que su salida sea verdadera. En la Tabla 2.2 se muestra su comportamiento, teniendo como entrada las variables 'X' y 'Y'.

Tabla 2.2: Tabla de verdad de la compuerta lógica XOR.

X	Y	Salida
0	0	0
0	1	1
1	0	1
1	1	0

En 1979 se propuso el Neocognitron (Fukushima, 1979), predecesor de las redes neuronales convolucionales (CNN), el cual cuenta con una unidad convolucional. En 1989 se aplicó el algoritmo de retropropagación a una red similar al Neocognitron, en el cual se incluyeron capas convolucionales, operaciones max-pooling, haciendo la arquitectura básica de una CNN (Schmidhuber, 2015). Las CNN son las arquitecturas preferentes a la hora de hablar de aprendizaje visual.

A partir del desarrollo de las redes con más de una capa se han propuesto una infinidad de arquitecturas. En 2006 Hilton y Osidero desarrollaron una arquitectura de más de una capa con entrenamiento rápido, con ello se introdujo el término de Aprendizaje Profundo, del cual forman parte las CNN (Russell y Norvig, 2016) (Wilamowski, 2009).

Actualmente la IA es una de las disciplinas más usadas en la investigación, es aplicada en trabajos multidisciplinarios en áreas como la medicina, robótica, sociología, economía, en general a toda área donde existan datos. Algunas de sus principales aplicaciones son las enlistadas a continuación:

- Aprendizaje automático

- Sistemas Expertos
- Visión por computadora
- Planificación
- Robótica
- Procesamiento del lenguaje natural

2.3. Aprendizaje de automático

El aprendizaje automático es una rama de la inteligencia artificial, cuyo objetivo es desarrollar técnicas que permitan que las computadoras aprendan (Dietterich, 2002). En este caso el concepto de aprender se refiere al hecho de que una computadora genere cierta experiencia en la realización de una tarea específica mediante una supervisión humana (Michie, Spiegelhalter, Taylor, et al., 1994).

Este aprendizaje es fundamentalmente una forma de estadística aplicada con mayor énfasis en el uso de computadoras para estimar funciones complicadas y un menor énfasis en los intervalos de confianza en torno a estas funciones. El aprendizaje automático se podría definir como un programa de computación que aprende de la experiencia E con respecto a una tarea T y alguna medida de rendimiento P , si es que el rendimiento en T , medido por P , mejora con la experiencia E . La mayoría de los algoritmos de aprendizaje automático se pueden dividir en las categorías de aprendizaje supervisado donde requiere la intervención humana y aprendizaje no supervisado donde no ocupa intervención.

Este subcampo permite a las máquinas aprender y hacer predicciones basadas en su experiencia, mientras que el aprendizaje profundo que es un tipo particular de aprendizaje automático, como se muestra en la 2.1, logra un gran poder y flexibilidad al aprender a representar el mundo como una jerarquía de conceptos o abstracciones anidadas.

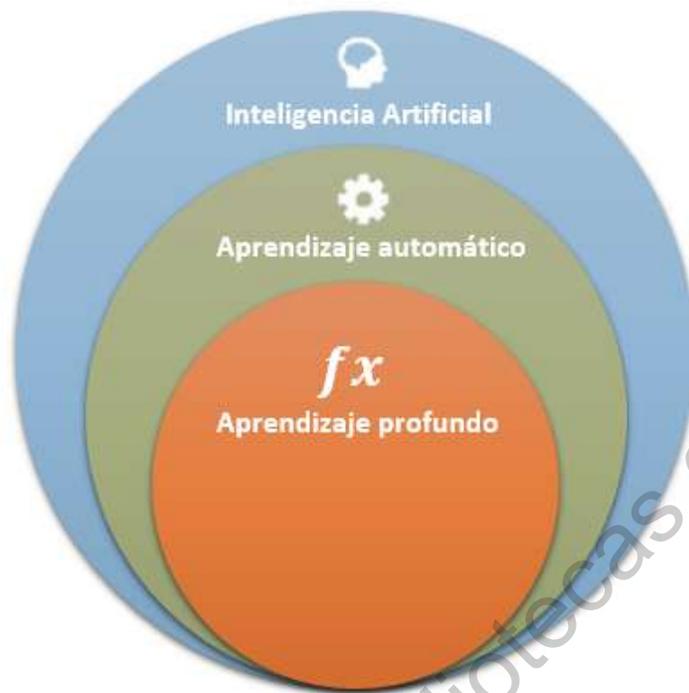


Figura 2.1: Relacion de IA, aprendizaje automático y aprendizaje profundo. Imagen propia.

2.3.1. Aprendizaje profundo

El aprendizaje profundo es una subsección del aprendizaje automático, siendo relativamente nuevo. Permite que modelos computacionales compuestos de múltiples capas de procesamiento aprendan representaciones de datos con múltiples niveles de abstracción (LeCun, Bengio, y Hinton, 2015), mejorando exponencialmente el estado del arte en reconocimiento de voz, detección de objetos, modelación de patrones no lineales, entre otros (Schmidhuber, 2015; LeCun et al., 2015).

El aprendizaje profundo recibe su nombre ya que utiliza redes neuronales de varias capas. El número de capas dentro de una red neuronal define la profundidad de la red. Dichas capas tienen diferentes funciones y escalas que cambian la entrada a medida que pasa a través de ellas, eventualmente la red produce una predicción (Schmidhuber, 2015).

La principal diferencia entre el aprendizaje profundo y el aprendizaje automático se basa en que el aprendizaje automático requiere cierta supervisión externa al algoritmo implementado, mientras

el aprendizaje profundo tiene etapas de retropropagación con el cual puede aprender por si mismo resolver el algoritmo implementado, de la misma manera la cantidad de datos utilizados en el aprendizaje profundo es mayor a los usados en el aprendizaje automático. Por ende, se ha usado principalmente en el área de grandes datos, grandes empresas como el caso de Google usa el aprendizaje profundo para el reconocimiento de voz y de imágenes (Ahmad, Farman, y Jan, 2019).

Algunas de las diferencias entre aprendizaje automático y profundo, como se muestra en la figura 2.2 , es la forma del aprendizaje, mientras aprendizaje automático requiere supervisión, se tiene que guiar al programa en todas las fases del sistema para que sepa identificar cada categoría automáticamente, el aprendizaje profundo requiere supervisión, es una técnica mejorada donde los sistemas alcanzan niveles de aprendizaje en un grado más detallado.

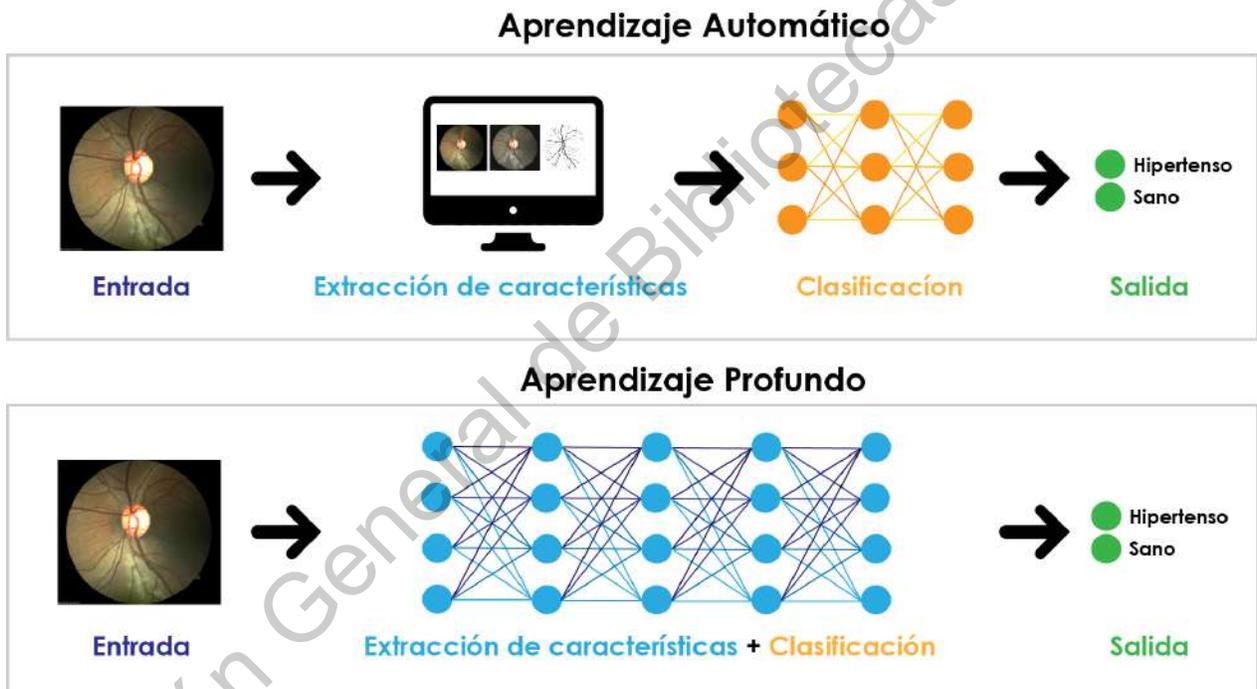


Figura 2.2: Relacion de aprendizaje automático y aprendizaje profundo. Imagen propia

2.4. Redes neuronales artificiales

Las redes neuronales artificiales son un modelo computacional inspirado en el cerebro humano, más específicamente en una red de neuronas (Hopfield, 1988). En la Figura 2.3 se puede observar

la comparación entre las partes de una neurona natural y una representación esquemática de un modelo de una neurona artificial. De esta manera se observa que ambas neuronas comparten ciertas características, tales como las dendritas, el cuerpo celular y el axón; los cuales en la neurona artificial se representan por las entradas x_n y los pesos w_{in} , la sección de sumatoria Σ y la función de activación respectivamente.

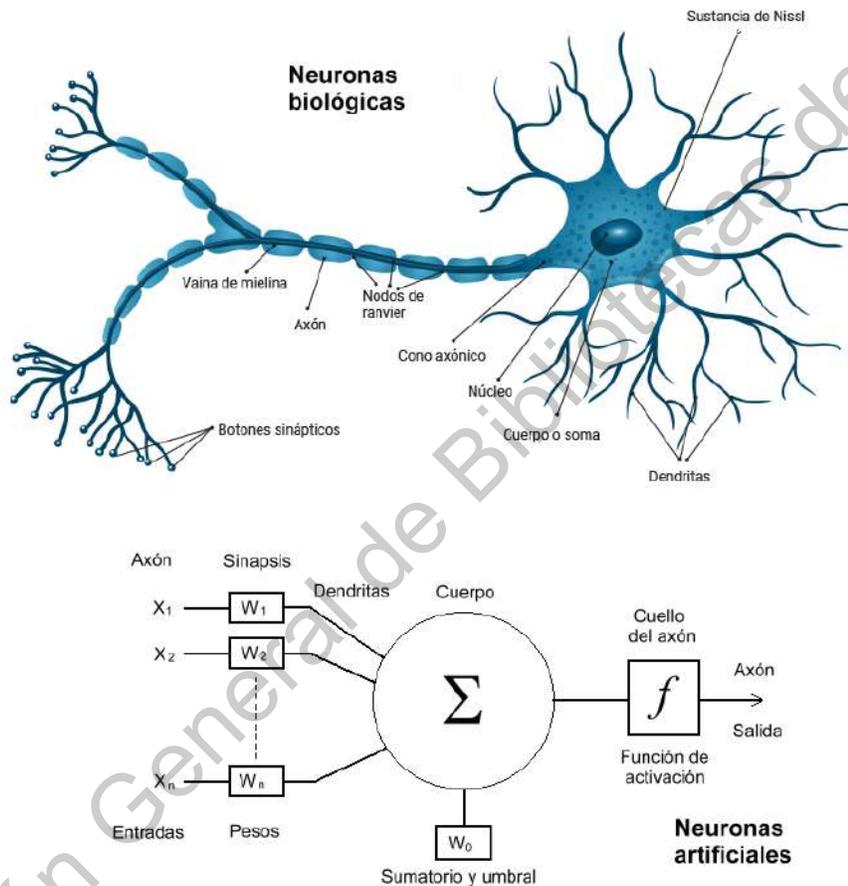


Figura 2.3: Comparación entre una neurona artificial y una natural. Imagen propia

Cada neurona está conectada con otras a través de unos enlaces. En los enlaces el valor de salida de la neurona anterior es multiplicado por un valor de peso. Estos pesos en dichos enlaces pueden incrementar o disminuir el estado de activación de las neuronas adyacentes (Abraham, 2005; Hassoun, 1995). Dichas redes se conforman por una capa de entrada, n capas ocultas y una

capa de salida. En la Figura 2.4 se muestra un ejemplo de una red neuronal con tres capas, con la finalidad de visualizar la capa de entrada, una capa oculta y una capa de salida.

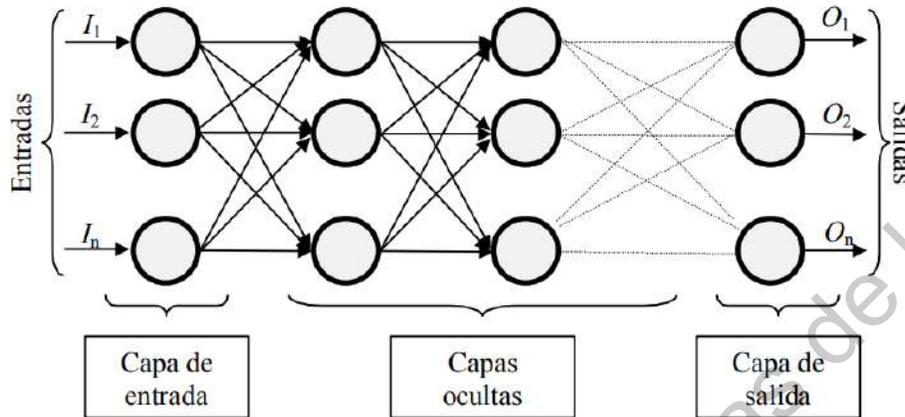


Figura 2.4: Estructura de Red neuronal básica. Imagen propia

Las neuronas de la primera capa reciben como entrada los datos reales que alimentan a la red neuronal, la primera capa se conoce como capa de entrada. La salida de la última capa es el resultado visible de la red, por lo que la última capa se conoce como la capa de salida. Las capas que se sitúan entre la capa de entrada y la capa de salida se conocen como capas ocultas.

Actualmente existen diversas estructuras o topologías de redes neuronales, en el área de inteligencia artificial se les considera resultado de la interpretación del funcionamiento del cerebro humano, pero no está claro que topología refleja realmente el funcionamiento cerebral (Abraham, 2005; Hopfield, 1988).

2.5. Redes neuronales convolucionales (CNN)

Las CNN son un tipo específico de red neuronal que funciona bien con datos específicos, son particularmente útiles con imágenes para tareas como clasificación o segmentación. Las capas convolucionales usan solo ciertas conexiones de la capa anterior; específicamente, las neuronas locales están conectadas a las neuronas de la siguiente capa. Este método hace que la capa comprenda mejor la vista genérica de las entradas. (LeCun, Bottou, Bengio, y Haffner, 1998).

El objetivo de una CNN es aprender características de orden superior en los datos mediante convoluciones. Se adaptan bien al reconocimiento de objetos en imágenes y a la clasificación de imágenes. Pueden identificar rostros, personas, letreros de calles, animales y muchos otros objetos individuales que contengan las imágenes. El uso principal de las CNN es con imágenes pero también se usan para analizar texto o sonido. La eficacia de las CNN en el reconocimiento de imágenes es una de las principales razones por las que el mundo reconoce el poder del aprendizaje profundo (Patterson y Gibson, 2018).

Las CNN transforman los datos de entrada de la capa de entrada a través de todas las capas conectadas en un conjunto de puntuaciones de clase dadas por la capa de salida. Hay muchas variaciones de la arquitectura de CNN, pero se basan en el patrón de capas, como se demuestra en la figura 2.5 donde se representan tres grupos principales: capa de entrada, capas de extracción de características (aprendizaje) y capas de clasificación.

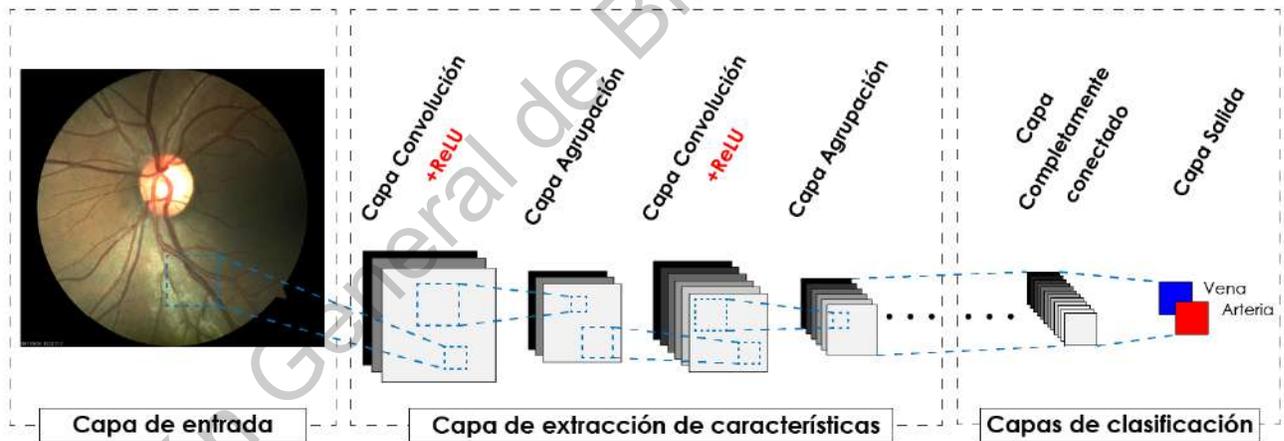


Figura 2.5: Arquitectura general de CNN. Imagen propia

La capa de entrada acepta entradas tridimensionales generalmente en la forma espacial del tamaño de la imagen y tiene una profundidad que representan los canales de color, generalmente tres para los canales de color RGB. Las capas de extracción de características tienen un patrón general de repetición de capa de convolución seguida por capa de agrupación. Las capas de agrupación

encuentran una serie de características en las imágenes y construyen progresivamente características de orden superior. Finalmente, las capas de clasificación en las que tenemos una o más capas completamente conectadas para tomar las características de orden superior y producir probabilidades de clase o puntajes. Estas capas están completamente conectadas a todas las neuronas de la capa anterior, como su nombre lo indica. La salida de estas capas produce normalmente una salida bidimensional donde tenemos el número de ejemplos de mini lote y el número de clases que se decaen encontrar.

2.5.1. Capa de entrada

Las capas de entrada son donde se carga y almacenan los datos de entrada sin procesar para su procesamiento en la red. Estos datos de entrada especifican el ancho, alto y número de canales. Normalmente, el número de canales es tres, para los valores RGB de cada píxel.

2.5.2. Capa convolucional

Las capas convolucionales se consideran los componentes básicos de las arquitecturas de CNN. Las capas convolucionales transforman los datos de entrada usando un parche de neuronas conectadas localmente de la capa anterior. La capa calculará un producto escalar entre la región de las neuronas en la capa de entrada y los pesos a los que están conectadas localmente en la capa de salida.

La salida resultante generalmente tiene las mismas dimensiones espaciales, pero a veces aumenta el número de elementos en la tercera dimensión de la salida, es decir la profundidad.

2.5.2.1. Convolución

Una convolución se define como una operación matemática que describe una regla sobre cómo fusionar dos conjuntos de información. Aplica un núcleo de convolución a la entrada y da un mapa de características como salida. La entrada a una convolución pueden ser datos sin procesar o una salida de mapa de características de otra convolución. A menudo se interpreta como un filtro en

el que el kernel filtra los datos de entrada para determinados tipos de información. Un kernel de borde permite pasar solo información desde el borde de una imagen.

La figura 2.6 ilustra cómo se desliza el núcleo a través de los datos de entrada para producir los datos de salida. En cada paso, el kernel se multiplica por los valores de los datos de entrada dentro de sus límites, creando una sola entrada en el mapa de características de salida. Los conjuntos de pesos en una capa convolucional se define como filtro. Este filtro está convolucionado con la entrada y el resultado es un mapa de características. El mapa de activación de cada filtro se apila a lo largo de la dimensión de profundidad para construir el volumen de salida 3D. Las capas convolucionales tienen parámetros para la capa e hiperparámetros adicionales. El descenso de gradiente se utiliza para entrenar los parámetros en esta capa de modo que las puntuaciones de la clase sean coherentes con las etiquetas del conjunto de entrenamiento.

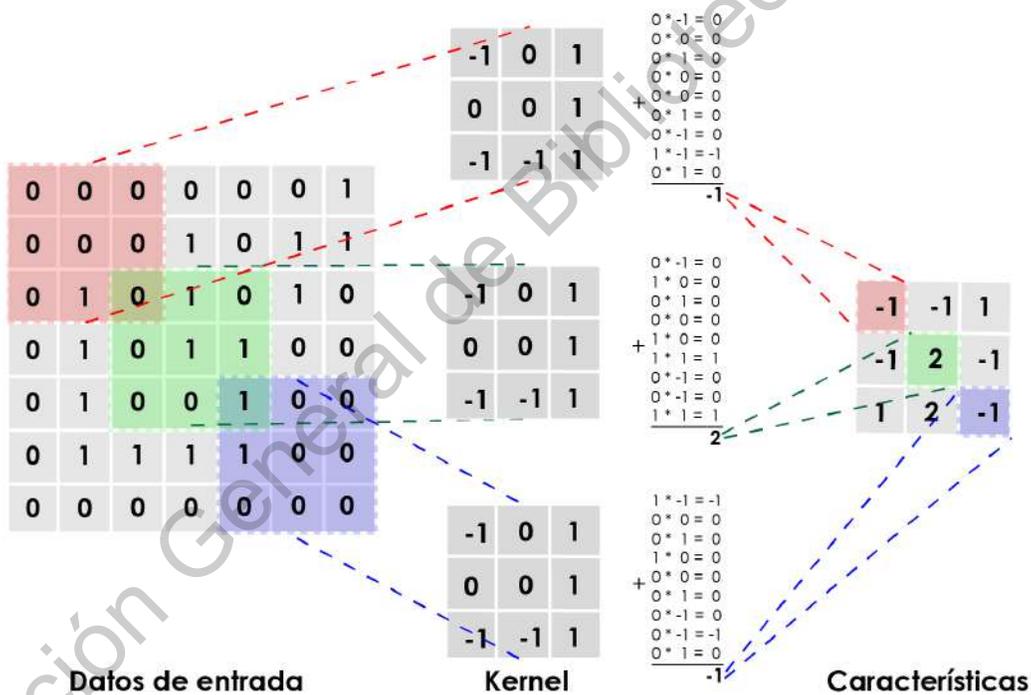


Figura 2.6: Operación de convolución. Imagen propia.

Los siguientes son los componentes principales de las capas convolucionales:

- Filtros
- Mapas de activación

- Compartir parámetros
- Hiperparámetros específicos de la capa.

2.5.3. Capa de agrupación

Se inserta comúnmente entre capas convolucionales sucesivas. Se encarga de reducir la cantidad de parámetros y el cálculo de la red, controlando el sobreajuste y reduciendo progresivamente el tamaño espacial. Esta operación toma el mayor número de la región del filtro seleccionado, sin afectar la profundidad. La capa de agrupación funciona de forma independiente en cada segmento de profundidad de la entrada.

La operación de reducción de resolución más común es la operación *max-pooling*. La siguiente operación más común es la agrupación promedio. Con un tamaño de filtro de 2×2 , la operación *max-pooling* toma el mayor de cuatro números en el área del filtro. Esta operación no afecta la dimensión de profundidad. Las capas de agrupación utilizan filtros para realizar el proceso de reducción de muestreo en el volumen de entrada. Estas capas realizan operaciones de reducción de muestreo a lo largo de la dimensión espacial de los datos de entrada. Esto significa que si la imagen de entrada tiene una dimensión de 32×32 , la imagen de salida sería más pequeña en ancho y alto, es decir 16×16 . La configuración más común para una capa de agrupación es aplicar filtros 2×2 con una zancada de 2.

2.5.4. Capa completamente conectada

Esta capa es utilizada para calcular las puntuaciones de la clase que se usan como salida de la red, es decir la capa de salida de la red. Las dimensiones del volumen de salida son $[1 \times 1 \times N]$, donde N es el número de clases de salida que estamos evaluando. Las capas completamente conectadas tienen los parámetros normales para la capa y los hiperparámetros. Las capas completamente conectadas realizan transformaciones en el volumen de datos de entrada que son una función de las activaciones en el volumen de entrada y los parámetros de pesos y sesgos de las neuronas.

2.6. Red neuronal recurrente (RNN)

Las redes neuronales recurrentes pertenecen a la familia de las redes neuronales de retroalimentación. Se diferencian de otras redes de propagación hacia adelante en su capacidad para enviar información en intervalos de tiempo.

Históricamente, estas redes han sido difíciles de entrenar, pero gracias a los avances de optimización, las nuevas arquitecturas diseñadas, y las unidades de procesamiento de gráficos (GPU) estas redes se han hecho más accesibles. Las redes neuronales recurrentes toman cada vector de una secuencia de vectores de entrada y los modelan uno a la vez, esto permite que la red retenga el estado mientras modela cada vector de entrada en la ventana de vectores de entrada.

2.6.1. Red neuronal de memoria a corto plazo LSTM

Las LSTM es un tipo de red neuronal recurrente, son la variación más utilizada RNN. Las redes LSTM fueron introducidas en 1997 por Hochreiter y Schmidhuber, donde define los LSTM como una forma de RNN donde la información más reciente en las neuronas es más crítica que la información anterior (Hochreiter y Schmidhuber, 1997).

El componente crítico de una LSTM es la celda de memoria y las compuertas, incluida la compuerta de olvido, pero también la compuerta de entrada. El contenido de la celda de memoria es modulado por las compuertas de entrada y de olvido. (Graves, 2012), (Gers, Schmidhuber, y Cummins, 1999). Si ambas puertas están cerradas, el contenido de la celda de memoria permanecerá sin modificaciones entre un paso de tiempo y el siguiente. La estructura de compuerta permite que la información se retenga en muchos pasos de tiempo y, en consecuencia, también permite que los gradientes fluyan a través de muchos pasos de tiempo. Esto permite que el modelo LSTM supere el problema de la desaparición del gradiente que ocurre con la mayoría de los modelos de redes neuronales recurrentes.

Algunas de las propiedades más relevantes de las redes LSTM incluyen la mejora de las ecua-

ciones de actualización y retropropagación.

2.7. Hiperparámetros

Los hiperparámetros son parámetros que ayudan a controlar el proceso de aprendizaje de las redes neuronales, su función es activar una neurona a diferentes intensidades dependiendo de la entrada, a continuación se explicaran.

2.7.1. Funciones de activación

Tanto en las redes neuronales biológicas como en las redes neuronales artificiales, una neurona no solo transmite la entrada que recibe. Existe un paso intermedio, denominado función de activación (Guyon, 1991; Rojas, 2013; Abraham, 2005; Ramachandran, Zoph, y Le, 2017). Las funciones de activación en las redes neuronales artificiales son funciones no lineales. Si no existiera una función de activación, todas las capas se pueden contraer en una sola capa (Rojas, 2013). Las redes neuronales son capaces de trabajar con espacios muestrales no lineales, solo por las funciones de activación (Guyon, 1991).

2.7.1.1. Lineal

La función de activación lineal esta representada por la ecuación 2.3, permite que el valor de entrada se dispare como salida de la neurona, como se muestra en la figura 2.7. La función de activación lineal es una de las funciones de activación más simples, rápida de calcular y no tiene restricciones en la salida.

$$f(x) = x \tag{2.1}$$

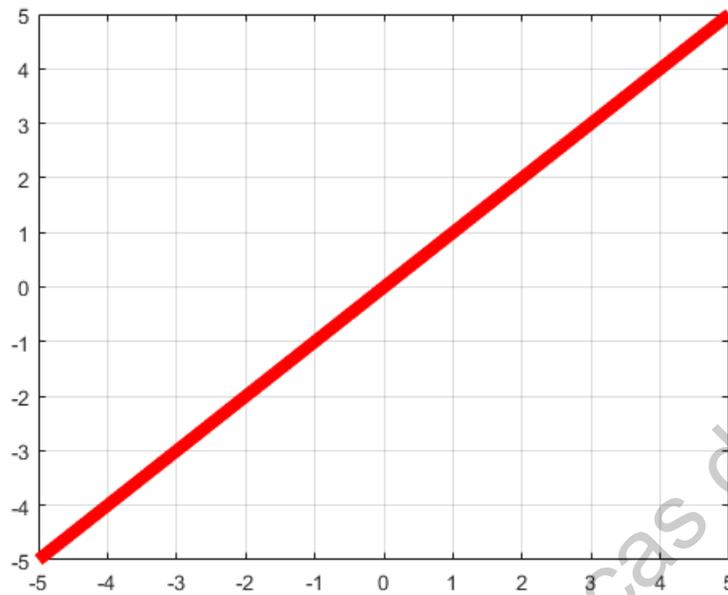


Figura 2.7: Función de activación lineal. Imagen propia.

2.7.1.2. Unidad lineal rectificada (ReLU)

Esta función de activación es una variación de la función de activación lineal. La principal diferencia es que transforma los valores negativos en ceros como se muestra en la figura 2.8. Esta función reduce el problema del descenso del gradiente. La función es rápida de entrenar y permite una transformación en los datos de entrada. La función ReLU se define como la ecuación 2.2.

$$f(x) = \begin{cases} 0, & x < 0 \\ x & x \leq 0 \end{cases} \quad (2.2)$$

La superioridad de ReLU se basa en que su rango de capacidad de respuesta es más útil comparada con la capacidad de respuesta de una función sigmoide, que decae relativamente rápido en ambos extremos. La función ReLU permite el paso de todos los valores positivos sin cambiarlos, asignando todos los negativos a 0 (Rojas, 2013).



Figura 2.8: Función de activación ReLU. Imagen propia.

2.7.1.3. Sigmoide

Históricamente, la función sigmoide (ecuación 2.3) es la función de activación más antigua y popular. Tiene una salida que oscila entre 0 y 1 como se muestra en la figura 2.9. Esta función de activación es adecuada para problemas de clasificación binaria, sin embargo es más lenta de calcular que las dos funciones pasadas.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$

2.7.1.4. Sofplus

La función de activación Sofplus definida en la ecuación 2.4. es similar a Relu en la salida, ya que tiene una salida mayor a 0 pero esta tiene una relación más suave sobre los valores en los límites de 0 como se muestra en la figura 2.10. Esta función es útil para los problemas de regresión y a diferencia de ReLU no tiene cambios drásticos a la salida, es más tardada en calcular que la

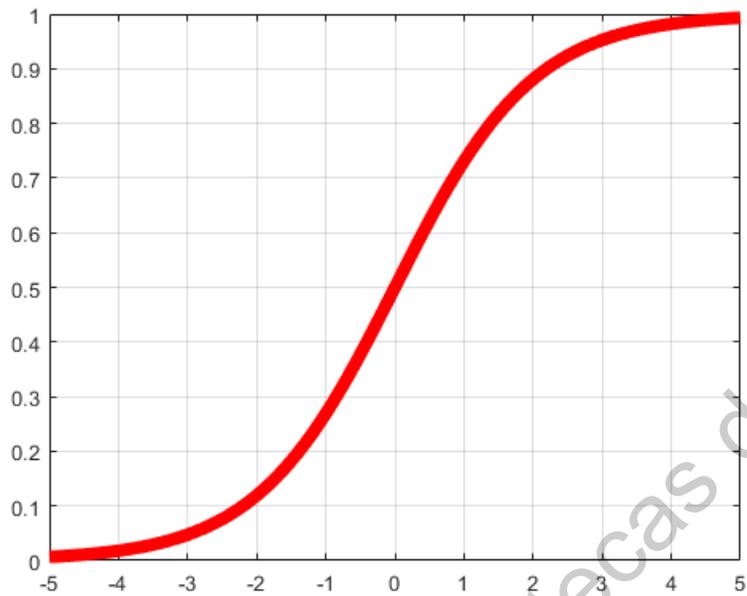


Figura 2.9: Función de activación sigmoide. Imagen propia.

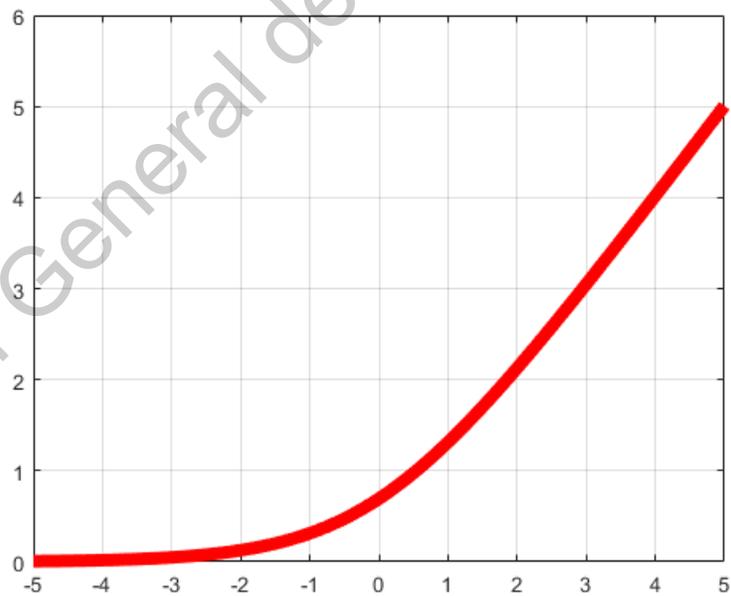


Figura 2.10: Función de activación Sofplus. Imagen propia.

función ReLU.

$$f(x) = \ln 1 + e^x \quad (2.4)$$

2.7.1.5. Unidad Lineal Exponencial (ELU)

Recientemente Djork-Arne Clevert, Thomas Unterthiner y Sepp Hochreiter en 2015, propusieron la función de activación Unidad Lineal Exponencial (ELU) definida en la ecuación 2.5. Al igual que la ReLU mejora el problema del gradiente descendente a través de la identificación de los valores positivos. En contraste con la ReLU tiene valores negativos que le permite empujar las activaciones de las unidades medias más cerca de cero, pero con una menor complejidad computacional como se muestra en la figura 2.11 (Ramachandran et al., 2017).

$$f(x) = \lambda \begin{cases} x, & x > 0 \\ e^x - 1, & x \leq 0 \end{cases} \quad (2.5)$$

Donde, $\alpha \approx 1,6733$

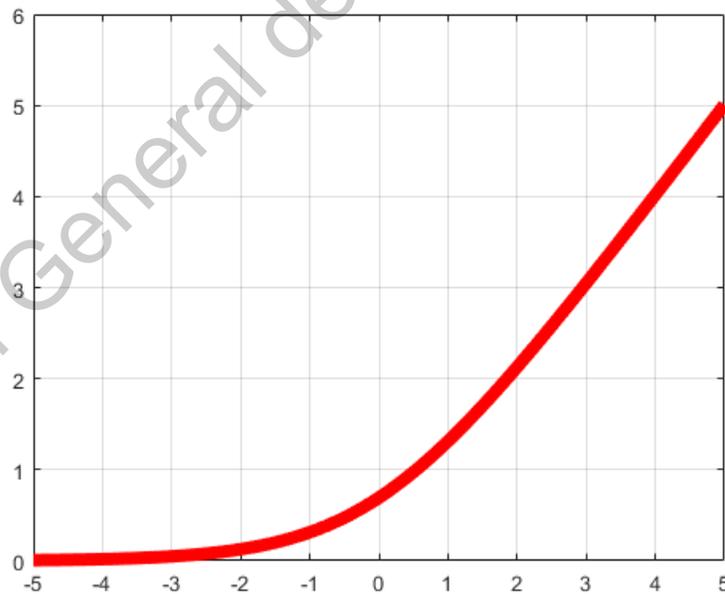


Figura 2.11: Función de activación ELU. Imagen propia.

2.7.1.6. SELU

La función de activación SELU definida en la ecuación 2.6, Unidad Lineal Exponencial Escalada, es una variante de la ELU. Propuesta en 2017, por G. Klambauer, T. Unterthiner, A. Mayr y S. Hochreiter. Es como una red neuronal autonormalizada con una varianza media y unitaria cercana a cero, convergiendo hacia la media y varianza unitaria cuando se propaga a través de múltiples capas durante el entrenamiento, ver Figura 2.12. Lo que la hace adecuada para el aprendizaje profundo (Ramachandran et al., 2017). La función se describe a continuación:

$$f(x) = \lambda \begin{cases} x, & x > 0 \\ \alpha e^x - \alpha, & x \leq 0 \end{cases} \quad (2.6)$$

Donde, λ es el factor de escala y $\alpha \approx 1,6733$

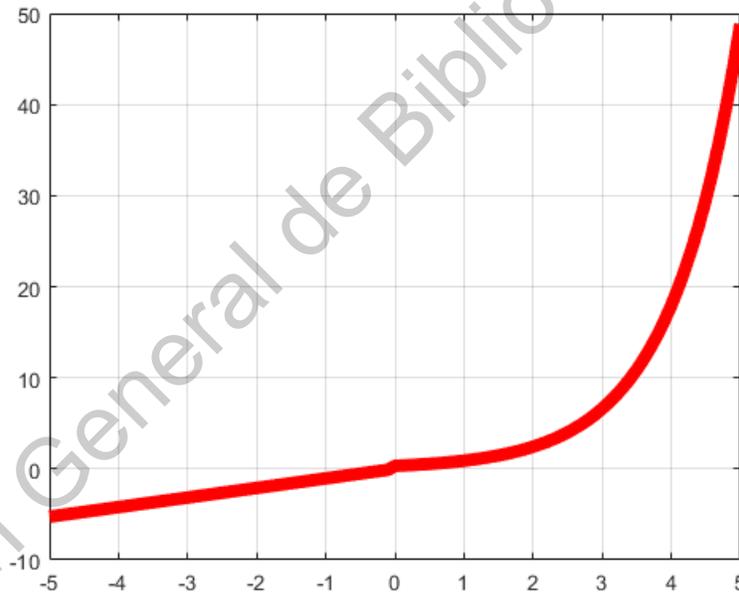


Figura 2.12: Función de activación SELU. Imagen propia.

2.7.2. Optimizador

El optimizador, es el encargado de actualizar los pesos de cada capa, su importancia es crucial para calcular el gradiente de la función de coste por cada peso de la red. Los optimizadores permiten que las redes neuronales tengan un mejor rendimiento en cada iteración. Cada optimizador se basa en sus criterios propios.

2.7.2.1. Adam

Adam es uno de los optimizadores más populares. Adam es un método optimizador de gradiente descendiente estocástico que se basa en la estimación adaptativa de momentos de primer y segundo orden. Adam es útil para problemas grandes en términos de datos y parámetros. (Jais, Ismail, y Nisa, 2019) Entre sus ventajas están:

- Fácil de implementar.
- Eficiente.
- Pequeños requerimientos de memoria.
- Adecuado para problemas con gran número de parámetros.

Metodología

El procedimiento para la realización del proyecto consta de 5 pasos principales como se muestra en la figura 3.1. *Adquisición de las imágenes de fondo de ojo*, donde se seleccionó una base de datos publica y se realizó una base de datos con 60 imágenes de retina de personas sanas y personas hipertensas. *Procesamiento de imagen*, donde se resaltan las características buscadas para ayudar al entrenamiento de la red. *Definir arquitectura de red neuronal convolucional* que se utiliza para la segmentación y clasificación de vasos retinianos. *Implementar la arquitectura*, entrenar la red, interpretar los resultados y validarlos para obtener la clasificación. Realizar un método que permita obtener el calibre de los vasos retinianos y con ello la relación arteria y vena que permita identificar a una persona sana de una persona con hipertensión.

3.1. Adquisición de imágenes

Para el desarrollo de este trabajo se trabajará con la base de datos publica DRIVE para realizar la clasificación de los vasos retinianos y la base de datos INSPIRE-AVR y DRIVE para el cálculo de relación arteria y vena (AVR). La base de datos propia, cuenta con 60 imágenes de fondo de ojo proporcionadas por el Instituto de Retina del Bajío (INDEREB).

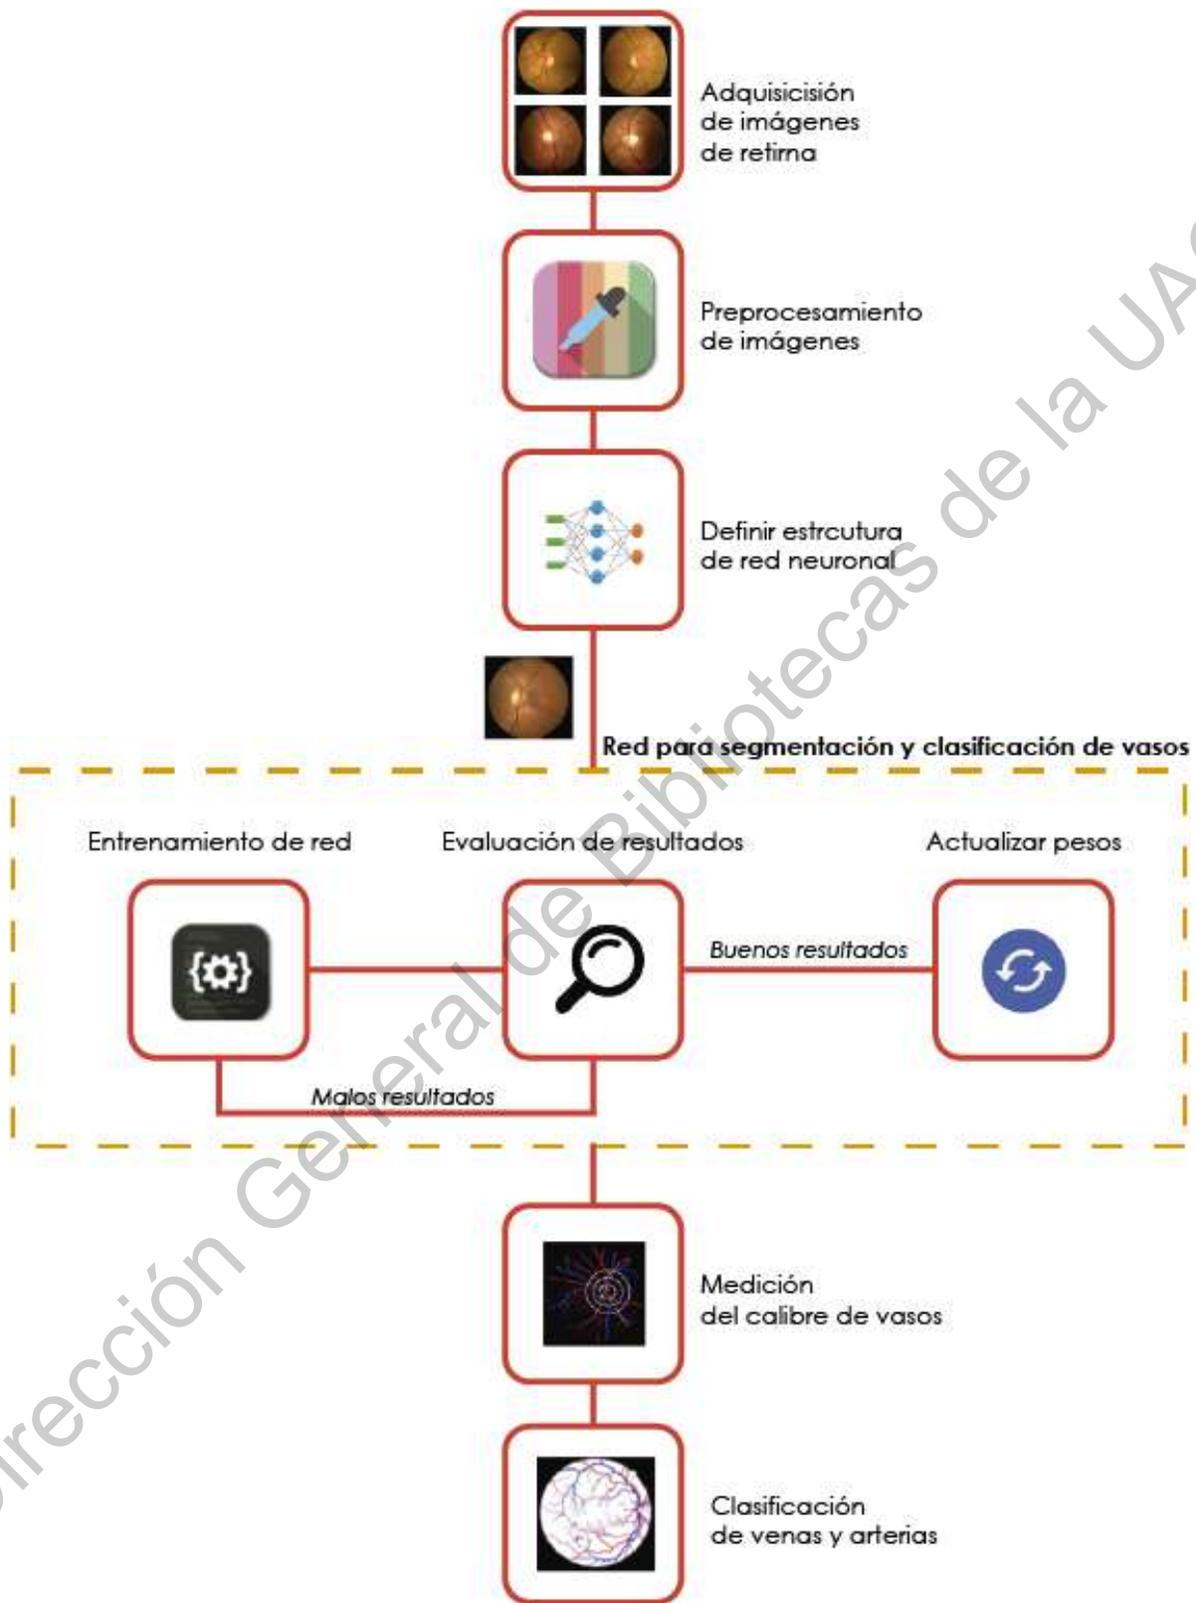


Figura 3.1: Metodología propuesta para definir los hiperparámetros y entrenar el clasificador de A/V. Imagen propia.

3.1.1. Base de datos DRIVE

DRIVE (Staal, Abramoff, Niemeijer, Viergever, y Van Ginneken, 2004) incluye un conjunto de cuarenta fotografías a color del fondo de ojo, obtenidas de una campaña de detección de retinopatía diabética. En este conjunto de datos, siete de las cuarenta imágenes contienen anomalías como exudados, hemorragias y epitelio pigmentario. Las imágenes tienen un tamaño de 565x584 píxeles, se adquirieron utilizando una cámara Canon CR5 no midriática 3-CCD con un campo de visión (FOV) de 45 grados. La base de datos DRIVE se divide en dos conjuntos, el conjunto de entrenamiento y el conjunto de prueba, cada uno con veinte imágenes. El conjunto de prueba está segmentado manualmente por dos observadores como se muestra en la figura 3.2, el primer observador es aceptado como criterio de referencia.

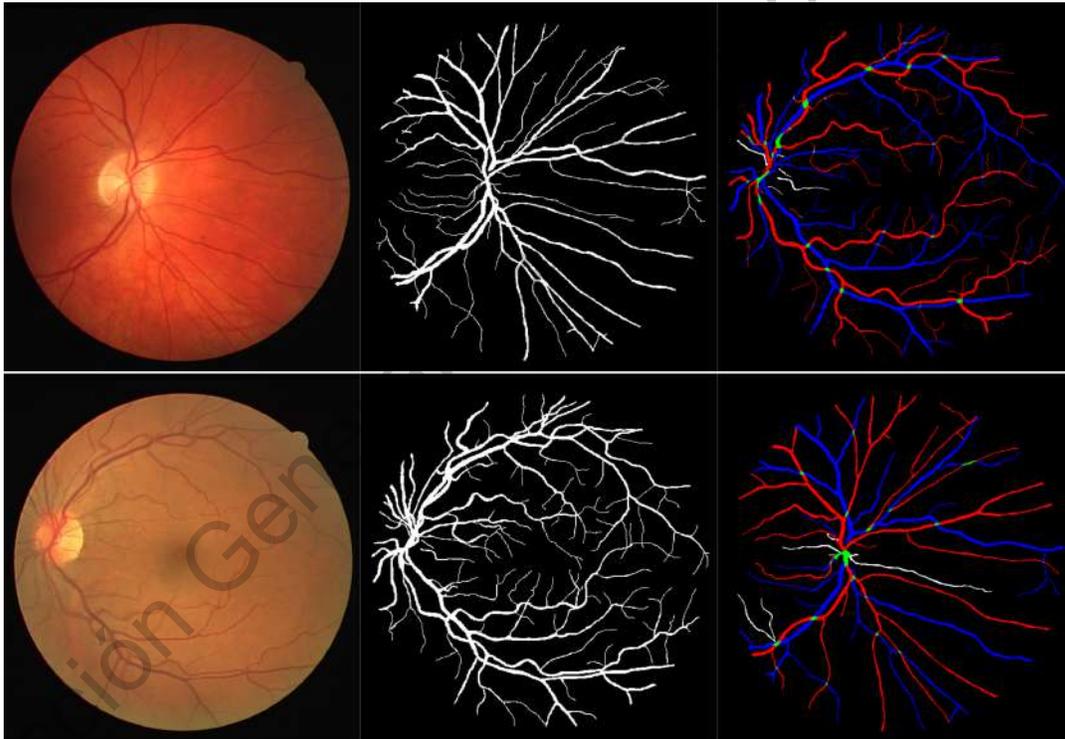


Figura 3.2: Ejemplos de imágenes de base de Datos DRIVE en la primera columna se muestran la imagen original, en la segunda la imagen segmentada y por ultimo en la tercera las imágenes clasificadas por Qureshi.

Para la clasificación de vena y arteria de imágenes de fondo de ojo como se muestra en la figu-

ra 3.2, se trabaja con la base de datos publicada por Qureshi (Qureshi, Habib, Hunter, y Al-Diri, 2013) donde un oftalmólogo capacitado etiquetó manualmente los vasos del conjunto de pruebas como arteria, vena o superposición.

3.1.2. Base de datos INSPIRE-AVR

INSPIRE-AVR (Niemeijer et al., 2011) cuenta con 40 imágenes en color del fondo de ojo centradas en el disco óptico y un estándar de referencia de relación arterio-venosa, las imágenes tienen un tamaño de 2392 x 2048 píxeles. El estándar de referencia es el promedio de la evaluación de la medición de AVR de dos expertos que utilizan IVAN (un programa informático semiautomático desarrollado por la Universidad de Wisconsin, Madison, WI, EE. UU.). En la figura 3.3 se muestra un ejemplo de una de las imágenes de la base de datos con sus respectivas medidas de AVR dadas por los dos observadores. Las imágenes fueron tomadas con una cámara de fondo de ojo Zeiss con un campo de visión de 30 grados.



AVR Obs. 1: 0.7

AVR Obs. 2: 0.71

Figura 3.3: Ejemplos de imagen de base de Datos INSPIRE con sus mediciones de AVR hechas por dos expertos utilizando IVAN.

3.1.3. Base de datos propia

La base de datos creada cuenta con 60 imágenes a color del fondo de ojo centradas en el nervio óptico. Las imágenes fueron tomadas en el INDEREB. En este conjunto de datos se incluyeron 30

imágenes de personas reportadas como sanas, y 30 imágenes de personas clínicamente diagnosticadas como hipertensas, con los siguientes criterios de exclusión:

- Fumadores
- Miopía mayores a -2.00D(dioptías)
- Diabéticos
- Cataratas
- Nervios opacos

La figura 3.4 muestra algunas de las imágenes de la base de datos creada. Las imágenes tienen un tamaño de 1620 x 1444 píxeles, se adquirieron con una cámara Carl Zeiss, visucam nm/fa mi-driática con campo de 45 y 30 grados, con un campo de visión de 30 grados. La base de datos fue segmentada y clasificada manualmente usando el software de edición Photoshop con la siguiente metodología: Resaltar vasos para poder distinguir mejor arteria de vena en vasos pequeños y etiquetar píxel por píxel como arteria o vena, a continuación se explica más a detalle cada paso.

3.1.3.1. Resaltar características

Para resaltar las características y mejorar el contraste se usó el filtro Ecuilización de histograma adaptativo de contraste limitado (CLAHE). CLAHE es una técnica de procesamiento de imágenes que se utiliza para mejorar el contraste en las imágenes (Zhou, Jin, Wang, Ye, y Qian, 2018). El método adaptativo de la técnica calcula varios histogramas, cada uno correspondiente a una sección diferente de la imagen, y los utiliza para redistribuir los valores de luminosidad. Por lo tanto, es adecuado para mejorar el contraste local y mejorar las definiciones de los bordes en cada región de una imagen.

Este filtro se insertó en cada una de las capas de la imagen. Las imágenes son RGB, es decir 3 capas de profundidad, el resultado de este preprocesamiento se puede ver en la figura 3.5, donde la primera imagen es la imagen original y la segunda es la imagen con el filtro, se puede observar que es más notoria la diferencia entre arteria y vena.

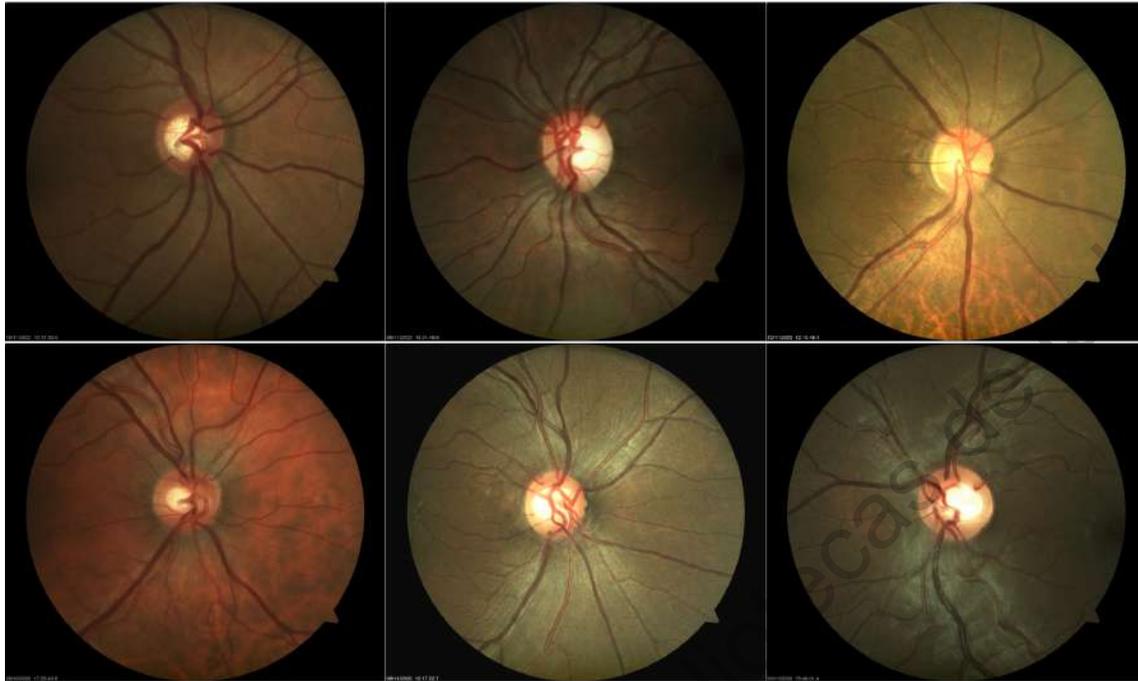


Figura 3.4: Imágenes de base de datos creada, el primer renglón muestra 3 imágenes de personas sanas, el segundo renglón muestra 3 imágenes de personas hipertensas.



Figura 3.5: Preprocesamiento con filtro CLAHE para mejorar la diferencia entre vena de arteria.

3.1.3.2. Clasificación de vasos retinianos

Para la clasificación de vasos retinianos se etiquetó píxel por píxel como arteria o vena, para esta tarea se usó el programa de edición de imágenes Photoshop. Este trabajo es demorado, ya que se requiere ser lo más exacto posible, la clasificación manual por cada imagen duró aproximadamente 2 horas y media. En la figura 3.6 se muestran dos ejemplos de la clasificación manual de la base de datos creada.

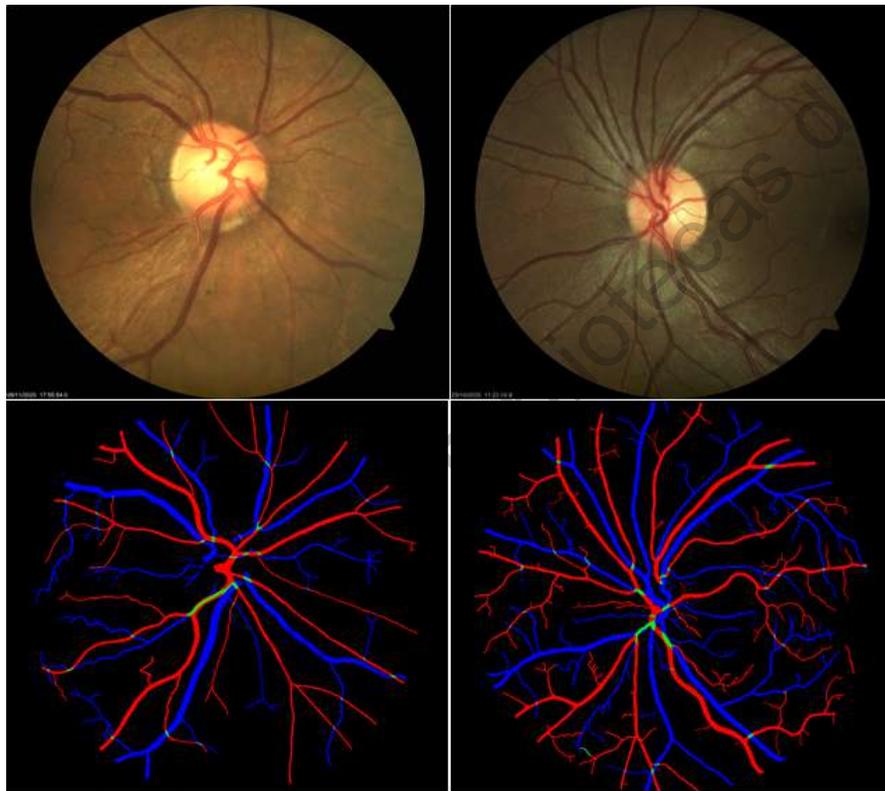


Figura 3.6: Clasificación manual de imágenes de la base de datos creada, en la primera columna se muestran las imágenes originales y en la segunda se muestra la clasificación.

3.2. Procesamiento de imagen

Las imágenes de fondo de ojo pueden tener una amplia variación en la pigmentación, debido a problemas con la iluminación no uniforme y a la mala exposición al momento de tomar la fotogra-

fía, lo que puede influir el rendimiento de la CNN. Realizar un preprocesamiento mejora la calidad de las imágenes y permite que la CNN detecte con mayor facilidad las características buscadas.

3.2.1. Normalización de datos

El primer paso es la normalización de datos. La normalización es usada para escalar un atributo dentro de un rango específico, facilitar y acelerar el entrenamiento de las redes. Las CNN no funcionan bien cuando los atributos numéricos de entrada tienen escalas muy diferentes. En este trabajo se utilizan dos técnicas de normalización, z-score y min-max (Mining, 2006).

La normalización z-score es útil cuando se tienen valores atípicos en un atributo:

$$x' = \frac{x - \mu_A}{\sigma_A} \quad (3.1)$$

donde μ_A y σ_A son la media y desviación estándar.

En la normalización min-max se hace una transformada lineal de los datos, los valores se desplazan y reescalán para que terminen en un rango de 0 a 1:

$$x' = \frac{x - \min(A)}{\max(A) - \min(A)} \quad (3.2)$$

Donde x' es el valor normalizado del valor original x relacionado con los valores mínimos y máximos de un atributo A.

3.2.2. Corrección de contraste

En todas las bases de datos que se explicaron con anterioridad, se tiene problemas con el contraste en algunas imágenes, esto debido a que este no es el mismo en todas las fotos y algunas tienen pequeños problemas de captura. Para corregir este problema así mismo se implementó el filtro por ecualización de histograma adaptativo limitada por contraste (CLAHE). En CLAHE la

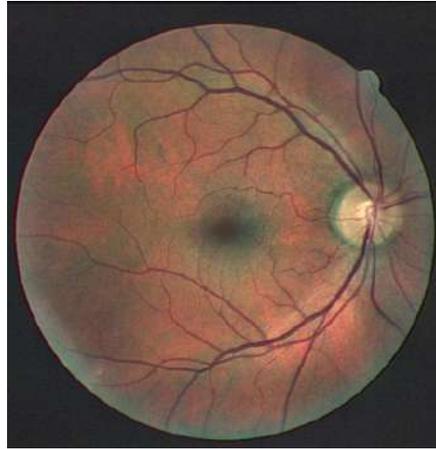


Figura 3.7: Aplicación de filtro CLAHE

imagen se divide en pequeños bloques, cada bloque se ecualiza. De tal manera que el histograma se limita a una región pequeña a menos que exista ruido, si hay ruido, se amplificaría, pero para evitar esto, se aplica limitación de contraste. Si algún contenedor de histograma está por encima del límite de contraste especificado, esos píxeles se recortan y distribuyen uniformemente a otros contenedores antes de aplicar la ecualización de histograma. Después de la ecualización, para eliminar los artefactos en los bordes de los mosaicos, se aplica la interpolación bilineal. El resultado de este proceso se puede ver en la figura 3.5

3.2.3. Corrección de brillo

El brillo es otro factor importante a corregir en nuestras imágenes, ya que no es constante en todas las imágenes de las bases de datos. Para mejorar de brillo se utiliza una corrección gamma. La corrección gamma se define como la relación entre el valor numérico de un píxel y su luminancia real. La imagen final se puede ver en la figura 3.8, donde la imagen a la izquierda es la imagen de entrada original y la imagen de la derecha la imagen final, donde ya se implementó el filtro CLAHE y la corrección gamma.

El resultado de este paso se puede ver en la Fig. 3.8)



Figura 3.8: Resultado de preprocesamiento de imagen. A la izquierda imagen original; a la derecha imagen preprocesada.

3.3. Segmentación y clasificación de vasos sanguíneos.

3.3.1. Aumento de datos.

Las bases de datos para la segmentación y clasificación de vasos retinianos no suelen ser grandes debido a su naturaleza. Para abordar este problema se hace un aumento de datos para mejorar el entrenamiento de la red neuronal.

Se implementa un aumento de datos mediante la extracción de parches aleatorios de cada imagen, haciendo giros vertical y horizontal aleatoriamente en cada parche. Con la intención de aumentar artificialmente los datos y agregar más variabilidad al conjunto de datos de entrenamiento. En la Fig. 3.9) podemos ver algunos parches extraídos con sus respectivas etiquetas.

3.3.2. Arquitectura para la clasificación de vasos.

En el clasificador propuesto se usan bloques ConvLSTM bidireccionales y parte reducida de la estructura U-net como se muestra en la Fig. 3.10). La estructura original, de U-net está compuesta por una parte de codificación, donde se captura la información semántica y la contextual a medida que se duplica el número de filtros. La segunda parte es la decodificación, donde se restaura

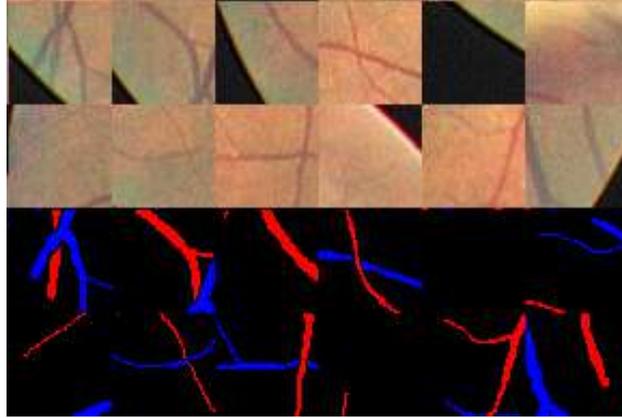


Figura 3.9: Ejemplo de extracción de parches. Dos filas superiores imágenes; dos filas inferiores etiquetas.

la información espacial y se fusionan las características obtenidas en los niveles más bajos.

La estructura propuesta consta de 2 niveles, en los que se aplican una doble convolución con un filtro de 3×3 , cada una seguida de una unidad lineal rectificadora (ReLU), una operación de agrupación máxima de 2×2 con paso de 2 para disminuir la resolución. La imagen de entrada es de 3 canales con un tamaño de 64×64 . En el primer nivel el número de canales utilizados fue de 64 y el tamaño de la imagen 32×32 tras dobles convoluciones. En el segundo nivel el número de canales utilizados fue de 128 y el tamaño de la imagen 16×16 . La parte de decodificación sigue la estructura anterior, el número de canales fue el mismo, pero en sentido contrario. También se añaden las características que se encuentran en cada uno de los diferentes niveles, concatenando la salida del nivel de contracción con la entrada de expansión.

Los mapas de características correspondientes a la capa de codificación tienen una resolución más alta, mientras que los mapas de característica correspondientes a la decodificación contienen más información semántica. En lugar de una simple concatenación en esta propuesta se hace la combinación de estos dos mapas de características con ConvLSTM bidireccional inspirado en (Azad, Asadi-Aghbolaghi, Fathy, y Escalera, 2019). Después de cada capa de convolución se aplica una capa de normalización por bloque y la función de activación ReLU.

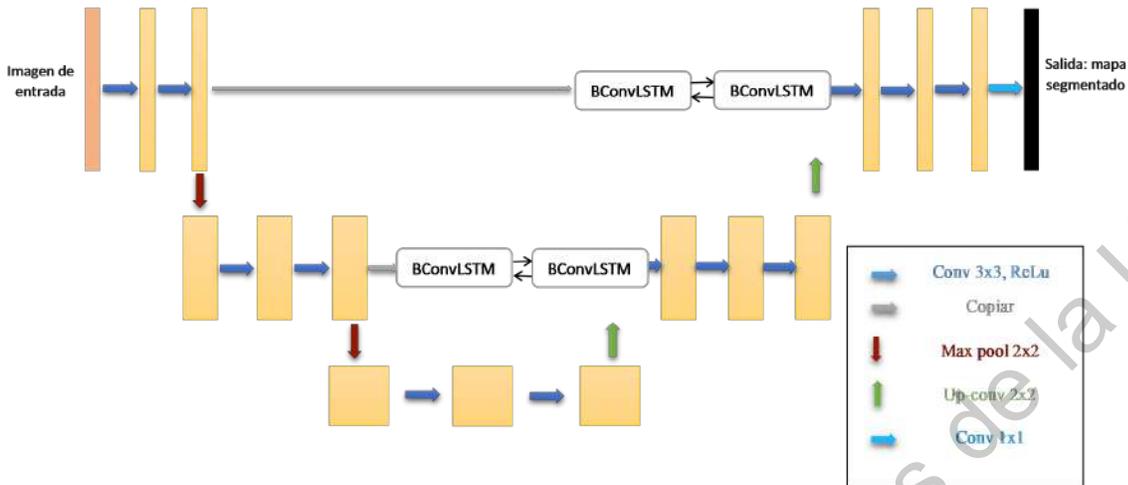


Figura 3.10: Arquitectura propuesta.

3.3.3. LSTM

La red neuronal recurrente LSTM o red neuronal recurrente de largo y corto plazo de memoria, propuesta por Hochreiter y Schmidhunder en 1997 (Lipton, Berkowitz, y Elkan, 2015), forman parte del aprendizaje profundo. Esta red recurrente es la utilizada principalmente en el presente trabajo. A diferencia de una red neuronal recurrente simple que forma una memoria a largo plazo en forma de pesos entre las neuronas, los cuales se van modificando durante el entrenamiento de la red y una memoria a corto plazo definida en las funciones de activación entre la comunicación de los nodos de las neuronas. El modelo LSTM introduce un bloque de memoria interno, compuesto por bloques simples conectados de forma específica, cada uno de los cuales se describen a continuación (Hua et al., 2019):

3.4. Ejecución del algoritmo.

Posteriormente se realizará el diseño de la red neuronal profunda, se ejecutará el algoritmo sobre la red de imágenes procesadas para efectuar la detección de los elementos de interés; en esta parte se entrenan y evalúan las imágenes pasadas en lote, se calcula el error y se ajustan los pesos,

todo este proceso es un ciclo sujeto a cambios de arquitecturas hasta lograr los mejores índices de rendimiento y se realiza una interpretación de los resultados obtenidos.

3.5. Detección de disco óptico y determinación del ROI

La detección de disco óptico es fundamental para realizar la medición del calibre de los vasos retinianos, ya que la medición del calibre se hace en todas las imágenes a un radio equivalente, tomando el centro del disco óptico como punto central de los círculos tomados para medir. El procedimiento para la detección del disco óptico se muestra en la figura 3.11.

Como ya se mencionó anteriormente las imágenes de las 3 bases de datos son RGB, a pesar de que la imagen en su mayoría esta compuesta de tonos rojos, el canal que más da información sobre los vasos sanguíneos es el canal verde, por lo cual el primer paso es la extracción del canal verde de la imagen como se muestra en la figura 3.11 inciso b). El segundo paso es la extracción del canal cyan del modelo de color CMYK, el canal cyan es el inverso del canal rojo del modelo de color RGB, la manera de obtenerlo en una imagen es como se muestra en la ecuación 3.3, el resultado se puede ver en la figura 3.11 inciso c).

$$Cyan = 1 - Img(:, :, 1) \quad (3.3)$$

donde $Img(:, :, 1)$ es igual al canal rojo.

El tercer paso es hacer una resta entre los dos canales obtenidos, es decir al canal verde se le resta el canal cyan, el resultado de la resta se muestra en la figura 3.11 inciso d).

Por ultimo se hace una binarización, donde se dejan pasar los valores mayores a 0.7, tomando en cuenta una escala de 0 a 1. El sistema no segmenta el disco óptico por lo cual se hace una suposición de que el diámetro de circulo es constante entre las imágenes de cada base de datos.

Una vez encontrado el centro de disco óptico, lo que se hace es determinar el área de interés para realizar la medición, de acuerdo a lo encontrado en la literatura, (Wong et al., 2003). El ROI consta de varias regiones circulares cuyo tamaño se basa en el diámetro aproximado del disco

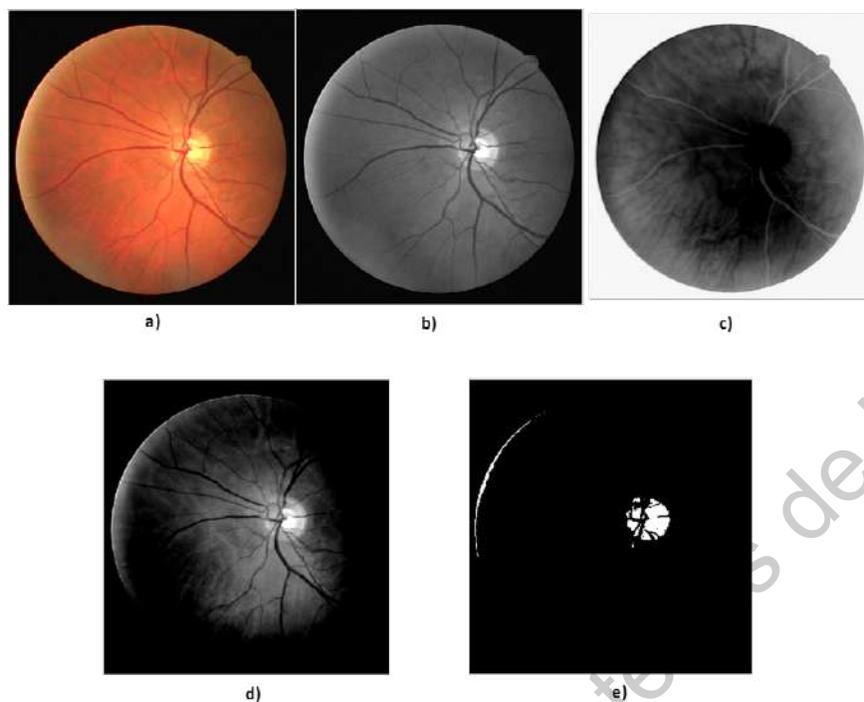


Figura 3.11: Proceso de detección del disco óptico: a) imagen original, b) canal verde, c) canal cyan, d) canal verde - cyan

óptico. La región A está entre 0.5 y 1 veces el diámetro de disco desde el centro del disco óptico y la región B, donde se toman las medidas del vaso, está entre 1 y 1.5 veces el diámetro de disco desde el centro del disco óptico, como se muestra en la figura 3.12 . Todos los análisis y evaluaciones realizados para comparar nuestro trabajo se basan en mediciones dentro de la región B.

3.6. Medición del calibre de los vasos.

Una vez ya segmentada el área de interés B, se mide el calibre de cada vaso. Para realizar esta medición, se implemento la metodología que se explicara a continuación.

La medición se hace por separado para venas y para arterias. Se crean dos círculos, pseudocódigo 3.6.1 con centro en el centro del disco óptico, el primer círculo C1 de tamaño de 1 diámetro de disco y el segundo círculo C2 con radio 4 píxeles más grande que C1. Al crear estos círculos se debe considerar que no sean mayores al tamaño de la imagen, esto para asegurar que se pueda hacer la medición en las imágenes que no estén centradas en el disco óptico, como es el caso de la

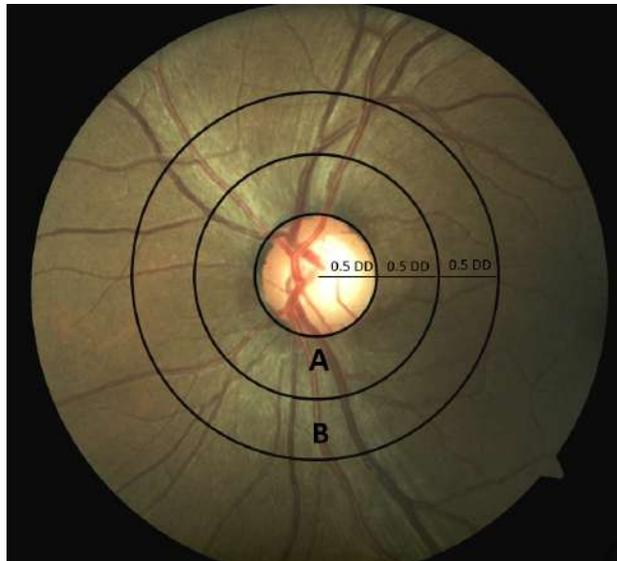


Figura 3.12: Imagen etiquetada con las diferentes áreas de interés.

base de datos DRIVE.

Dentro de estos dos círculos se busca en la imagen ya segmentada el inicio de cada vaso, iniciando con un ángulo de 270 grados y continua a favor de las manecillas del reloj, de tal manera que se guarda en una matriz el punto (x, y) de cada vaso, el ángulo en el que fue encontrado, esto mismo se hace para C2. Posteriormente se busca en C2 el punto (x, y) con el ángulo más cercano en cada uno de los puntos de la matriz de C1, esto con la finalidad de asegurarnos que C1 y C2 encontraron el punto inicial del mismo vaso. En el pseudocódigo 3.6.2 se realiza lo explicado.

Una vez teniendo los puntos de inicio de cada vaso de C1 (P1), y los puntos de inicio de cada vaso de C2 (P2), se prosigue a la medición del calibre de cada vaso. Esta medición se hace con la ayuda del punto encontrado en C1, es decir P1 y el punto encontrado en C2, es decir P2. Se crea una línea entre el punto P1 y P2 de cada vaso, y se calcula la pendiente de la línea entre P1 y P2 (L1) con la ecuación 3.4.

$$m1 = \frac{y2 - y1}{x2 - x1} \quad (3.4)$$

donde m es la pendiente, $(x1, y1)$ corresponden al punto P1 y $(x2, y2)$ corresponden al punto

Algoritmo 3.6.1: Circulo en centro de disco óptico

```
1 Entrada Tamaño Imagen (sx, sy), Centro de DO C(x,y), Radio (r), t, n
2 Salida Circulo (x, y)
3 Circle sx, sy, C, r, t, n
4    $x = c(1) + r \sin(t)$ 
5    $y = c(1) + r \cos(t)$ 
6   for  $j \leftarrow 1$  to  $n$  by 1 do
7     if  $x(j) < 1$  then
8        $x(j) = 1$ 
9     else if  $x(j) > sx$  then
10       $x(j) = sx$ 
11     else
12       $x(j) = x(j)$ 
13     end
14     if  $y(j) < 1$  then
15        $y(j) = 1$ 
16     else if  $y(j) > sy$  then
17        $y(j) = sy$ 
18     else
19        $y(j) = y(j)$ 
20     end
21   end
22   return  $x, y$ 
23 end
```

P2.

La pendiente de la línea L1 se calcula con la finalidad de obtener la ecuación de la recta perpendicular a ella, ya que esta línea perpendicular (L2) corresponde a la línea donde se debe medir el calibre de los vasos. Esto se hace para reducir el error al realizar la medición del calibre de los vasos.

Como se busca que L2 sea perpendicular a L1, se calcula la pendiente de L2 haciendo uso del teorema de las pendientes de rectas perpendiculares: "Dos rectas cuyas pendientes son m_1 y m_2 , son perpendiculares si y sólo si $m_1 m_2 = -1$ ", por lo cual podemos deducir la ecuación 3.5,

$$m_2 = \frac{-1}{m_1} \quad (3.5)$$

Algoritmo 3.6.2: Búsqueda del punto de inicio de cada vaso

```
1 Entrada Vasculatura ( $V$ ), Centro de disco óptico ( $C$ ), Circulo 1 ( $x, y$ ), Circulo2 ( $x_2, y_2$ ), número de vasos  
   ( $n$ )  
2 Salida Vasos encontrados en circulo 1 y 2  
3 FindVessels ( $V, t, n, C, x, y, x_2, y_2$ ):  
4    $k = 0$   
5    $flag = 0$   
6    $cont = 0$   
7    $l = 0$   
8    $flag2 = 0$   
9    $cont2 = 0$   
10  for  $i \leftarrow 1$  to  $n$  by 1 do  
11    if  $V(x(i), y(i)) \geq 0.6$  then  
12       $cont + = 1$   
13      if  $flag == 0$  then  
14         $flag = 1$   
15         $k + = k$   
16         $Vessel(k, 1) = x(i)$   
17         $Vessel(k, 2) = y(i)$   
18      end  
19       $Vessel1(k, 3) = x(i)$   
20       $Vessel1(k, 4) = y(i)$   
21       $Vessel1(k, 4) = cont$   
22    else  
23       $flag = 0$   
24       $cont = 0$   
25    end  
26    if  $V(x1(i), y1(i)) \geq 0.6$  then  
27      if  $flag2 == 0$  then  
28         $flag2 = 1$   
29         $l + = l$   
30         $Vessel2(l, 1) = x1(i)$   
31         $Vessel2(l, 2) = y1(i)$   
32         $Vessel2(l, 3) = t(i)$   
33      end  
34    else  
35       $cont2 + = cont2$   
36      if  $cont > 3$  then  
37         $flag2 = 0$   
38         $cont2 = 0$   
39      end  
40    end  
41  end  
42  return  $Vessel1, Vessel2$   
43 end
```

Ya conocemos la pendiente de la recta L2, y tenemos el punto inicial P1, con esta información ya es posible conocer la ecuación de la recta 3.11. La figura 3.13 muestra un esquema gráfico de lo explicado anteriormente.

$$y - y_0 = m(x - x_0) \quad (3.6)$$

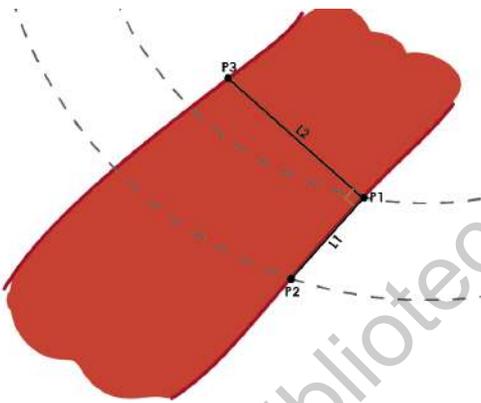


Figura 3.13: Visualización del cálculo de calibre de cada vaso.

Teniendo la ecuación de la recta L2, que es la recta que se usará para medir el calibre, prosigue encontrar el punto P3 que es el punto final de la distancia para la medición del calibre. Para encontrar P3 se hace una búsqueda en el punto siguiente (P_s) por la derecha y por la izquierda sobre la recta L2. Debido a que los vasos van en todas direcciones, como se muestra en la figura 3.14 y la recta L2, en los cuatro cuadrantes de círculo las variables x y y del punto P_s son diferentes, en el vaso 1 y 2 de la figura se busca por la derecha y en los vasos 3 y 4 se busca por izquierda.

Para encontrar el valor siguiente (P_s) a P1 de la recta L2 por la derecha (Pd) y por la izquierda (Pi) se requiere encontrar el paso constante que tendrá sobre el eje x , ya que las pendientes siempre serán distintas y pueden llegar a tomar todos los valores posibles, si ponemos un aumento de contante de un píxel, en las pendientes más inclinadas habrá un paso en Y muy grande y estará fuera del área del vaso que se este midiendo, en el pseudocódigo 3.6.3 se describe el código. Para solucionar este problema se toma la distancia de P1 a P_s como la hipotenusa de un triángulo rec-

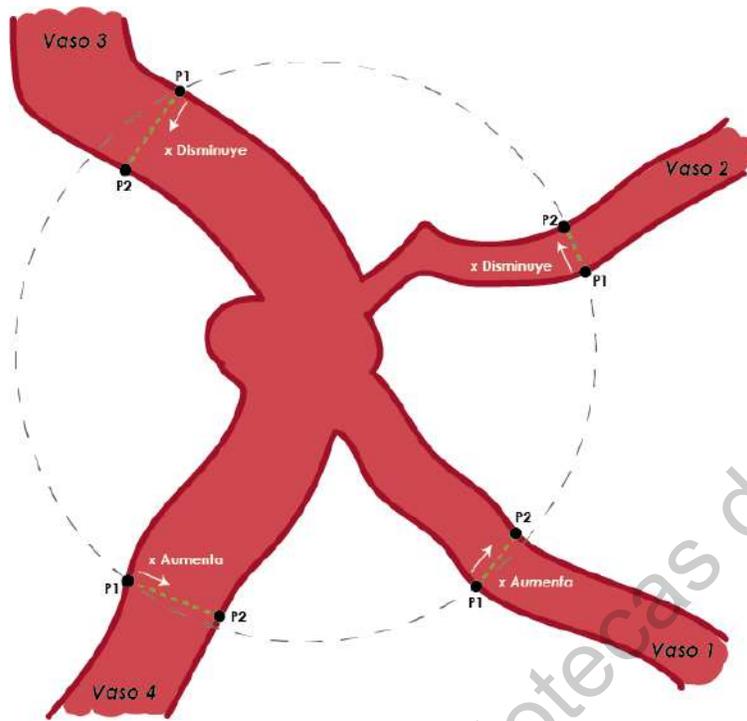


Figura 3.14: Demostración de vasos colocados en los cuatro cuadrantes.

tángulo, como se muestra en la figura 3.15

El ángulo que una recta forma con el eje horizontal está relacionado con la pendiente, por medio de la ecuación,

$$\theta = \arctan(m) \quad (3.7)$$

donde, θ es el ángulo entre L2 y el x_{Ps} y m la pendiente de L2.

Haciendo uso de las funciones trigonométrica, tenemos que,

$$\cos \theta = \frac{C.a}{h} \quad (3.8)$$

donde $C.a$ es el aumento que debe tener x , es decir ΔX , y h es la distancia de P1 a Ps.

La distancia entre P1 y Ps se eligió siempre de 1 por lo cual, despejando $c.a$, tenemos que el

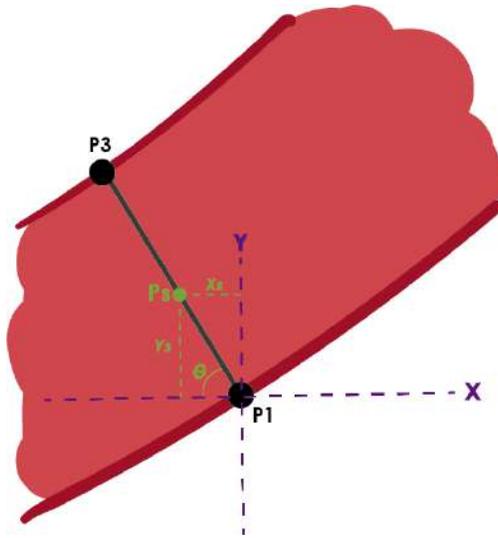


Figura 3.15: Demostración del calculo del incremento en el eje x.

aumento en x es,

$$\Delta X = \cos \theta \quad (3.9)$$

tenemos que,

$$x_{ps} = \Delta X + x_{p1} \quad (3.10)$$

para buscar a la derecha, o,

$$x_{ps} = -\Delta X + x_{p1} \quad (3.11)$$

para buscar a la izquierda.

De esta manera ya se puede saber el valor de y_{ps} y si se busca a la derecha o a la izquierda el valor de $P3$. Se hace esto en la dirección correcta hasta que se encuentra $P3$, que es el punto final de la recta $L2$.

Con el punto $P1$ y $P3$ ya se puede calcular el calibre de cada vaso, aplicando la fórmula de la distancia entre dos puntos,

$$d = \sqrt{(x_{ps} - x_{p1})^2 + (y_{ps} - y_{p3})^2} \quad (3.12)$$

Algoritmo 3.6.3: Cálculo de ΔX

```
1 Entrada indice del vaso (i), Vasos encontrados en C1 y C2(Vessel1, Vessel2)
2 Salida aumento en x (step), pendiente de L2(m2), Ángulo (theta)
3 Fstep (i, Vessel1, Vessel2):
4    $r = \text{knn}(Vessel1(:, 1 : 2), Vessel2(i, 1 : 2))$ 
5    $m1 = (Vessel2(r, 2) - Vessel1(i, 2)) / (Vessel2(r, 1) - Vessel1(i, 1))$ 
6    $m2 = -1 / m1$ 
7    $theta = \arctan(m)$ 
8    $step = \cos(theta)$ 
9   return step, m2, theta
10 end
```

Este procedimiento se implementa en cada vaso encontrado, se hace tanto para venas como arterias. Las venas se encuentran en el canal 3 de la imagen ya que son de color azul y las arterias en el canal 1 ya que son color rojo. En el pseudocódigo 3.6.4 es el encargado de hacer el proceso antes descrito, dando como salida un vector con el valor correspondiente al calibre de cada vaso.

3.7. Cálculo de la relación arteria y vena (AVR)

La relación arteria y vena se define como

$$AVR = \frac{CREA}{CRVE} \quad (3.13)$$

donde, *CREA* es equivalente a la arteria central de la retina y *CRVE* es equivalente a la vena central de la retina.

Para realizar el cálculo de AVR, Kudtson (Knudtson et al., 2003) propuso un método donde readaptó las fórmulas existentes, en este trabajo se realiza una experimentación para calcular el coeficiente de ramificación y se hace el cálculo del calibre para CRAE y CRVE. En este método se ingresan las seis venas y las seis arterias más anchas encontradas en la imagen, aun que es posible utilizar una cantidad menor de vasos si no se llega a contar con 6 vasos. Las fórmulas que

Algoritmo 3.6.4: Cálculo del calibre de vasos retinianos

```
1 Entrada Imagen de vasculatura V, Vasos encontrados en C1 y C2(Vessel1, Vessel2)
2 Salida Calibre caliber
3 CaliberCalculation (V, Vessel1, Vessel2):
4   for i ← 1 to length(Vessel2) by 1 do
5     [step, m, theta] = Fstep(i, Vessel1, Vessel2)
6     xp1 = Vessel1(i, 1) + step
7     yp1 = m(Vessel1(i, 1) - xp1) + Vessel1(i, 2)
8     p1 = V(xp1, yp1)
9     xp2 = Vessel1(i, 1) - step
10    yp2 = m(Vessel1(i, 1) - xp2) + Vessel1(i, 2)
11    p2 = V(xp2, yp2)
12    if V(xp1, yp1) >= 0.6 then
13      past = 0
14      while p1 >= 0.6 do
15        xp1 = Vessel1(i, 1) + step
16        yp1 = m(Vessel1(i, 1) - xp1) + Vessel1(i, 2)
17        step = step + 0,1 cos(theta)
18        p1 = V(xp1, yp1)
19      end
20    end
21    if V(xp2, yp2) >= 0.6 then
22      past = 0
23      while p1 >= 0.6 do
24        xp2 = Vessel1(i, 1) + step
25        yp2 = m(Vessel1(i, 2) - xp2) + Vessel1(i, 2)
26        step = step + 0,1 cos(theta)
27        p2 = V(xp2, yp2)
28      end
29      xp1 = xp2
30      yp1 = yp2
31    end
32    d1(i) =  $\sqrt{(xp1 - Vessel1(i, 1))^2 + (yp1 - Vessel1(i, 2))^2}$ 
33    d2(i) =  $\sqrt{(Vessel1(i, 3) - Vessel1(i, 1))^2 + (Vessel1(i, 4) - Vessel1(i, 2))^2}$ 
34    dif = d1(i) - d2(i)
35    if dif > 3 then
36      caliber(i) = d2(i)
37    end
38    caliber(i) = d1(i)
39  end
40  return caliber
41 end
```

se proponen son las de la ecuación 3.14 y 3.15.

$$WA = 0,88\sqrt{w_1^2 + w_2^2} \quad (3.14)$$

donde WA es igual a $CREA$, w_1 el calibre del vaso más estrecho y w_2 el calibre del vaso más ancho.

$$WV = 0,95\sqrt{w_1^2 + w_2^2} \quad (3.15)$$

donde WV es igual a $CRVE$, w_1 el calibre del vaso más estrecho y w_2 el calibre del vaso más ancho.

Algoritmo 3.7.1: Cálculo de AVR

```

1 Entrada Vector con el calibre de todas las arterias encontradas ( $da$ ), Vector con el
   calibre de todas las venas encontradas ( $dv$ )
2 Salida Valor de la relacion arteria y vena (AVR)
3 AVRCalculation ( $i, Vessel1, Vessel2$ ):
4   Ordenar ascendente vector  $da$ 
5   Ordenar ascendente vector  $dv$ 
6   for  $i \leftarrow 1$  to 3 by 1 do
7      $W_{a1}(i) = 0,88\sqrt{da(i)^2 + da(7-i)^2}$ 
8      $W_{v1}(i) = 0,95\sqrt{dv(i)^2 + dv(7-i)^2}$ 
9   end
10  Ordenar vector  $W_{da}$ 
11  Ordenar vector  $W_{dv}$ 
12   $AVR = \frac{W_{da}}{W_{dv}}$ 
13  return AVR
14 end

```

De esta manera se calculó el AVR, el pseudocódigo 3.7.1 muestra la descripción en código de lo explicado. Las entradas son el calibre de todos los vasos, están separados en arteria y en vena, se ordenan de mayor a menor y se hace el calculo, para las venas: se hace el calculo de la vena mayor, es decir la que ocupa la posición 1 del vector, y la vena menor, es decir la posición 1; después la vena de la posición 2 con la vena de la posición 5; la vena de la posición 3 con la vena de la posición 4. Al finalizar se tendrá 3 valores distintos de WV, donde se ordenan y se volverá a aplicar

las formulas, se aplica al mayor con el menor y al resultado se aplica de nuevo la formula con el resultado faltante.

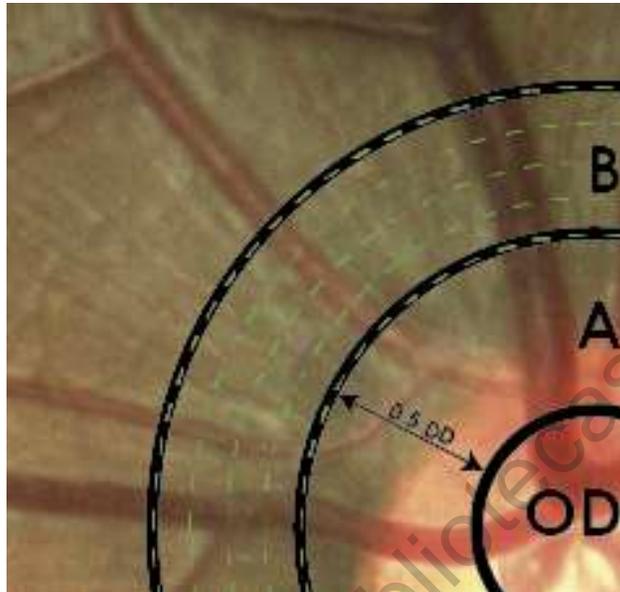


Figura 3.16: Detalle de una fotografía de fondo de ojo donde se muestran los distintos diámetros tomados para calcular el AVR.

Como ya se explico, el calculo de AVR se realiza en la sección B marcada en la figura 3.12, para disminuir el error y asegurarnos que todos los vasos que se encuentran en la sección B entran en el calculo, el calculo de AVR se repite en varios diámetros dentro del ROI como se muestra en la figura 3.16. Dentro del ROI se, seleccionaron seis diámetros distintos para hacer las mediciones de AVR. Los diámetros inicial y final del ROI son 1 DD y 1.5 DD, se realizaron divisiones de 0.1 DD dentro de los valores iniciales y finales. Para cada diámetro se realizo el procedimiento de calculo de AVR. Los seis valores resultantes de AVR se promediaron para llegar a la estimación final de AVR.

Tabla 3.1: AVR normal en los diferentes grados de retinopatía hipertensiva.

Grado	AVR
Normal.	0.66 - 0.75
Grupo 1.	0.5 - 0.66
Grupo 2.	0.33 - 0.50
Grupo 3.	0.25 - 0.33
Grupo 4.	menor a 0.25

3.8. Diagnóstico de retinopatía hipertensiva

Como ya se comentó en la introducción, la retinopatía hipertensiva se clasifica en 4 grupos, marcados por diferentes patologías detectables en imágenes de retina. Uno de los signos que se encuentra en es el estrechamiento de arterias, en la tabla 3.1 se muestra los diferentes valores de AVR de los cuatro grupos de retinopatía hipertensiva y en las personas sanas (Narasimhan, Neha, y Vijayarekha, 2012).

Resultados y Discusión

En este capítulo se mostrarán los resultados obtenidos en este proyecto, incluyendo los resultados obtenidos en la clasificación de vasos implementada en la arquitectura de CNN, los resultados del calibre de los vasos, la relación arteria y vena y por último la clasificación asignada a cada imagen, es decir si el AVR es normal o pertenece a retinopatía hipertensiva.

4.1. Resultados de clasificación de vasos mediante la CNN

4.1.1. Métricas de evaluación.

Las métricas usadas para la evaluación del desempeño del modelo son sensibilidad, especificidad y exactitud. El cálculo de estas métricas se basa en cuatro posibles interpretaciones de los datos:

- Verdadero positivo (TP): la etiqueta de la muestra es positiva y se clasifica como tal.
- Verdadero negativo (TN): la etiqueta de la muestra es negativa y se clasifica como tal.
- Falso positivo (FP): la etiqueta de la muestra es negativa, pero se clasifica como positiva.
- Falso negativo (FN): la etiqueta de la muestra es positiva, pero se clasifica como negativa.

En función de estos valores, se pueden calcular las métricas mencionadas anteriormente de acuerdo a las ecuaciones 4.1, 4.2, 4.3.

- Sensibilidad: También llamada tasa de Verdaderos Positivos. Es la proporción de casos positivos que fueron correctamente identificados.

$$\text{Sensibilidad} = \frac{TP}{TP + FN} \quad (4.1)$$

- Especificidad: También llamada Tasa de Verdaderos Negativos. Casos negativos que se clasificaron correctamente.

$$\text{Especificidad} = \frac{TN}{TN + FP} \quad (4.2)$$

- Exactitud: Mide cuántas observaciones, tanto positivas como negativas, se clasificaron correctamente. Es la proporción de instancias negativas que se clasifican incorrectamente como positivas.

$$\text{Exactitud} = \frac{TP + TN}{TP + FP + FN + TN} \quad (4.3)$$

4.1.2. Resultados Clasificación de vasos retinianos

En la figura 4.1 se puede ver un ejemplo de un resultado obtenido del conjunto de datos DRIVE utilizando la arquitectura de red CNN antes mencionada. Los falsos negativos son especialmente vasos retinianos pequeños que no se alcanzan a detectar. En los vasos mayores a 5 píxeles, los falsos positivos se ubican en los bordes. Existe una confusión entre arteria y vena o viceversa en los vasos más pequeños o en los puntos de intersección entre estos dos. A pesar de la confusión que existe en las intersecciones, en la mayoría de los casos esto se corrige a lo largo de la extensión del vaso.

En la figura 4.2 se proporciona la curva ROC (Receiver Operating Characteristic) y en la figura 4.3 la curva PR (Precision-Recall) para la segmentación arteria y vena. La curva ROC muestra el rendimiento de un modelo de clasificación, el área bajo la curva es de 0.9722 para este modelo. La

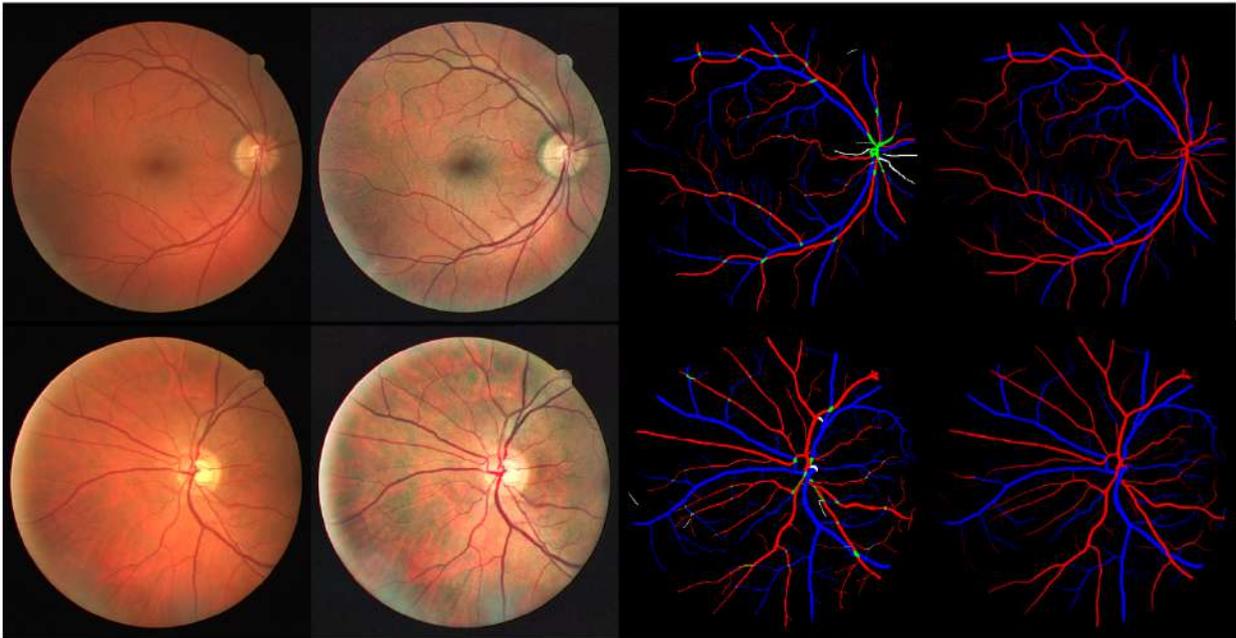


Figura 4.1: Resultado de clasificación de arteria y vena de dos imágenes. Iniciando con la primera a la izquierda, imagen original; segunda imagen, preprocesamiento; tercera imagen verdad fundamental; última imagen salida clasificada

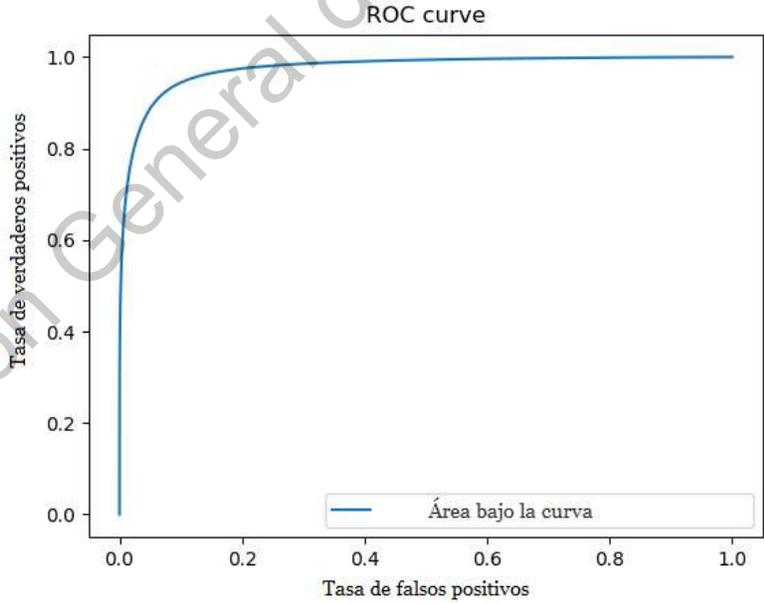


Figura 4.2: Rendimiento de segmentación A / V en DRIVE.

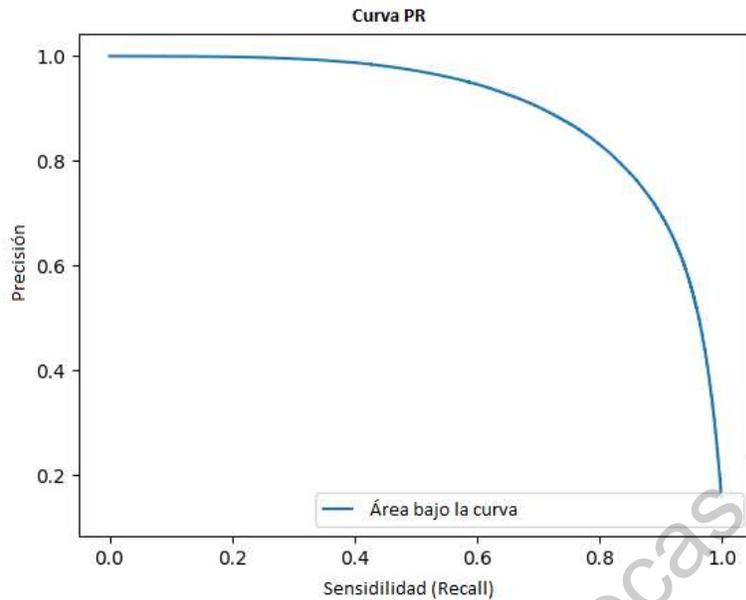


Figura 4.3: curva Precision-Recall para segmentación A / V en DRIVE.

curva traza la sensibilidad contra especificidad, parámetros de tasa de verdaderos positivos y tasa de falsos positivos. La curva PR tiene un área bajo la curva de 0.9003, esta gráfica permite ver a partir de que sensibilidad se tiene una degradación de la precisión y viceversa, esta curva se centra principalmente en el rendimiento de la clase positiva.

Analizando detalladamente algunos errores de la clasificación realizada por la red, se puede observar que algunos tramos de los vasos son clasificados erróneamente, en la figura 4.4 se muestran algunos ejemplos de este tipo de errores. En su mayoría, los vasos clasificados mal son venas, en pequeños tramos se clasifican como arterias, esto debido a que las venas son de color más intenso que las arterias pero esta diferencia no se puede hacer en toda la vasculatura. En algunos tramos la diferencia entre vena y arteria es irreconocible. Todos los métodos propuestos en la literatura presentan este tipo de problemas.

En la tabla 4.1 podemos ver una comparación de trabajos similares basados en el conjunto de datos DRIVE, donde se observa sensibilidad, especificidad y exactitud, métricas descritas anteriormente.

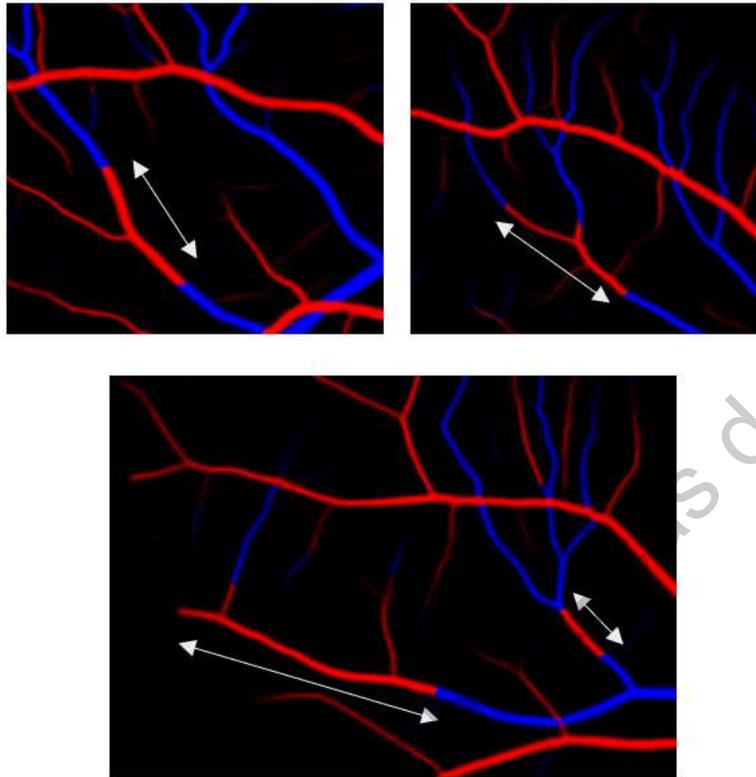


Figura 4.4: Errores de clasificación de arteria y vena.

Tabla 4.1: Comparación de resultados de clasificación Vena/Arteria con estado del arte en base de datos DRIVE.

Método	Sensibilidad	Especificidad	Exactitud
(Estrada et al., 2015)	0.9170	0.9170	0.9100
(Xu et al., 2017)	-	-	0.9230
(Welikala et al., 2017)	0.7810	-	0.9190
(Xu et al., 2018)	0.8700	0.9800	0.8320
(Girard et al., 2019)	0.9370	0.9290	0.9493
Propuesto	0.8000	0.9780	0.9550

4.2. Resultados de la detección de disco óptico

Aunque comúnmente, el diagnóstico de RH se realiza en imágenes centradas en el disco óptico, se obtuvieron buenos resultados en imágenes centradas en la macula como todas las de la base de datos DRIVE. En la base de datos DRIVE no se pudo detectar el centro del disco óptico en 5 imágenes, debido a la tonalidad oscura que presentan algunas imágenes. Por ello en estas 5 imágenes no se pudo realizar un diagnóstico de RH.

En la base de datos INSPIRE y la base de datos creada se detectó el disco óptico en todas las imágenes de una manera adecuada, en la figura 4.5 se muestran algunos ejemplos de la detección del disco óptico.

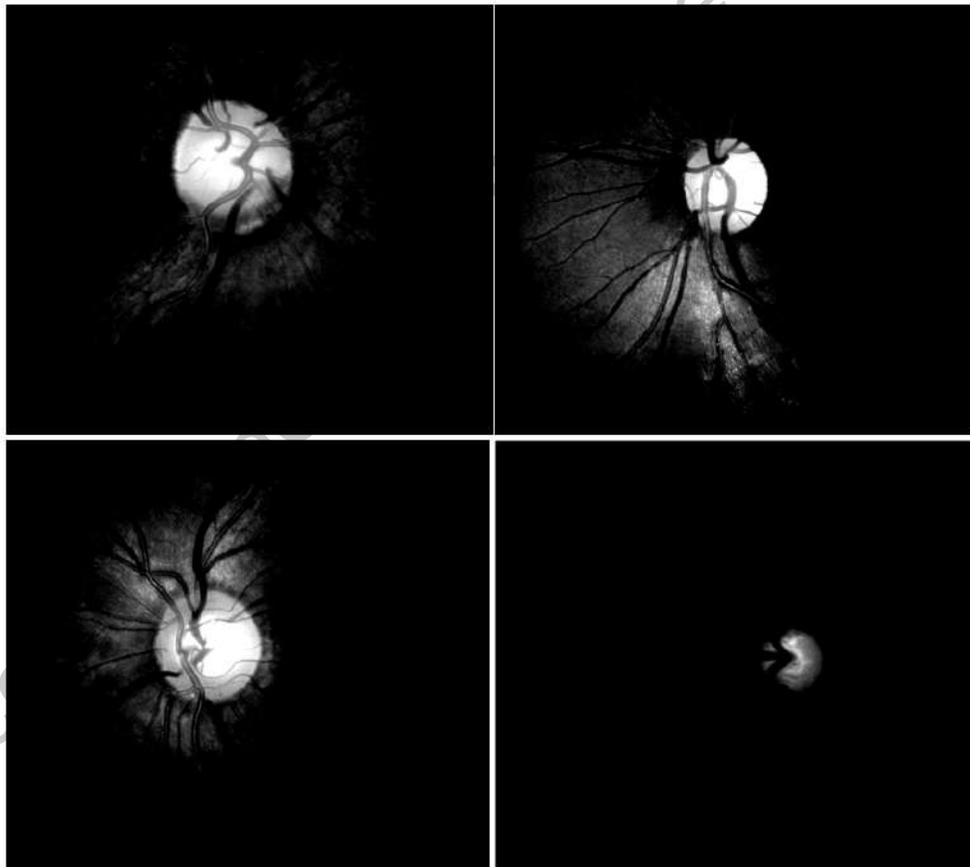


Figura 4.5: Detección de disco óptico en base propia.

4.3. Resultados del algoritmo para la medición del calibre

El algoritmo propuesto para la medición del calibre en los vasos, pudo detectar correctamente el grado de inclinación y medir de una manera perpendicular al vaso en la mayoría de estos, sobre las imágenes clasificadas dadas por la red neuronal. En la figura 4.6 se muestran algunos ejemplos donde se hace la medición, las líneas blancas es donde el algoritmo hizo la medición del calibre.

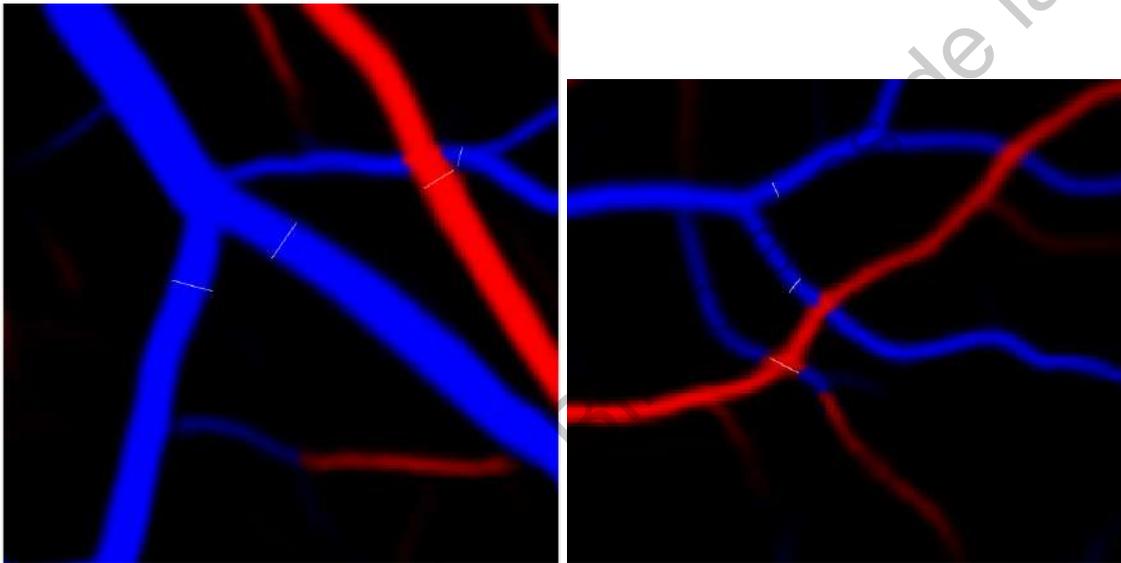


Figura 4.6: Medición del calibre de los vasos de manera perpendicular.

4.4. Resultados de la medición del AVR

4.4.1. Medición del AVR en la base de datos DRIVE

Para la base de datos DRIVE no existe un estándar de comparación, ya que es una base de datos donde las imágenes están centradas en la macula, y para la obtención del AVR las imágenes ideales son centradas en el disco óptico. En la tabla 4.2 se muestran los resultados de los valores de AVR de cada imagen. El algoritmo para la detección del disco óptico no pudo detectar 5 imágenes, y son las que aparecen como ND, 8 imágenes aparecen con un valor de AVR menor a 0.66.

Recordemos que en la base de datos solo 7 imágenes cuentan con una patología, la demás son imágenes aparentemente sanas. En la figura 4.7 se muestran 4 imágenes que salieron con el AVR bajo, dos de ellas tiene patologías visibles.



Figura 4.7: Imágenes con AVR menor a 0.66

4.4.2. Medición del AVR en la base de datos INSPIRE

Como se menciono anteriormente la base de datos INSPIRE cuenta con 40 imágenes de retina centradas es el disco óptico, en las cuales se midió el AVR por (Niemeijer et al., 2011), que es nuestro punto de comparación, en el articulo, se utilizó un programa informático semiautomático

Tabla 4.2: Resultados AVR de base de datos DRIVE

Número de imagen	AVR	Conclusión
Imagen 1.	0.6675	Sano
Imagen 2.	0.6801	Sano
Imagen 3.	ND	ND
Imagen 4.	0.6822	Sano
Imagen 5.	0.6671	Sano
Imagen 6.	0.6284	RH
Imagen 7.	0.6712	Sano
Imagen 8.	ND	ND
Imagen 9.	0.6276	RH
Imagen 10.	0.6889	Sano
Imagen 11.	0.7906	Sano
Imagen 12.	0.6645	Sano
Imagen 13.	0.6575	Sano
Imagen 14.	0.6952	RH
Imagen 15.	0.7259	Sano
Imagen 16.	0.5863	RH
Imagen 17.	0.668	Sano
Imagen 18.	0.6486	Sano
Imagen 19.	0.7022	Sano
Imagen 20.	0.5537	RH
Imagen 21.	0.6884	Sano
Imagen 22.	0.7444	Sano
Imagen 23.	ND	ND
Imagen 24.	0.7227	Sano
Imagen 25.	0.6697	Sano
Imagen 26.	ND	ND
Imagen 27.	0.6434	RH
Imagen 28.	0.7096	Sano
Imagen 29.	0.6572	Sano
Imagen 30.	ND	ND
Imagen 31.	0.67	Sano
Imagen 32.	0.6755	Sano
Imagen 33.	0.7638	Sano
Imagen 34.	0.5815	RH
Imagen 35.	0.7205	Sano
Imagen 36.	0.6763	Sano
Imagen 37.	0.6243	RH
Imagen 38.	0.6638	Sano
Imagen 39.	0.702	Sano
Imagen 40.	0.6976	Sano
Media	0.6746	
Desviación Estándar	0.2303	64
Mínimo	0.5537	
Máximo	0.7905	

desarrollado por la Universidad de Wisconsin, Madison (IVAN) y dos expertos toman las medidas de AVR, los resultados se muestran en la tabla 4.3, en el artículo mencionado proponen un software para el cálculo automático de AVR y toman como referencia únicamente al primer observador y comparan sus resultados con el segundo observador. Para tener resultados confiables en el presente trabajo se realiza el promedio entre el resultado de AVR del primer experto y el segundo en cada imagen y ese se toma como patrón de referencia. En la tabla 4.3 se muestran los resultados de cada observador, el promedio, los resultados de (Niemeijer et al., 2011), el error de los resultados de (Niemeijer et al., 2011) respecto al promedio, los resultados del método propuesto y el error del método propuesto.

Para tener un panorama general de los resultados obtenidos del método propuesto y del (Niemeijer et al., 2011) se implementa el análisis de Bland-Altman, este análisis es un método gráfico que permite comparar dos técnicas de medición sobre una misma variable cuantitativa. El eje y corresponde a las diferencias entre los valores de los métodos y el eje x representa el valor de la media de ambos.

En la figura 4.8 se muestra el análisis de Bland-Altman del método propuesto, se puede observar que la media entre los dos grupos de datos, también conocida como bias, se encuentra en 0, es la línea punteada azul. Los límites superior e inferior, líneas naranjas, se encuentran a un 90 %. En la figura 4.9 se muestra el gráfico para el método de comparación donde se observa una mayor diferencia en los datos ya que la línea azul que representa la media da un valor de -0.01 y los límites son mayores. Los datos se observan más dispersados y existe un error mayor en el método de referencia.

4.4.3. Medición del AVR en la base de datos creada

Para facilitar el análisis de los resultados del cálculo del AVR de la base de datos creada se realizaron dos tablas, una tabla con los resultados del AVR de las personas sanas y otra con los

Tabla 4.3: Comparación de resultados de AVR de base de datos INSPIRE

Imagen	Obs. 1	Obs. 2	Media	Niemeijer	Error Ni.	Método propio	Error
1	0.7	0.71	0.705	0.62	0.085	0.69	0.015
2	0.63	0.68	0.655	0.81	0.155	0.75	0.095
3	0.7	0.65	0.675	0.81	0.135	0.69	0.015
4	0.65	0.64	0.645	0.76	0.115	0.68	0.035
5	0.78	0.75	0.765	0.59	0.175	0.7	0.065
6	0.65	0.65	0.65	0.8	0.15	0.76	0.11
7	0.67	0.65	0.66	0.7	0.04	0.68	0.02
8	0.64	0.71	0.675	0.59	0.085	0.65	0.025
9	0.69	0.76	0.725	0.68	0.045	0.68	0.045
10	0.56	0.85	0.705	0.74	0.035	0.75	0.045
11	0.64	0.74	0.69	0.58	0.11	0.65	0.04
12	0.76	0.75	0.755	0.74	0.015	0.7	0.055
13	0.57	0.62	0.595	0.68	0.085	0.6	0.005
14	0.62	0.58	0.60	0.77	0.17	0.62	0.02
15	0.64	0.61	0.625	0.57	0.055	0.59	0.035
16	0.68	0.68	0.68	0.7	0.02	0.71	0.03
17	0.52	0.45	0.485	0.6	0.115	0.58	0.095
18	0.62	0.63	0.625	0.59	0.035	0.52	0.105
19	0.67	0.63	0.65	0.67	0.02	0.61	0.04
20	0.71	0.62	0.665	0.67	0.005	0.67	0.005
21	0.57	0.58	0.575	0.55	0.025	0.6	0.025
22	0.72	0.76	0.74	0.58	0.16	0.71	0.03
23	0.66	0.69	0.675	0.71	0.035	0.68	0.005
24	0.65	0.64	0.645	0.67	0.025	0.62	0.025
25	0.56	0.49	0.525	0.59	0.065	0.55	0.025
26	0.73	0.61	0.67	0.74	0.07	0.73	0.06
27	0.64	0.63	0.635	0.63	0.005	0.64	0.005
28	0.63	0.68	0.655	0.69	0.035	0.6	0.055
29	0.72	0.7	0.71	0.6	0.11	0.65	0.06
30	0.59	0.61	0.6	0.66	0.06	0.7	0.1
31	0.75	0.75	0.75	0.61	0.14	0.68	0.07
32	0.53	0.61	0.57	0.68	0.11	0.63	0.06
33	0.61	0.59	0.6	0.61	0.01	0.59	0.01
34	0.65	0.61	0.63	0.71	0.08	0.61	0.02
35	0.74	0.64	0.69	0.68	0.01	0.63	0.06
36	0.69	0.62	0.655	0.59	0.065	0.64	0.015
37	0.82	0.79	0.805	0.64	0.165	0.81	0.005
38	0.93	0.76	0.845	0.72	0.125	0.78	0.065
39	0.61	0.64	0.625	0.7	0.075	0.65	0.025
40	0.74	0.62	0.68	0.81	0.13	0.64	0.04
Media	0.666	0.6595	0.66275	0.671	0.07875	0.6605	0.0415
S	0.080	0.077	0.069	0.073	0.052	0.062	0.029
Mínimo	0.52	0.45	0.485	0.55	0.005	0.52	0.005
Máximo	0.93	0.85	0.845	0.81	0.175	0.81	0.11

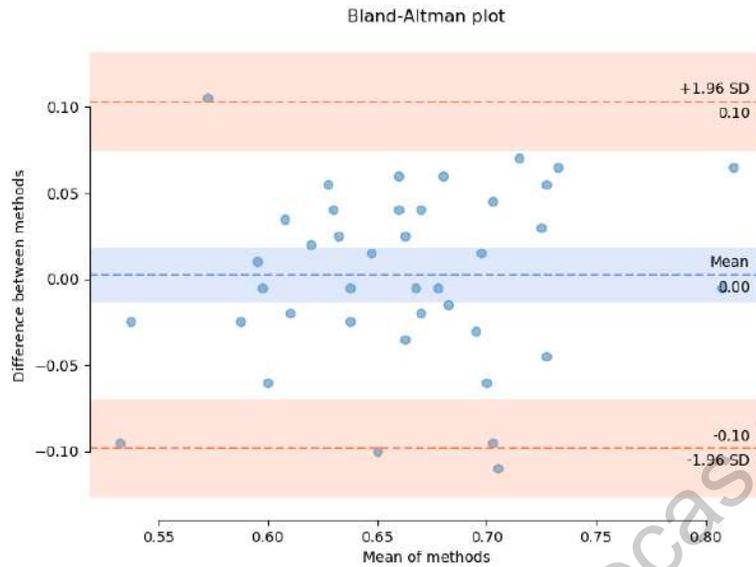


Figura 4.8: Gráfico de Bland-Altman entre el promedio de los dos observadores y el resultado del sistema propuesto.

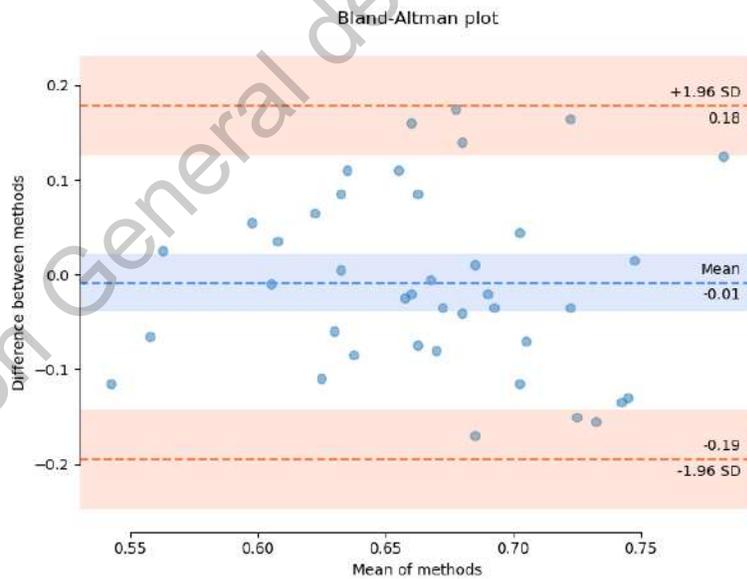


Figura 4.9: Gráfico de Bland-Altman entre el promedio de los dos observadores y la bibliografía de referencia.

resultados del AVR de las personas hipertensa.

En la tabla 4.4 se recopilaron los datos de las personas clínicamente diagnosticadas como hipertensas. En esta tabla se muestra el AVR de cada imagen calculado por la metodología antes propuesta y la predicción que el algoritmo hace de acuerdo al AVR calculado. El valor medio del AVR de las personas hipertensas es de 0.5880, el valor mínimo de 0.4433 y el valor máximo de 0.7342.

En la tabla 4.5 se recopilaron los datos de las personas que no fueron diagnosticadas sanas, es decir que no tienen hipertensión y que cuentan con los criterios de exclusión mencionados anteriormente. En esta tabla se muestra el AVR de cada imagen calculado por la metodología antes propuesta y la predicción que el algoritmo hace de acuerdo al AVR calculado. El valor medio es de 0.6552, el valor mínimo es de 0.5077 y el valor máximo de 0.8312.

Tabla 4.4: AVR de personas diagnosticadas como hipertensas de la base de datos creada

Diagnostico clínico	AVR	Predicción
Hipertenso 1	0.5416	Hipertenso
Hipertenso 2	0.5706	Hipertenso
Hipertenso 3	0.6613	No hipertenso
Hipertenso 4	0.6626	No hipertenso
Hipertenso 5	0.4605	Hipertenso
Hipertenso 6	0.5298	Hipertenso
Hipertenso 7	0.5673	Hipertenso
Hipertenso 8	0.6182	Hipertenso
Hipertenso 9	0.5947	Hipertenso
Hipertenso 10	0.4628	Hipertenso
Hipertenso 11	0.6935	No hipertenso
Hipertenso 12	0.6205	Hipertenso
Hipertenso 13	0.5971	Hipertenso
Hipertenso 14	0.6705	No hipertenso
Hipertenso 15	0.6899	No hipertenso
Hipertenso 16	0.6858	No hipertenso
Hipertenso 17	0.5797	Hipertenso
Hipertenso 18	0.4433	Hipertenso
Hipertenso 19	0.6162	Hipertenso
Hipertenso 20	0.7342	No hipertenso
Hipertenso 21	0.525	Hipertenso
Hipertenso 22	0.5696	Hipertenso
Hipertenso 23	0.517	Hipertenso
Hipertenso 24	0.5273	Hipertenso
Hipertenso 25	0.562	Hipertenso
Promedio	0.5880	
SD	0.0779	
Min	0.4433	
Max	0.7342	

Tabla 4.5: AVR de personas diagnosticadas como sanas de la base de datos creada

Diagnostico clínico	AVR	Predicción
Sano 1	0.6198	Hipertenso
Sano 2	0.7203	No hipertenso
Sano 3	0.7119	No hipertenso
Sano 4	0.7127	No hipertenso
Sano 5	0.6475	No hipertenso
Sano 6	0.7105	No hipertenso
Sano 7	0.6475	No hipertenso
Sano 8	0.6852	No hipertenso
Sano 9	0.5802	Hipertenso
Sano 10	0.6436	No hipertenso
Sano 11	0.592	Hipertenso
Sano 12	0.5105	Hipertenso
Sano 13	0.5975	Hipertenso
Sano 14	0.6551	No hipertenso
Sano 15	0.6388	No hipertenso
Sano 16	0.583	Hipertenso
Sano 17	0.5077	Hipertenso
Sano 18	0.5952	Hipertenso
Sano 19	0.6656	No hipertenso
Sano 20	0.8312	No hipertenso
Sano 21	0.8177	No hipertenso
Sano 22	0.6695	No hipertenso
Sano 23	0.7771	No hipertenso
Sano 24	0.6009	Hipertenso
Sano 25	0.66	No hipertenso
Promedio	0.6552	
SD	0.0807	
Min	0.5077	
Max	0.8312	

Conclusiones y trabajo futuro

En este trabajo se crea una base de datos de 60 imágenes centradas en el disco óptico, con sus etiquetas correspondientes a arteria y vena. Se propuso una arquitectura basada en una U-net modificada con bloques ConvLSTM bidireccionales para clasificar los vasos en arteria y vena. Se implementó una metodología para el cálculo del AVR a partir de la medición del calibre de los vasos. Con el valor del AVR se pudo clasificar imágenes como hipertensas o no hipertensas de acuerdo a la disminución del AVR provocado por el estrechamiento de las arterias consecuencia de la hipertensión.

El preprocesamiento de las imágenes de entrada a la CNN es de suma importancia, ya que resalta los vasos retinianos y corrige algunos problemas en la imagen causados por el estado patológico del fondo de ojo. Estos problemas pueden afectar la clasificación de arteria y vena, específicamente cuando existe una lesión obstruyendo los vasos. Cuando las lesiones son pequeñas el modelo clasifica correctamente pero cuando las lesiones son grandes y en un color contrastante al resto de la retina los vasos quedan ausentes o clasificados erróneamente. El preprocesamiento no solo mejoró los resultados del clasificador si no también se realizó para mejorar visualmente la diferencia de arteria y vena, y poder realizar la clasificación manual. En toda la literatura consultada para la clasificación de vasos se realiza un preprocesamiento y mejora la clasificación hecha por la CNN.

Acompañado del preprocesamiento, el aumento de datos es importante en el modelo propuesto. Las bases de datos usadas, por su naturaleza, cuentan con pocas imágenes para realizar un entrenamiento con una CNN, lo cual implementar aumento de datos por extracción de parches y girarlos aleatoriamente ayuda al entrenamiento. Contar con una cantidad mayor y variada de imágenes etiquetadas podría mejorar la clasificación, el modelo podría aprender más información de la estructura provocando que el modelo sea robusto para diferentes patologías severas que compliquen la clasificación de los vasos.

La clasificación de vasos retinianos es un problema de clases desbalanceadas, donde el fondo es aproximadamente el 93 % de la imagen, las venas el 4 % y las arterias el 3 %. Esto representa un problema para las CNN ya que la clase que mayor representa la imagen es el fondo, la CNN reconoce más fácilmente éste que los vasos. Los resultados de la CNN propuesta superar los vistos en la literatura. Se propone una red U-net con bloques ConvLSTM bidireccionales, los cuales ayudan a extraer características más complejas y mejoran la clasificación en áreas donde el balance es complicado.

El algoritmo propuesto para la medición del calibre en los vasos pudo detectar correctamente el grado de inclinación y medir el calibre de una manera perpendicular al vaso. Realizar la medición de manera perpendicular ayuda a realizar una medición estándar en cada uno de los vasos lo cual disminuye el error. Como se observó en las etiquetas de la base de datos INSPIRED, la medición de una imagen realizada diferentes expertos puede llegar a tener una diferencia considerable. Esta diferencia se puede explicar debido a que la selección de donde inicia y donde termina el vaso acompañado de la pendiente de esta línea puede llegar a ser muy diferente para ambos expertos. El método automático de medición del calibre de los vasos aquí propuesto disminuye esta variabilidad pues siempre se tomaran las mismas consideraciones en todas las imágenes. La base de datos desarrollada en este trabajo cuenta con 50 % más imágenes que las encontradas en la literatura. El AVR promedio obtenido de las 30 imágenes de personas hipertensas es de 0.58, lo que concuerda con el AVR de retinopatía hipertensiva grado 1, mientras que el AVR promedio de personas sanas es de 0.66 el cual concuerda con el AVR de personas sanas. De las 30 imágenes de personas

hipertensas solo 7 fueron reconocidas erróneamente como sanas, y de las 30 imágenes de personas sanas 9 fueron clasificadas erróneamente como hipertensas. Los errores de los resultados anteriores se deben a errores que se encontraron en la clasificación de arteria y vena dada como resultado de la CNN.

5.1. Trabajos futuros

- Tener un estándar de comparación de la medida de AVR de la base de datos propuesta, es decir que un oftalmólogo experto ayude a calcular el AVR de cada imagen.
- Mejorar las etiquetas de clasificación de vasos.
- Mejorar el método de detección de disco óptico.
- Aumentar la base de datos.
- Poner a prueba el sistema con imágenes nuevas.

Referencias

- Abraham, A. (2005). Artificial neural networks. *Handbook of measuring system design*. doi: 10.1002/0471497398.mm421
- Ahmad, J., Farman, H., y Jan, Z. (2019). Deep learning methods and applications. En *Springer deep learning: Convergence to big data analytics* (p. 31-42). Springer. doi: 10.1007/978-981-13-3459-7_3
- Azad, R., Asadi-Aghbolaghi, M., Fathy, M., y Escalera, S. (2019). Bi-directional convlstm u-net with densley connected convolutions. *In Proceedings of the IEEE International Conference on Computer Vision Workshops*.
- Brunekreef, B., y Holgate, S. T. (2002). Air pollution and health. *The lancet*, 360(9341), 1233-1242. doi: 10.1016/S0140-6736(02)11274-8
- Dasgupta, A., y Singh, S. (2017). A fully convolutional neural network based structured prediction approach towards the retinal vessel segmentation. *IEEE 14th International Symposium on Biomedical Imaging*, 248-251. doi: 10.1109/ISBI.2017.7950512
- Dietterich, T. G. (2002). Machine learning for sequential data: A review. En *Joint iapr international workshops on statistical techniques in pattern recognition (spr) and structural and syntactic pattern recognition (sspr)* (p. 15-30). doi: 10.1007/3-540-70659-3_2
- Estrada, R., Allingham, M. J., Mettu, P. S., Cousins, S. W., Tomasi, C., y Farsiu, S. (2015). Retinal artery-vein classification via topology estimation. *Transactions on medical imaging*, 34(12), 2518-2534. doi: 10.1109/TMI.2015.2443117
- Fukushima, K. (1979). Neural network model for a mechanism of pattern recognition unaffected by shift in position-neocognitron. *IEICE Technical Report*, 62(10), 658-665.
- Gers, F. A., Schmidhuber, J., y Cummins, F. (1999). Learning to forget: Continual prediction with lstm. *9th International Conference on Artificial Neural Networks: ICANN*, 850-855. doi: 10.1049/cp:19991218
- Giancardo, L., Meriaudeau, F., Karnowski, T. P., Tobin, K. W., Grisan, E., Favaro, P., . . . Chaum, E. (2010). Textureless macula swelling detection with multiple retinal fundus images. *Transac-*

- tions on *Biomedical Engineering*, 58(3), 795–799. doi: 10.1109/TBME.2010.2095852
- Girard, F., Kavalec, C., y Cheriet, F. (2019). Joint segmentation and classification of retinal arteries/veins from fundus images. *Artificial intelligence in medicine*, 94, 96-106. doi: 10.1016/j.artmed.2019.02.004
- Graves, A. (2012). *Supervised sequence labelling with recurrent neural networks*. Springer.
- Guyon, I. (1991). Neural networks and applications tutorial. *Physics Reports*, 207(3-5), 215-259. doi: 10.1016/0370-1573(91)90146-D
- Hassoun, M. H. (1995). *Fundamentals of artificial neural networks*. MIT press.
- Hochreiter, S., y Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. doi: 10.1162/neco.1997.9.8.1735
- Hopfield, J. J. (1988). Artificial neural networks. *IEEE Circuits and Devices Magazine*, 4(5), 3-10. doi: 10.1109/101.8118
- Hua, Y., Zhao, Z., Li, R., Chen, X., Liu, Z., y Zhang, H. (2019). Deep learning with long short-term memory for time series prediction. *Communications Magazine*, 57(6), 114–119. doi: 10.1109/MCOM.2019.1800155
- INSP. (2016). *Encuesta nacional de salud y nutrición del medio camino 2016*. <https://ensanut.insp.mx/encuestas/ensanut2016/index.php>. (Accedido 08-09-2019)
- Jais, I. K. M., Ismail, A. R., y Nisa, S. Q. (2019). Adam optimization algorithm for wide and deep neural network. *Knowledge Engineering and Data Science*, 2(1), 41-46. doi: 10.17977/um018v2i12019p41-46
- Keith, N. M., Wagener, H. P., y Barker, N. W. (1974). Some different types of essential hypertension: their course and prognosis. *Am J Med Sci*, 197, 336-345.
- Knudtson, M. D., Lee, K. E., Hubbard, L. D., Wong, T. Y., Klein, R., y Klein, B. E. (2003). Revised formulas for summarizing retinal vessel diameters. *Taylor Francis Current eye research*, 27(3), 143-149. doi: 10.1076/ceyr.27.3.143.16049
- LeCun, Y., Bengio, Y., y Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. doi: 10.1038/nature14539
- LeCun, Y., Bottou, L., Bengio, Y., y Haffner, P. (1998). Gradient-based learning applied to docu-

- ment recognition. *IEEE*, 86(11), 2278-2324. doi: 10.1109/5.726791
- Leung, H., Wang, J. J., Rochtchin, E., Wong, T., Klein, R., y Mitchell, P. (2004). Impact of current and past blood pressure on retinal arteriolar diameter in an older population. *Journal of hypertension*, 22(8), 1543-1549. doi: 10.1097/01.hjh.0000125455.28861.3f
- Lipton, Z. C., Berkowitz, J., y Elkan, C. (2015). A critical review of recurrent neural networks for sequence learning. *arXiv preprint arXiv:1506.00019*.
- McCulloch, W. S., y Pitts, W. (1994). A logical calculus of the ideas immanent in nervous activity. *Springer The bulletin of mathematical biophysics*, 5(4), 115-133. doi: 10.1007/BF02478259
- Michie, D., Spiegelhalter, D. J., Taylor, C., y cols. (1994). Machine learning. *Neural and Statistical Classification*, 13.
- Mining, W. I. D. (2006). *Data mining: Concepts and techniques*. Morgan Kaufmann.
- Mirsharif, Q., Tajeripour, F., y Pourreza, H. (2013). Automated characterization of blood vessels as arteries and veins in retinal images. *ELSEVIER Computer methods and programs in biomedicine*, 37(7-8), 607-617. doi: 10.1016/j.compmedimag.2013.06.003
- Muramatsu, C., Nakagawa, T., Sawada, A., Hatanaka, Y., Hara, T., Yamamoto, T., y Fujita, H. (2011). Automated segmentation of optic disc region on retinal fundus photographs: Comparison of contour modeling and pixel classification methods. *ELSEVIER Computer methods and programs in biomedicine*, 101(1), 23-32. doi: 10.1016/j.cmpb.2010.04.006
- Narasimhan, K., Neha, V. C., y Vijayarekha, K. (2012). Hypertensive retinopathy diagnosis from fundus images by estimation of avr. *Procedia engineering*, 38(12), 980-993. doi: 10.1016/j.proeng.2012.06.124
- Nguyen, T. T., Wang, J. J., y Wong, T. Y. (2007). Retinal vascular changes in pre-diabetes and prehypertension: new findings and their research and clinical implications. *Diabetes Care*, 30(10), 2708-2715. doi: 10.2337/dc07-0732
- Niemeijer, M., Xu, X., Dumitrescu, A. V., Gupta, P., Van Ginneken, B., Folk, J. C., y Abramoff, M. D. (2011). Automated measurement of the arteriolar-to-venular width ratio in digital color fundus photographs. *ransactions on medical imaging*, 30(11), 1941-1950. doi: 10.1016/j.proeng.2012.06.124

- Nilsson, N. J., y Nilsson, N. J. (1998). *Artificial intelligence: a new synthesis*. Morgan Kaufmann.
- Patterson, J., y Gibson, A. (2018). *Deep learning*. Dong nan da xue chu ban she.
- Qureshi, T. A., Habib, M., Hunter, A., y Al-Diri, B. (2013). A manually-labeled, artery/vein classified benchmark for the drive dataset. *International Symposium on Computer-Based Medical Systems*, 485-488. doi: 10.1109/CBMS.2013.6627847
- Ramachandran, P., Zoph, B., y Le, Q. V. (2017). Searching for activation functions. *arXiv preprint arXiv:1710.05941*.
- Reddy, S. V. B., Jain, A., Yadav, S. B., Sharma, K., y Bhatia, E. (2014). Prevalence of graves ophthalmopathy in patients with graves disease presenting to a referral centre in north india. *The Indian journal of medical research*, 139(1), 99-104.
- Rojas, R. (2013). *Neural networks: a systematic introduction*. Springer Science & Business Media.
- Ruggeri, A., Tramontan, L., y Grisan, E. (2008). Automatic estimation of the arteriolar-to-venular diameter ratio (avr) in retinal images. *Acta Ophthalmologica*, 86. doi: 10.1111/j.1755-3768.2008.4143.x-i1
- Rumelhart, D. E., Hinton, G. E., y Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 223(6088), 533-536. doi: 10.1038/323533a0
- Russell, S. J., y Norvig, P. (2016). *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited,.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117. doi: 10.1016/j.neunet.2014.09.003
- Sharrett, A. R., Hubbard, L. D., Cooper, L. S., Sorlie, P. D., Brothers, R. J., Nieto, F. J., . . . Klein, R. (1999). Retinal arteriolar diameters and elevated blood pressure. *American Journal of Epidemiology*, 150(3), 263-270. doi: 10.1093/oxfordjournals.aje.a009997
- Staal, J., Abramoff, M. D., Niemeijer, M., Viergever, M. A., y Van Ginneken, B. (2004). Ridge-based vessel segmentation in color images of the retina. *IEEE Trans Med Imaging*, 23(4), 501-509. doi: 10.1109/TMI.2004.825627
- Tso, M. O., y Jampol, L. M. (1982). Pathophysiology of hypertensive retinopathy. *Ophthalmology*,

89(10), 1132-1145. doi: 10.1016/S0161-6420(82)34663-1

- Tsukikawa, M., y Stacey, A. W. (2020). A review of hypertensive retinopathy and chorioretinopathy. *Clinical Optometry*, 12(20), 67-73. doi: 10.2147/OPTO.S183492
- Turing, A. M. (1950). *Computing machinery and intelligence*. Cambridge, MA: MIT Press.
- Welikala, R. A., Foster, P. J., Whincup, P. H., Rudnicka, A. R., Owen, C. G., Strachan, D. P., y Barman, S. A. (2017). Automated arteriole and venule classification using deep learning for retinal images from the uk biobank cohort. *Computers in biology and medicine*, 90, 23-32. doi: 10.1016/j.compbiomed.2017.09.005
- WHF. (2019). *World heart federation*. <https://www.world-heart-federation.org>. (Accedido 08-09-2019)
- Wilamowski, B. M. (2009). Neural network architectures and learning algorithms. *IEEE Industrial Electronics Magazine*, 3(4), 56-63. doi: 10.1109/MIE.2009.934790
- Wong, T. Y., Klein, R., Klein, B. E., Tielsch, J. M., Hubbard, L., y Nieto, F. J. (2001). Retinal microvascular abnormalities and their relationship with hypertension, cardiovascular disease, and mortality. *Survey of ophthalmology*, 46(1), 59-80. doi: 10.1016/S0039-6257(01)00234-X
- Wong, T. Y., Klein, R., Nieto, F. J., Klein, B. E., Sharrett, A. R., Meuer, S. M., ... Tielsch, J. M. (2003). Retinal microvascular abnormalities and 10-year cardiovascular mortality: a population-based case-control study. *ELSEVIER Ophthalmology*, 110(5), 933-940. doi: 10.1016/S0161-6420(03)00084-8
- Wong, T. Y., y McIntosh, R. (2005). Hypertensive retinopathy signs as risk indicators of cardiovascular morbidity and mortality. *british medical bulletin*. *British medical bulletin*, 73(1), 57-70. doi: 10.1093/bmb/ldh050
- Wong, T. Y., Ming, C., Cheung, G., Larsen, M., y Sharma, S. (2016). Diabetic retinopathy. *Medicine*, 47, 77-85.
- Xu, X., Ding, W., Abrámoff, M. D., y Cao, R. (2017). An improved arteriovenous classification method for the early diagnostics of various diseases in retinal image. *computer methods and programs in biomedicine*. *Computer methods and programs in biomedicine*, 141, 3-9. doi:

10.1016/j.cmpb.2017.01.007

Xu, X., Tan, T., y Xu, F. (2018). An improved u-net architecture for simultaneous arteriole and venule segmentation in fundus image. *Medical Image Understanding and Analysis. MIUA 2018*, 894, 333-340. doi: 10.1007/978-3-319-95921-4_31

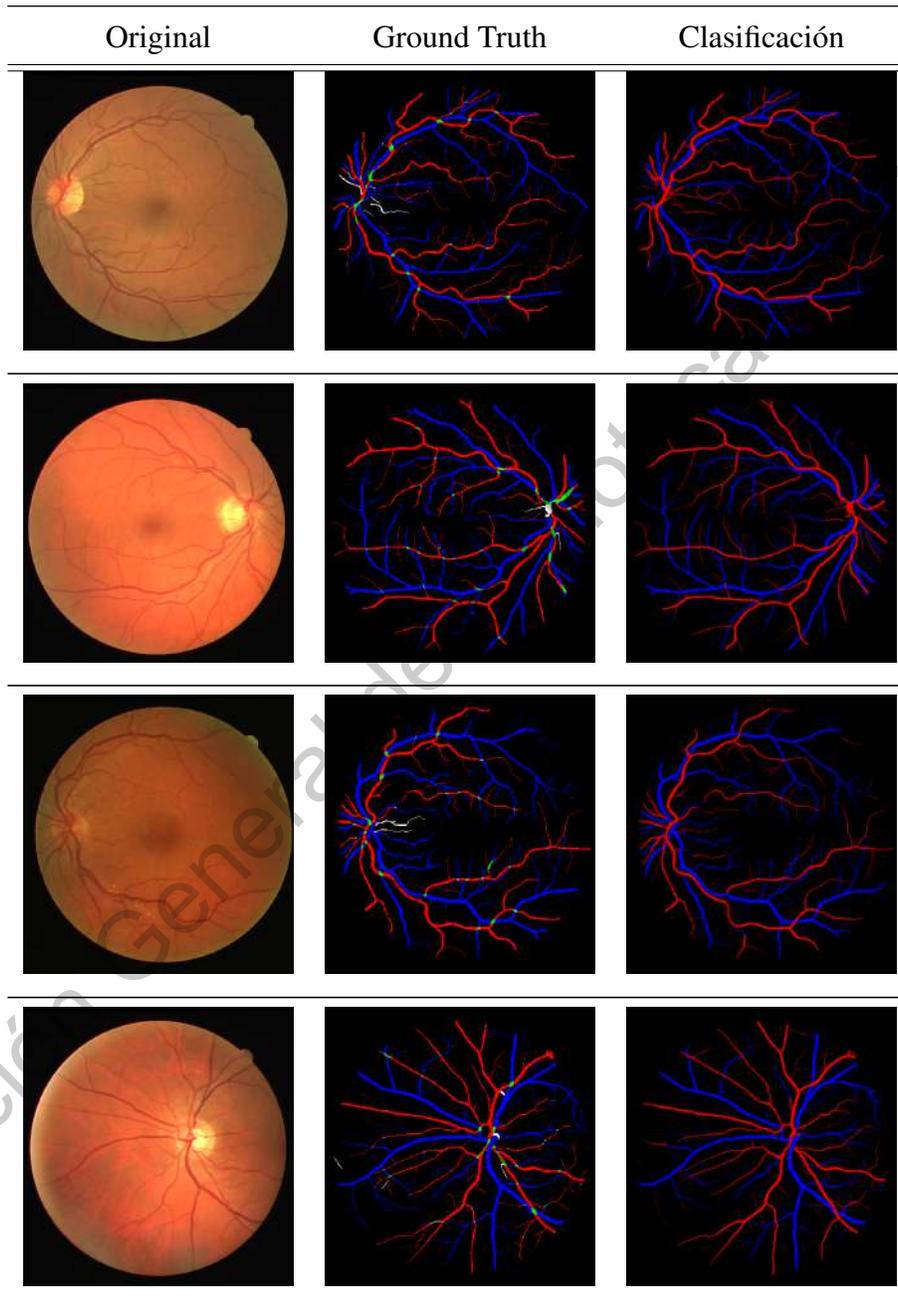
Zachariah, S., Wykes, W., y Yorston, D. (2016). Grading diabetic retinopathy (dr) using the scottish grading protocol. *Community Eye Health*, 28(92), 72-73.

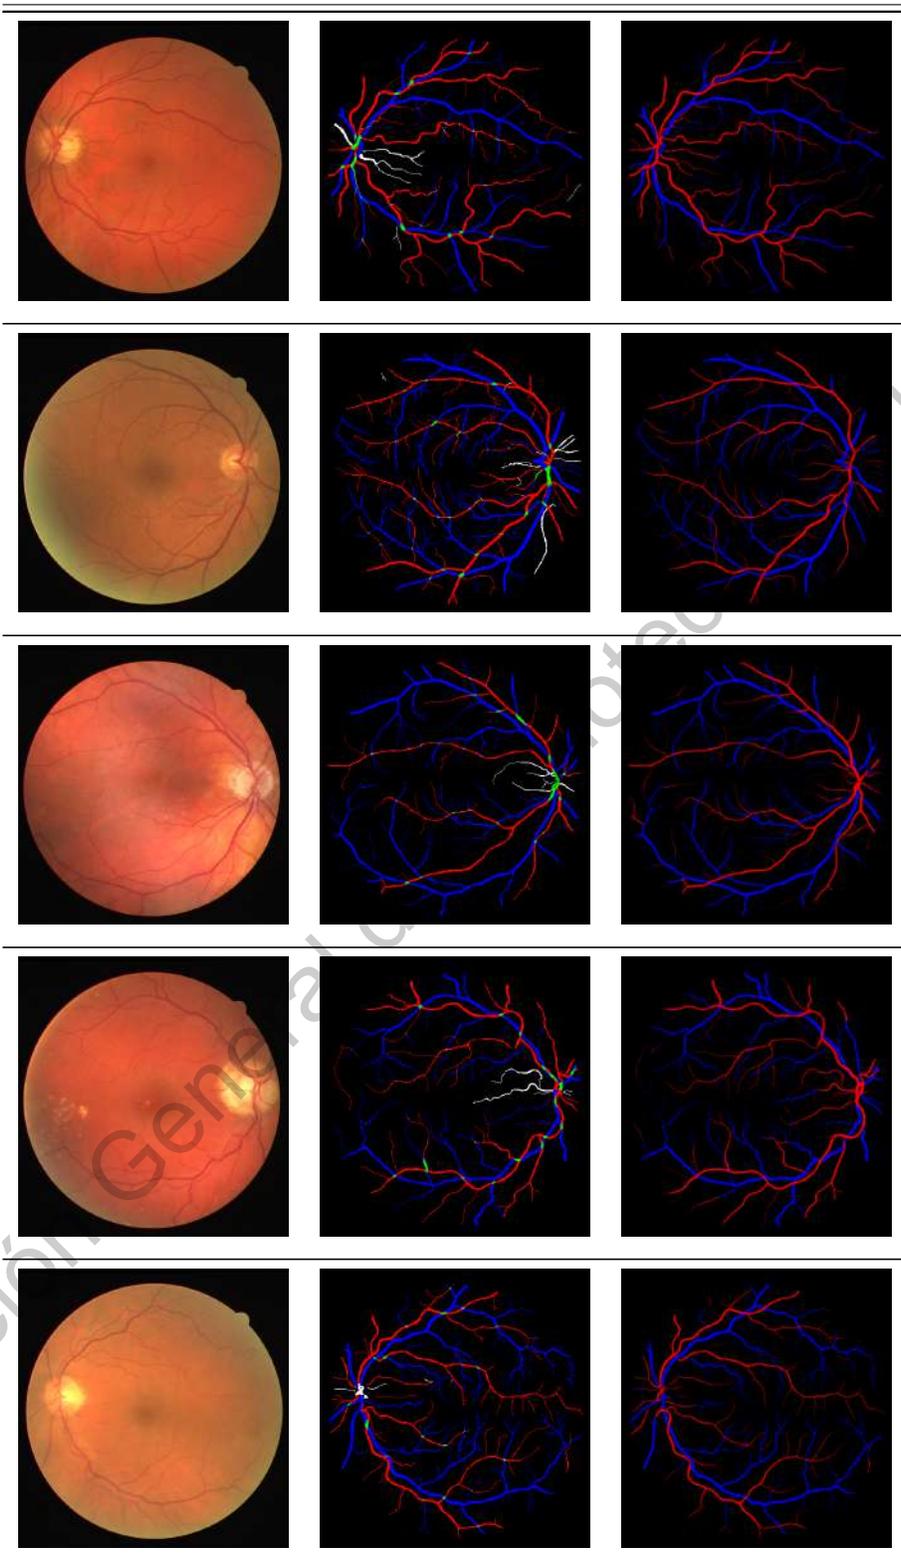
Zhou, M., Jin, K., Wang, S., Ye, J., y Qian, D. (2018). Color retinal image enhancement based on luminosity and contrast adjustment. *IEEE Transactions on Biomedical Engineering*, 65(3), 521-527. doi: 10.1109/TBME.2017.2700627

Dirección General de Bibliotecas de la UAQ

5.2. Anexos

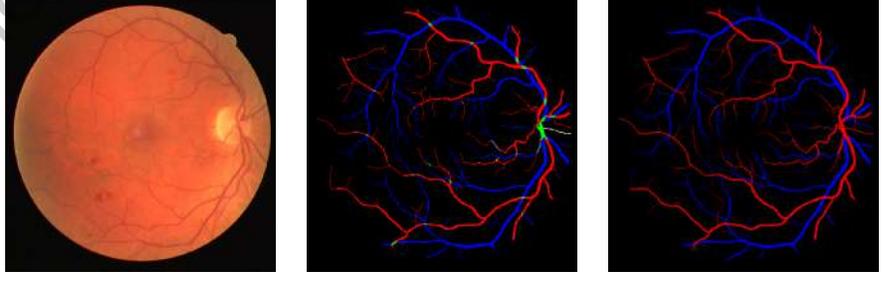
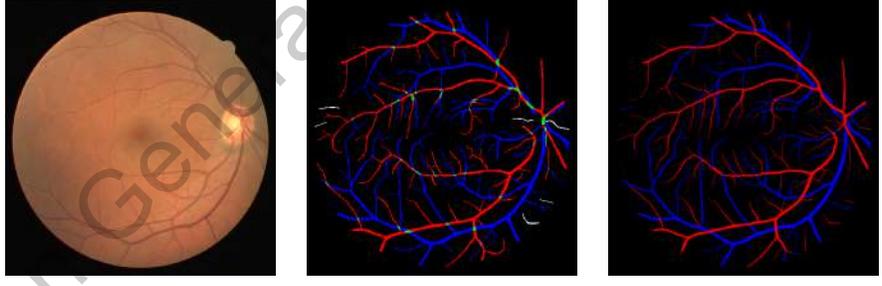
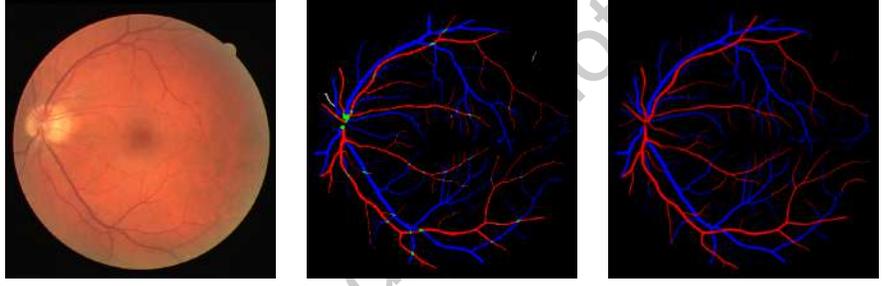
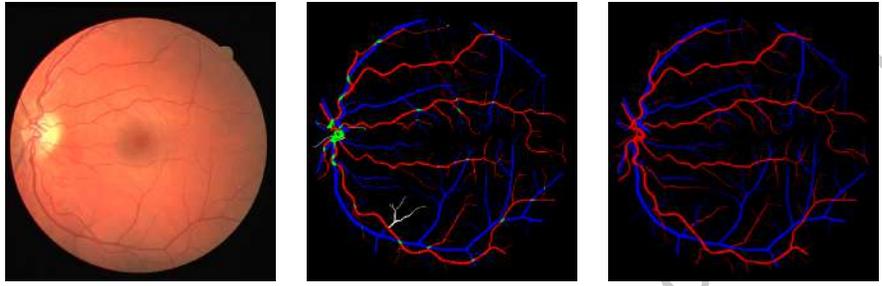
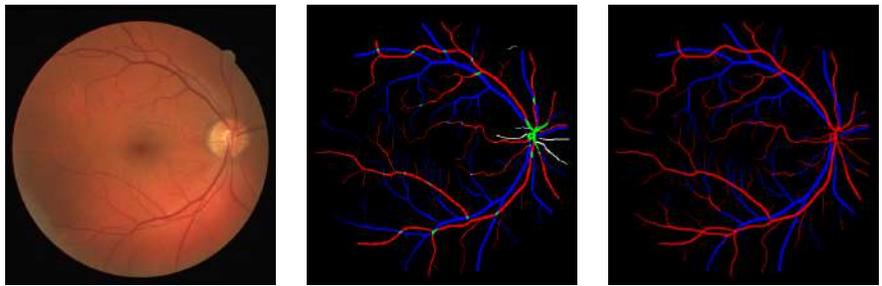
5.2.1. Clasificación de todas las imágenes de la base de datos DRIVE



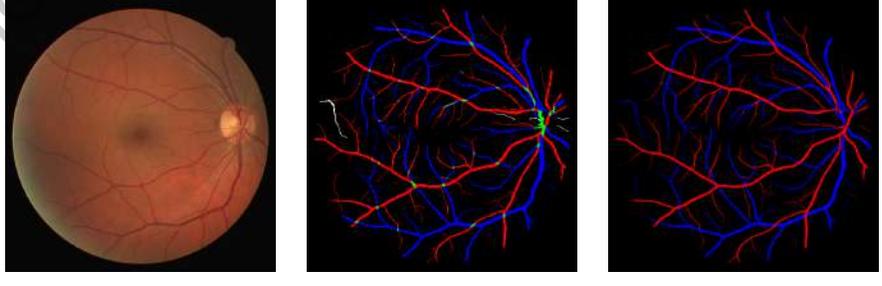
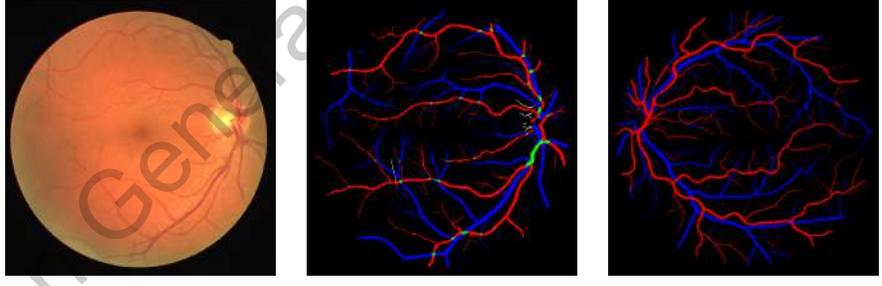
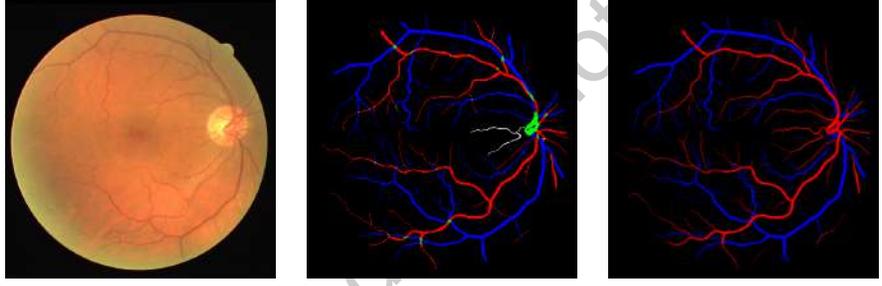
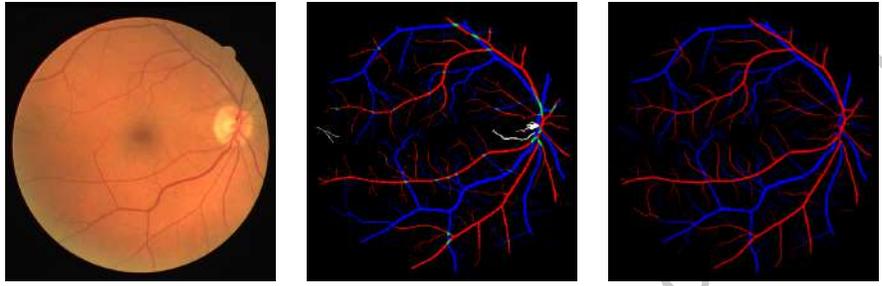
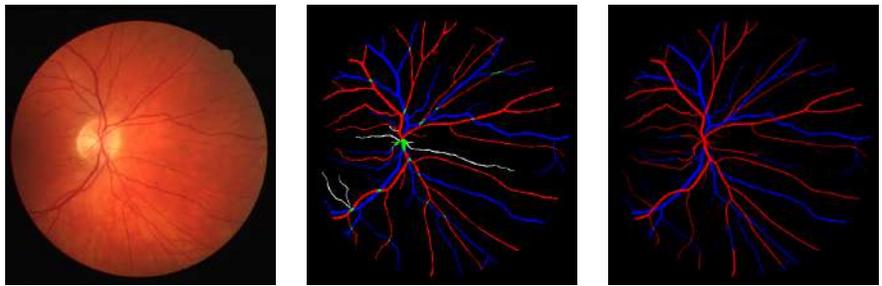


la UAQ

Dirección
Genética

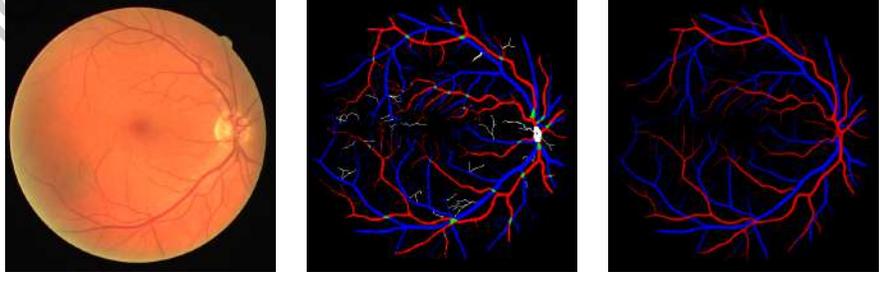
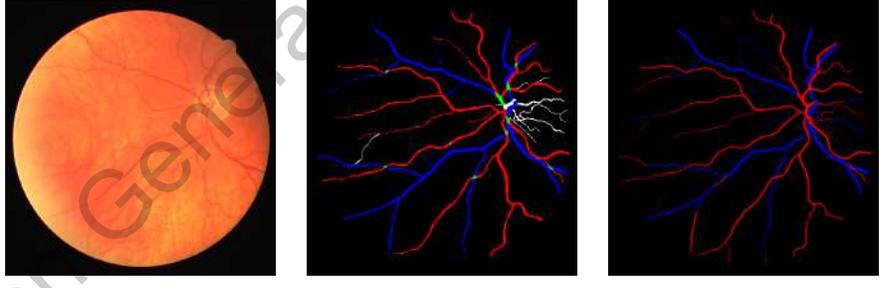
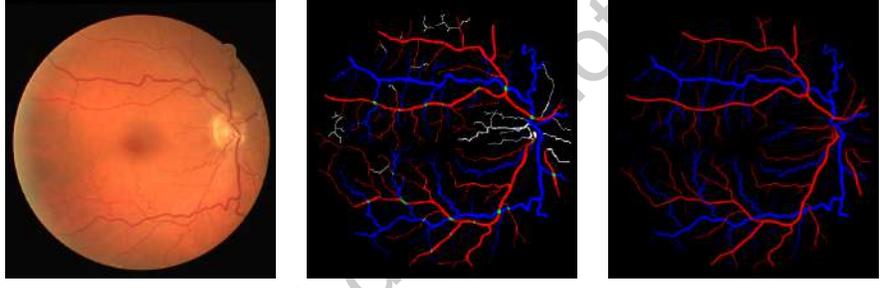
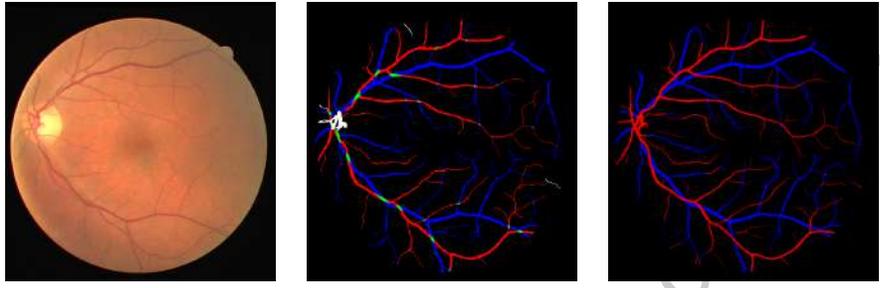
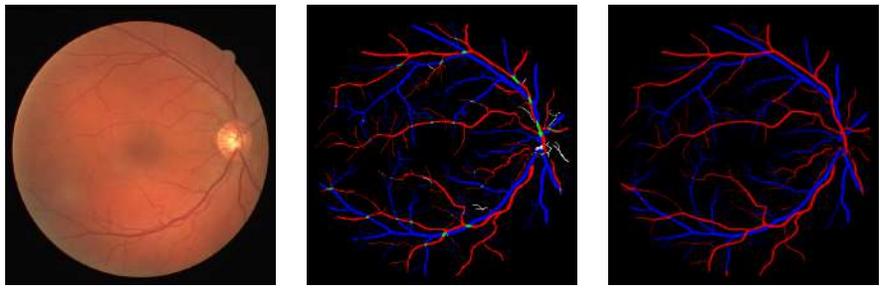


Dirección General de Investigación Científica y Tecnológica
la UAQ

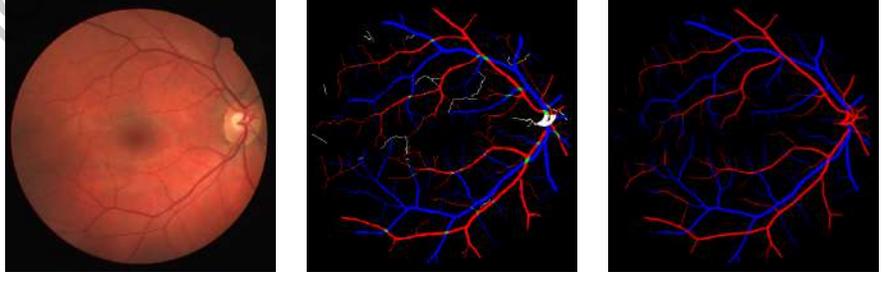
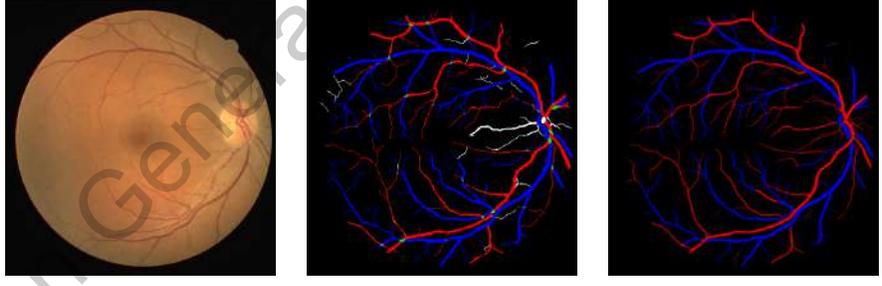
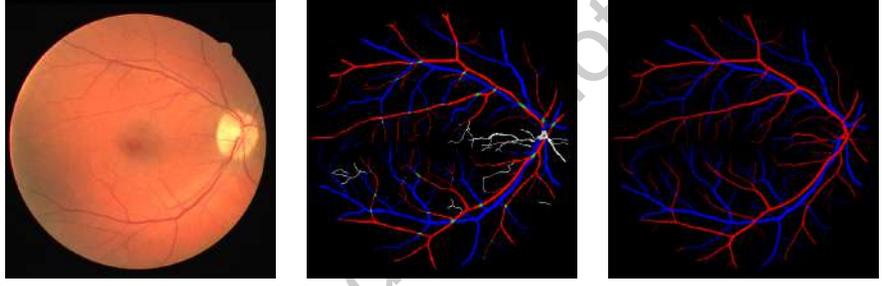
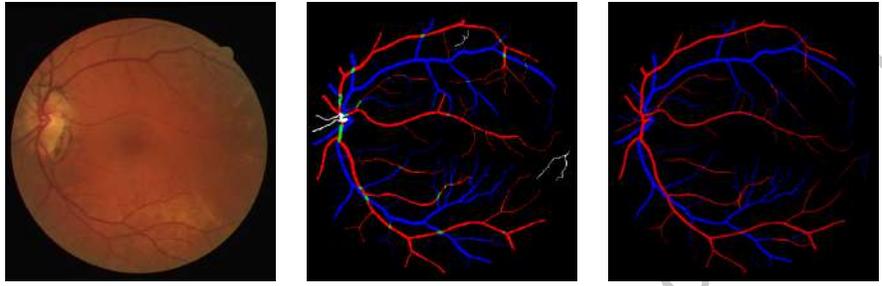
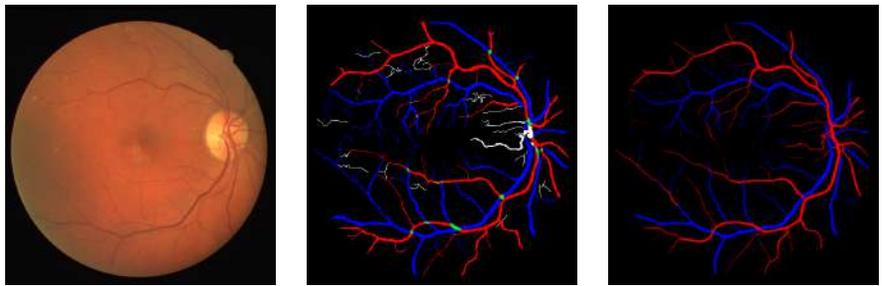


la UAQ

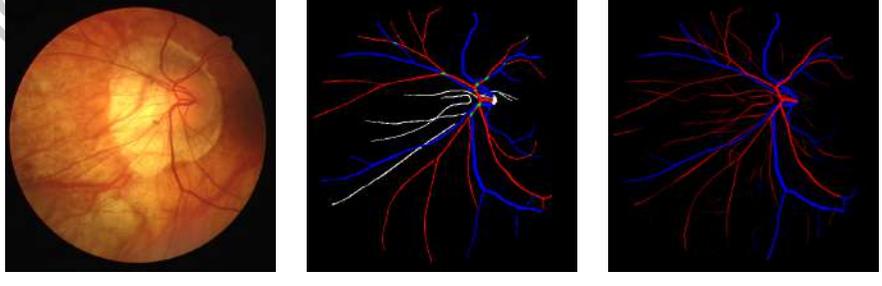
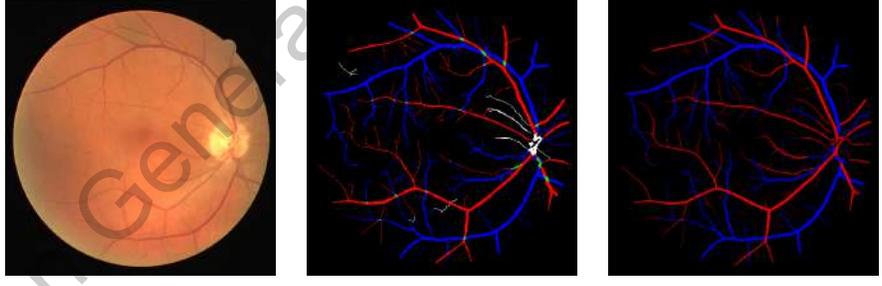
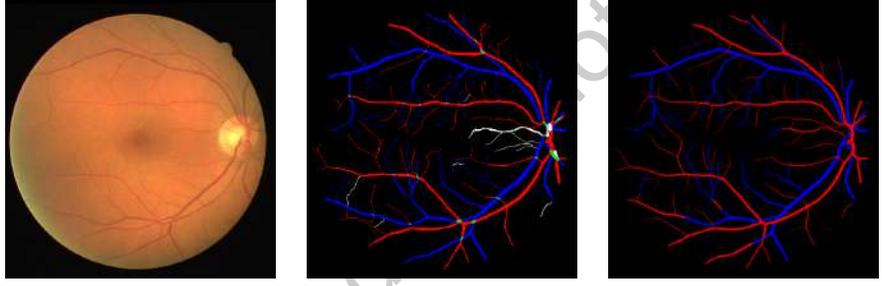
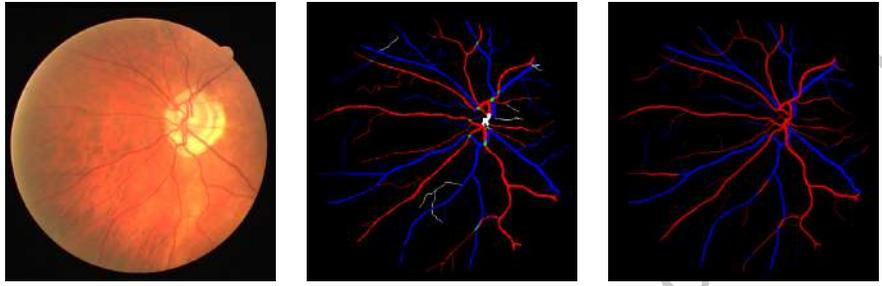
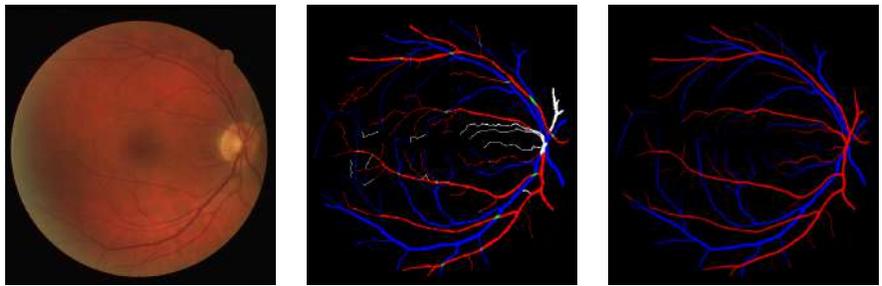
Dirección General de Investigación Científica y Tecnológica



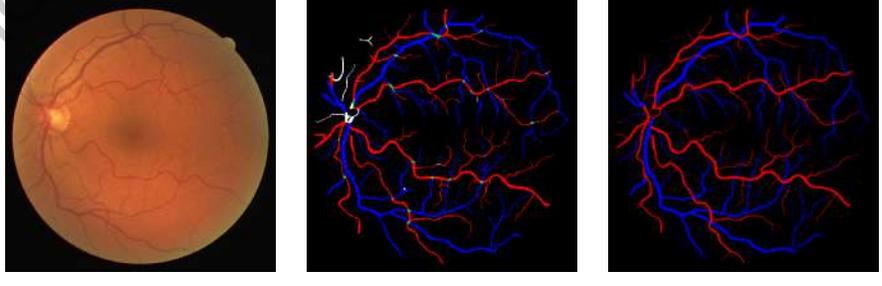
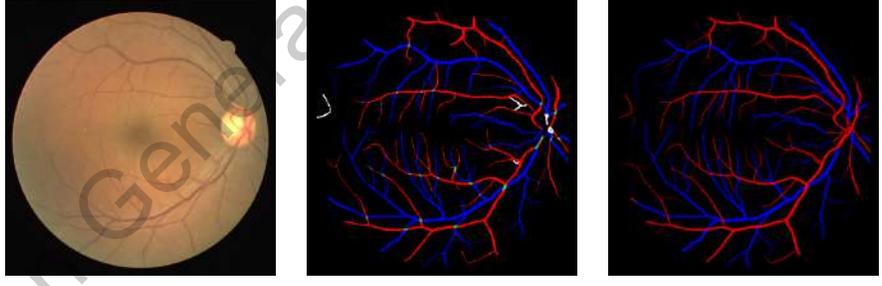
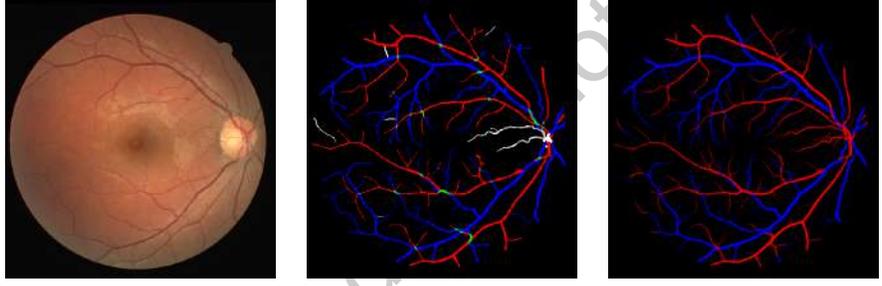
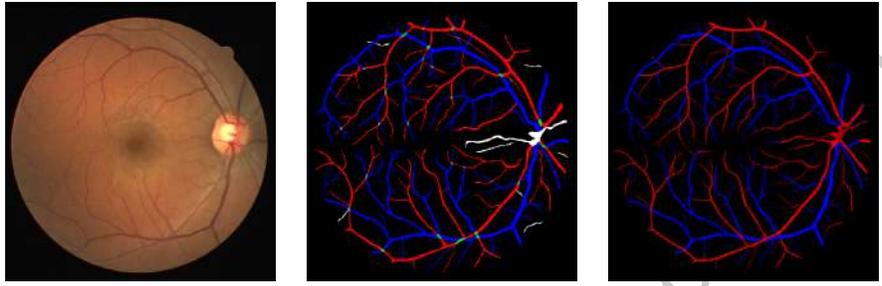
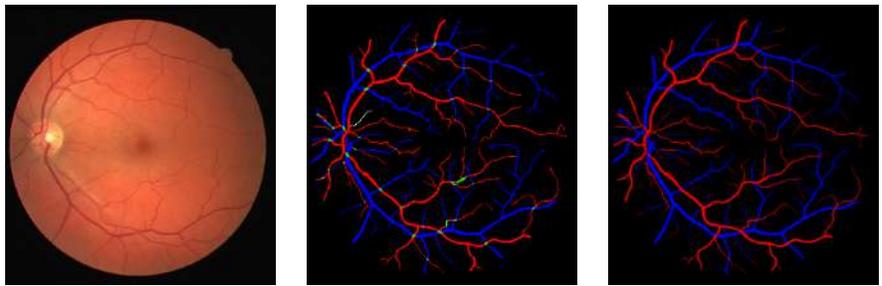
Dirección General de Investigación Científica y Tecnológica
la UAQ



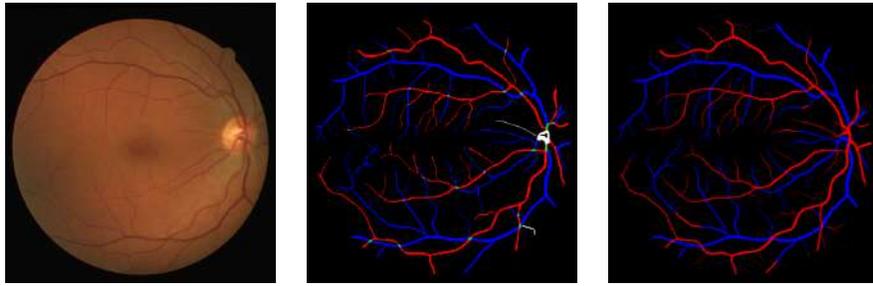
Dirección General de Investigación Científica y Tecnológica
la UAQ



Dirección General de Investigación Científica y Tecnológica
la UAQ



Dirección General de Investigación Científica y Tecnológica
la UAQ



Dirección General de Bibliotecas de la UAQ

5.2.2. Artículo publicado

   UNIVERSIDAD AUTÓNOMA DE CIUDAD JUÁREZ

LA SOCIEDAD MEXICANA DE INTELIGENCIA ARTIFICIAL Y LA UNIVERSIDAD AUTÓNOMA DE CIUDAD JUÁREZ

OTORGAN ESTE CERTIFICADO A:

María Guadalupe Hernández Ramírez, Saul Tovar Arriaga, Jesus Carlos Pedraza Ortega y Efrén Gorrostieta Hurtado



POR LA PRESENTACIÓN DEL ARTÍCULO TITULADO:

Clasificación de A/V en imágenes de retina usando arquitectura inspirada en U-net con ConvLSTM bidireccionales

en el XII Congreso Mexicano de Inteligencia Artificial - COMIA 2020
Cd. Juárez, Chihuahua, México, del 5 al 7 de agosto de 2020

 **Dr. Félix Castro Espinoza**
Presidente SMIA

 **Dr. Oscar Herrera Aleántara**
Presidente Comité de Programa

 **Dr. Noé A. Castro Sánchez**
Presidente Comité de Programa

 **Dr. Manuel de J. Nandayapa Alfaro**
Comité Local COMIA

Dirección General de Bibliotecas de la UAQ

5.2.3. Requisito de manejo de la lengua inglesa



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE LENGUAS Y LETRAS

A QUIEN CORRESPONDA:

La que suscribe, Directora de la Facultad de Letras y Letras, hace **C O N S T A R** que

HERNANDEZ RAMIREZ MARIA GUADALUPE

Presentó el **Examen de Manejo de la Lengua** efectuado el día veintiséis de junio de dos mil veinte, en el cual obtuvo la siguiente calificación:

8+

Se extiende la presente a petición de la parte interesada, para los fines escolares y legales que le convengan, en el Campus Aeropuerto de la Universidad Autónoma de Querétaro, el día tres de julio de dos mil veinte.



Atentamente,
"Enlazar Culturas por la Palabra"

LIC. LAURA PÉREZ TÉLLEZ

LPT/jals*CL*FLL-C.-711



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE LENGUAS Y LETRAS



Campus Aeropuerto, 03 de septiembre de 2020.
FLL/SA/HCA/2020/1021

C. Hernández Ramírez, María Guadalupe
Exp. 195725
Facultad de Ingeniería
Presente.

Me permito comunicar a usted que en Sesión Ordinaria del H. Consejo Académico de la Facultad de Lenguas y Letras, celebrada el **03 de septiembre de 2020**, se acordó **Aprobar** su solicitud de **convalidación** de la Constancia del Examen de Manejo de la Lengua (8+), expedida por el CELyC, por el Examen de Comprensión de Textos en Inglés

Sin más por el momento, me es grato quedar a sus órdenes para cualquier aclaración.

Atentamente,
"Enlazar Culturas por la Palabra"


Dra. Ma. de Lourdes Rico Cruz
Secretaria Académica



C.c. Expediente.
Archivo.

MLRC/**mlp

SOMOS UAQ
EDUCAR CRECER CONSOLIDAR

Campus Aeropuerto, Anillo Vial Fray Junípero Serra S/N, Querétaro, Qro. C.P. 76140
Tel. 442 192 12 00 Dirección Ext. 61010, Secretaría Administrativa Ext.61300, Posgrado Ext. 61140,
Licenciatura Ext.61070, Centro de Lenguas Ext.61050, Secretaría Académica Ext.61100 y Planeación Ext.61110