

Optimización adaptativa de preprocesamiento para la segmentación de la red vascular retiniana

Adaptive Preprocessing Optimization for Retinal Vascular Network Segmentation

Evelyn Berenice **Bautista Coello** ¹

Álvaro **Anzueto Ríos** ²

Alma Aide **Sánchez Ramírez** ³

Instituto Politécnico Nacional,
Unidad Profesional Interdisciplinaria en Ingeniería y Tecnologías Avanzadas,
Ciudad de México
MÉXICO

¹ ORCID: 0009-0004-6328-8424 / ebautistac1700@alumno.ipn.mx

² ORCID: 0000-0003-1627-0323 / laanzuetor@ipn.mx

³ ORCID: 0009-0003-1852-7775 / aasanchezra@ipn.mx

<https://cientifica.site>

Recibido 03/09/2025, aceptado 05/11/2025.



Resumen

La segmentación de la red vascular en imágenes de fondo de ojo es un paso importante en el diagnóstico y seguimiento de patologías oftalmológicas y sistémicas, como la retinopatía diabética (RD). Sin embargo, la fiabilidad de los métodos automatizados se ve comprometida por desafíos inherentes a las imágenes, principalmente la iluminación no uniforme, el bajo contraste y la presencia de ruido. Este trabajo propone una metodología para el procesamiento y segmentado automatizado de imágenes de fondo de ojo, abordando estos problemas mediante una estrategia de adaptación y regularización. El método inicia con la extracción del canal verde (G) para maximizar el contraste. Luego, se aplica un filtro gaussiano cuyo parámetro de suavizado (σ) es optimizado para cada imagen, balanceando la reducción de ruido y la preservación de detalles mediante la Varianza del Laplaciano (VoL) y la Energía de Alta Frecuencia Residual (HFER). Después, se implementa un filtro homomórfico para corregir la iluminación, ajustando sus parámetros con un algoritmo de Enjambre de Partículas (PSO) y utilizando la entropía de Shannon como función objetivo. Finalmente, el filtro de Frangi resalta las estructuras tubulares, seguido de una binarización controlada. El método fue validado en las bases de datos públicas DRIVE y STARE, donde la etapa de optimización homomórfica demostró un incremento consistente en la entropía de la imagen (ej., de 5.7 a 6.2 bits/píxel), mejorando el contraste. La estrategia de preprocesamiento adaptativo propuesta contribuye a mejorar la fiabilidad de la segmentación vascular y, por ende, el diagnóstico de las patologías.

2

Palabras clave: segmentación de imágenes, fondo de ojo, vasos sanguíneos, filtro homomórfico, PSO.

Abstract

The segmentation of the vascular network in fundus images is a key step in the diagnosis and monitoring of ophthalmological and systemic pathologies, such as diabetic retinopathy (RD). However, the reliability of automated methods is challenged by inherent image issues, mainly non-uniform illumination, low contrast, and noise. This work proposes a methodology for the automated preprocessing and segmentation of fundus images, addressing these problems through an adaptation and regularization strategy.

The method begins with the extraction of the green channel (G) to maximize contrast. Then, a Gaussian filter is applied, with its smoothing parameter (σ) optimized for each image by balancing noise reduction and detail preservation using the Variance of Laplacian (VoL) and High-Frequency Energy Residual (HFER). Next, a homomorphic filter is applied to correct illumination, with its parameters dynamically adjusted using a Particle Swarm Optimization (PSO) algorithm, employing Shannon entropy as the objective function. Finally, the Frangi filter is used to enhance tubular structures, followed by controlled binarization. The method was validated on the public DRIVE and STARE databases, where the homomorphic optimization stage showed a consistent increase in image entropy (e.g., from 5.7 to 6.2 bits/pixel), improving contrast. The proposed adaptive preprocessing strategy helps improve the reliability of vascular segmentation and, consequently, the diagnosis of related pathologies.

Index terms: image segmentation, fundus eye image, blood vessels, homomorphic filter, PSO.

I. INTRODUCCIÓN

El ojo es uno de los órganos más complejos, uno de sus elementos más importantes es la retina. Esta es una capa neuronal delgada, sensible a la luz, que se sitúa en la parte posterior del ojo. Se encuentra conectada a una red microvascular responsable de proporcionar nutrientes y eliminar desechos. Además, la retina convierte la luz en señales neuronales para su posterior procesamiento en la corteza visual del cerebro [1], [2].

La red microvascular es, con frecuencia, uno de los primeros sitios donde se manifiestan diversas enfermedades oculares, muchas de ellas asociadas a los vasos sanguíneos. Por esta razón, el análisis de la red vascular de la retina es importante para la detección temprana de diferentes patologías [2]. Algunas de las enfermedades más comunes que se pueden identificar a través de esta red se encuentran el glaucoma, la retinopatía diabética (RD) y diversas afecciones cardiovasculares [1].

La retina representa una región clave para realizar diagnósticos médicos, ya que las enfermedades vinculadas a ella es una de las principales causas de ceguera a nivel mundial. Las variaciones que se observan en la red vascular retiniana pueden servir como indicadores de distintas enfermedades [3].

Las imágenes de fondo de ojo son una herramienta no invasiva con la que se puede observar la red vascular de la retina. Mediante de estas imágenes, es posible analizar atributos morfológicos de los vasos sanguíneos, como el diámetro, la forma, la tortuosidad y la bifurcación, los cuales pueden emplearse para la detección, evaluación y seguimiento de diversas anomalías oculares [3]. No obstante, obtener datos de estas imágenes no es una tarea sencilla dado a que la segmentación manual de los vasos sanguíneos puede resultar lenta y laboriosa. Por lo tanto, se han desarrollado métodos automáticos que buscan acelerar este proceso de análisis sin sacrificar la precisión.

Estos métodos de segmentación automática se han vuelto una parte fundamental en los sistemas de ayuda al diagnóstico por computadora (CAD). La primera etapa en estos sistemas suele ser la segmentación de la red vascular, proceso esencial para el diagnóstico de enfermedades [4]. Sin embargo, este proceso representa un desafío en el procesamiento de imágenes. Entre los problemas más comunes se encuentran la baja visibilidad de los vasos debido al bajo contraste, la ruptura de los vasos en zonas de cruces o bifurcaciones, así como la presencia de artefactos en la imagen como ruido, iluminación no uniforme o desenfoque [5].

Los métodos de segmentación automática para los vasos sanguíneos se dividen en dos: los supervisados y no supervisados. Los métodos supervisados se desarrollan mediante un grupo de muestras de entrenamiento que sirven para extraer el vector propio de las imágenes, lo cual posibilita alcanzar una alta exactitud en la segmentación. Entre los algoritmos de esta clasificación se encuentran las redes neuronales artificiales, las redes neuronales convolucionales (CNN), los bosques aleatorios, entre otros. Sin embargo, requieren grandes volúmenes de datos y largos tiempos de entrenamiento. Por otro lado, los métodos no supervisados se basan principalmente en técnicas de procesamiento de imágenes, las cuales no requieren un conjunto de entrenamiento previo. Estos métodos aprovechan la respuesta de filtros o transformaciones matemáticas para detectar estructuras vasculares de manera más rápida y directa. Ejemplos de estos enfoques incluyen como Modelo mixto gaussiano, fuzzy, c-media, por mencionar algunos ejemplos [6], [7].

Se han publicado diversos artículos sobre segmentación automática de vasos sanguíneos; sin embargo, aún existen áreas de mejora, especialmente en lo referente a la reducción del tiempo de cómputo y a la automatización del proceso. Aunque los métodos supervisados han demostrado una alta precisión en la segmentación, presentan la desventaja de requerir extensos conjuntos de entrenamiento y procesos de aprendizaje prolongados, lo que incrementa

significativamente el costo computacional y limita su aplicación en entornos donde se requiere un procesamiento más ágil y eficiente.

Frente a estos retos, se hace necesario desarrollar soluciones que aborden a la complejidad de las imágenes de la retina y que trabajen bajo diversas condiciones. En esta investigación, se propone un método automatizado no supervisado para la segmentación de vasos sanguíneos en imágenes de fondo de ojo, con el objetivo de mejorar la detección de alteraciones vasculares. Para lograr esto, se utilizó un enfoque basado en un filtro gaussiano adaptable, un filtro homomórfico modificado que trabaja en conjunto de un método metaheurístico, con el fin de seleccionar los parámetros óptimos para la segmentación. Posteriormente, se utilizó el filtro de Frangi y una técnica de binarización para completar el proceso.

El artículo se organiza de la siguiente manera: en la Sección II se presenta la metodología utilizada, donde se explican los fundamentos teóricos de los filtros aplicados, así como cada etapa del desarrollo del sistema. Esta sección incluye el preprocesamiento (conversión a escala de grises, eliminación de ruido con el filtro gaussiano adaptable y corrección de iluminación mediante el filtro homomórfico junto con un método metaheurístico), seguido por la segmentación con el filtro de Frangi y el proceso de binarización. En la Sección III se muestran los resultados mediante esta metodología. Finalmente, en la Sección IV se discuten las conclusiones, los hallazgos principales, las limitaciones y algunas recomendaciones para futuras investigaciones.

II. METODOLOGÍA

4

En esta sección se describe el procedimiento para el desarrollo e implementación del algoritmo propuesto como los conceptos teóricos básicos, cuyo propósito principal es mejorar la segmentación de las imágenes mediante un preprocesamiento (nótese en la Fig. 1). El algoritmo está diseñado para mejorar la calidad de la imagen previo a la implementación de métodos de segmentación, lo que facilita una identificación de las estructuras de interés.




Fig. 1. Diagrama del algoritmo propuesto para la segmentación de la red vascular de la retina en imágenes de fondo de ojo.

A. Base de datos

Para la evaluación de la metodología propuesta se emplearon dos bases de datos: STARE y DRIVE. La base STARE, publicada en el año 2000, tiene una resolución de 605×700 píxeles y formato PPM, distribuidas equitativamente entre casos normales y patológicos. Por otro lado, la base DRIVE, lanzada en 2004, con resolución de 768×584 píxeles y en formato JPEG, está dividida en conjuntos de entrenamiento y prueba, y abarcando tanto casos normales como pacientes con retinopatía diabética [3]. En este estudio se consideraron imágenes de ambas categorías normales y con RD, obteniendo un total de 169 imágenes, las cuales fueron estandarizadas a una resolución de 633×595 píxeles y formato JPG para facilitar el procesamiento y análisis comparativo.

B. Conversión a escala de grises

Las imágenes de fondo de ojo se encuentran en formato RGB, lo que implica que se conforman de tres canales: rojo, verde y azul como se logra apreciar en la Fig. 2 y se describe en la ecuación (1). Dentro de estos, el canal verde (G) sobresale por proporcionar una sensibilidad visual superior al ojo humano, así como un mayor contraste en comparación con los otros dos canales [8].

De acuerdo con [9], donde se implementó una red neuronal profunda basada en U-Net para comparar el desempeño de cada canal en la segmentación de estructuras retinianas, se comprobó que, aunque la combinación de los tres canales aporta información complementaria, el canal verde logra los mejores resultados de manera individual particularmente en la segmentación de los vasos sanguíneos. Por ello, en el presente trabajo se emplea exclusivamente dicho canal para la conversión a escala de grises.

$$I = [I_R I_G I_B] \quad (1)$$




Fig. 2. Imágenes correspondientes a los tres canales de color que componen la imagen de fondo de ojo en formato RGB: canal rojo (R), canal verde (G) y canal azul (B).

C. Filtro gaussiano

En el proceso de adquisición de imágenes de fondo de ojo es habitual que se introduzca ruido. Para resolver este inconveniente, se utiliza el filtro gaussiano, un filtro de pasa bajas que realiza la suavización de la imagen mitigando así el ruido. Esta técnica se basa en la convolución de la imagen con un kernel gaussiano, que se describe en la ecuación (2).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2)$$

En esta ecuación, σ simboliza la desviación estándar de la distribución, mientras que x e y son los índices de ubicación relativas al kernel.

El valor de σ determina el nivel de desenfoque que se implementará en el entorno de cada píxel [10]. Por esta razón, se utilizó una metodología particular para elegir el valor ideal de sigma, sustentada en la Varianza del Laplaciano (VoL) y la Energía Alta Frecuencia Residual (HFER).

1) Varianza del laplaciano

Hay varias técnicas para establecer si una imagen está borrosa, tales como la Transformada Wavelet de Haar y la Transformada Rápida de Fourier (FFT). No obstante, en este caso se decidió emplear el operador Laplaciano, dado que facilita la identificación de los bordes, es decir, las áreas donde ocurre una variación notable en la intensidad.

El operador Laplaciano es una máscara de segundo orden que permite identificar cambios en la intensidad, como los bordes de los objetos en la imagen. Este operador puede ser categorizado en dos configuraciones principales: una con un valor positivo y otra con un valor negativo.

El operador Laplaciano es un operador escalar diferencial que se utiliza en una función escalar, y se representa a través de la ecuación (3) [11]:

$$\Delta f = \nabla^2 f = \nabla \cdot \nabla f \quad (3)$$

2) La Energía de Alta Frecuencia Residual

La energía de una imagen suele calcularse como la suma de los valores de intensidad de los píxeles elevados al cuadrado. El HFER representa la cantidad de la energía total de la imagen original que se ha suprimido durante el proceso de suavizado, y actúa como señal del grado de pérdida de datos de alta frecuencia. El procedimiento para obtener el valor de HREF se ilustra en las ecuaciones (4), (5), (6), (7) en el que el valor x, y representan las coordenadas espaciales de los píxeles en la imagen.

$$R(x, y) = I_{original}(x, y) - I_{filtrada}(x, y) \quad (4)$$

$$E_R = \sum_{x,y} R(x, y)^2 \quad (5)$$

$$E_O = \sum_{x,y} I_{original}(x, y)^2 \quad (6)$$

$$HREF = \frac{E_R}{E_O} \quad (7)$$

El valor de σ determina el nivel de desenfoque que se implementará en el entorno de cada píxel [7]. Por esta razón, se utilizó un método específico (observe la Fig. 3) para elegir el valor ideal de sigma, sustentada en la VoL y el estudio de HFER.




Fig. 3. Metodología empleada para encontrar el valor de σ_a .

7

Para determinar el valor del parámetro σ del filtro gaussiano, se emplearon las métricas de VoL y HFER. Para ello se realizó la evaluación de sigma en la imagen en un rango de 0.2 a 4.1 en pasos de 0.2 y se registraron los valores de HFER y VoL en cada caso (véase Fig. 4). Como se indicó anteriormente, el valor del Laplaciano es una medida para medir el nivel de desenfoque en una imagen, al realizar esta evaluación, se obtiene una curva donde se identifica el punto de codo en la curva (este corresponde al punto donde hay un cambio abrupto). Lo que nos indicará hasta qué punto el valor de σ conserva la imagen sus detalles antes de empezar a desvanecer información relevante.

Por otro lado, utilizando la misma metodología con la métrica HFER ofrece la información de alta frecuencia como detalles finos y ruido que ha sido suprimida por el filtro. Esta medida es efectiva para detectar el punto en el que la tendencia de pérdida de detalle se incrementa rápidamente.

Para elegir el valor final para σ , se tomaron en cuenta ambas métricas: el punto de cambio más elevado registrado por VoL y el valor que representa el cambio más significativo en la HFER. Finalmente, se determinó un promedio entre ambos valores expresado matemáticamente por la ecuación (8), y este resultado se empleó como valor ideal de σ , facilitando de esta manera un balance apropiado entre el suavizado de la imagen y la conservación de sus detalles.

$$\sigma_a = \frac{\sigma_{HFER} + \sigma_{VOL}}{2} \quad (8)$$

Análisis de Sigma para Filtro Gaussiano




Fig. 4. Gráfico de σ obtenido a partir del grafico HREF y VoL en una imagen.

D. Filtro homomórfico

8

El filtro homomórfico es un filtro que trabaja en el dominio de las frecuencias y su metodología consiste en descomponer la imagen en sus dos componentes: la iluminancia y la reflectancia. Su meta principal es mejorar la apariencia de la imagen a través de la distinción de las frecuencias altas y bajas modificándose simultáneamente, lo que permitirá solucionar problemas de iluminación y contrastar los detalles en la imagen. Esto ocurre porque las frecuencias bajas están vinculadas con la información global de la imagen, como la iluminación, en cambio, las frecuencias altas están vinculadas con los detalles.

El procedimiento que lleva a cabo con la modificación de la imagen a través de una función logarítmica, lo que facilita la transformación de la multiplicación de iluminancia y reflectancia en una suma. Así, la imagen puede ser desglosada en un elemento aditivo. Posterior a ello se envía en el dominio de frecuencia a través de la transformada rápida de Fourier, y se aplica un filtro pasa altas. Al pasar por este proceso se regresan a su forma original aplicando la inversa de la transformada rápida de Fourier como una transformación exponencial para obtener la imagen mejorada [12], [13].

En este caso, el filtro pasa altas empleado es el que se muestra en la ecuación (9). Es una versión levemente modificada del filtro pasa altas gaussiano, también denominado GHPF (Gaussian highpass filter). Este filtro, establecido por la ecuación (10) a través de la función $D(u, v)$ simboliza la separación entre el punto (u, v) en el dominio de la frecuencia y el centro del rectángulo de la frecuencia $P \times Q$. El filtro pasa altas emplea los parámetros γ_H y γ_L , que tienen la tarea de reducir el aporte de las frecuencias bajas (iluminación) y aumentar las frecuencias altas (reflectancia). En consecuencia, se consigue una compresión del espectro dinámico y se potencia el contraste. Estos parámetros se seleccionan de forma que se satisfagan: $\gamma_H < 1$ y γ_L menor que 1 [13].

$$D(u, v) = \left[\left(u - \frac{P}{2} \right)^2 + \left(v - \frac{Q}{2} \right)^2 \right]^{\frac{1}{2}} \quad (9)$$

$$H(u, v) = (\gamma_H - \gamma_L) \left[1 - e^{\frac{-D^2(u, v)}{D_0^2}} \right] + \gamma_L \quad (10)$$

Sin embargo, persiste un problema en el filtro homomórfico y es la selección correcta de estos parámetros. Como se puede apreciar, existen ciertos rangos de las variables. Determinar el valor incorrecto de estas variables puede generar efectos como el oscurecimiento de la imagen, y a menudo se lleva a cabo a prueba y error. Debido a esto se empleó para mitigar esta problemática un algoritmo de optimización PSO (*Particle Swarm Optimization*).

El PSO se encargará de encontrar los valores adecuados de γ_H , γ_L , D_0 y esto se realizará a través de una función objetivo.

1) Función objetivo

A continuación, se explicará la variable empleada para obtener los valores correspondientes al filtro homomórfico.

a. Entropía

El término entropía hace referencia al grado de aleatoriedad o incertidumbre que existe en una señal o en este caso es una imagen; en otras palabras, señala la cantidad de información (observe la ecuación (11)). Si se cuantifica la incertidumbre antes y después a la captura de una imagen, la diferencia que existe entre ambas se le denominada entropía de la información simboliza una medida numérica de la información que transmite tal imagen [14].

$$E = - \sum_{i=0}^{255} P_i \log_2 P_i \quad (11)$$

A través de la función objetivo, se consiguen los valores ideales del filtro homomórfico mediante el PSO, cuyo objetivo primordial es aumentar la entropía de Shannon de la imagen filtrada. En este contexto, se examina el negativo de la entropía determinada en la imagen procesada con varios grupos de parámetros γ_H , γ_L y D_0 en busca de aquellos que produzcan una distribución de los niveles de grises lo más uniforme posible, lo que está vinculado con un incremento en el contenido informativo de la imagen obtenida. La metodología propuesta se puede observar en la Fig. 4.




Fig. 5. Metodología empleada para el filtro homomórfico.

E. Filtro Frangi

Para resaltar la red vascular de la retina en las imágenes, se utilizó el filtro de Frangi, este filtro es conocido debido a su desempeño para identificar las estructuras tubulares, como los vasos sanguíneos, a través del análisis de la matriz Hessiana de segundo orden.

El fundamento matemático del filtro se basa en el análisis de los autovalores de la matriz Hessiana (véase la ecuación (12)), calculada en cada punto x de la imagen a través de derivadas de segundo orden aplicadas a una imagen suavizada por una función gaussiana con desviación estándar σ :

$$H_{\sigma}(I, x) = \frac{\partial^2 I_{\sigma}}{\partial x^2} = I(x) * \frac{\partial^2 G_{\sigma}(x)}{\partial x^2} \quad (12)$$

Donde $I(x)$ es la imagen y $G_{\sigma}(x)$ es la función gaussiana. A partir de la descomposición de la matriz Hessiana se obtienen los autovalores λ_1 , λ_2 , λ_3 y sus respectivas direcciones principales, que permiten identificar patrones geométricos como estructuras tipo cilindro, planas o tubulares. La función de similitud vascular, propuesta originalmente por se define en (13) [13].

$$V_{\sigma}^F(x) = \begin{cases} 0, & \text{si } \lambda_2 < 0 \\ \exp\left(-\frac{R_B^2}{2\beta^2}\right) \left(1 - \exp\left(-\frac{S^2}{2c^2}\right)\right), & \text{en otro caso} \end{cases} \quad (13)$$

En la ecuación (14) el parámetro S representa el factor de escala, mientras que en la ecuación (13) los valores de c y β controlan la sensibilidad del filtro. En particular el parámetro β se emplea para regular la sensibilidad asociada al parámetro R_B (ecuación 15) [16].

$$S = \sqrt{\lambda_1^2 + \lambda_2^2} \quad (14)$$

$$R_B = \frac{|\lambda_1|}{|\lambda_2|} \quad (15)$$

La respuesta total del filtro se calcula tomando el valor máximo de la función vesselness a lo largo de un rango de escalas, tal como se muestra en la ecuación (16) [17]:

$$V^F(x) = \max_{\sigma_{\min} \leq \sigma \leq \sigma_{\max}} V_{\sigma}^F(x) \quad (16)$$

En este caso para emplear este filtro se utilizó la biblioteca scikit-image. El filtro `skimage.filters.frangi` fue diseñado para resaltar estructuras lineales oscuras sobre un fondo claro. Este filtro opera mediante un método multiescala, analizando la imagen a distintos niveles de resolución para identificar vasos de diferentes calibres, tal como se plantea en el artículo original [15]. En dicho trabajo se emplean los valores $\beta = 0.5$, $c = 0.5$ y los valores de sigma en las escalas

1, 3, 5, 7 y 9 para el análisis multiescala, lo que incrementa su estabilidad ante la variabilidad estructural del sistema vascular [18].

F. Binarización

Se llevó a cabo un procedimiento de binarización en imágenes que habían sido previamente filtradas con el filtro de Frangi, con la finalidad de destacar las estructuras vasculares. En este contexto, se estableció un límite que se basó en el percentil que superaba el 7% de los valores de intensidad, lo que permitió mantener solo los píxeles más claros vinculados a las posibles venas. Posterior a ello se llevó a cabo una fase de limpieza morfológica donde se descartaron pequeños objetos blancos cuya superficie fuera inferior a un límite establecido, con el objetivo de disminuir el ruido binario y mantener solo las estructuras relacionadas a la red vascular. Este método permitió la creación de imágenes binarias con fondo negro y venas en blanco.

III. RESULTADOS

A continuación, se presentan los resultados con la metodología propuesta. Para ilustrar el procedimiento, se seleccionó una imagen representativa de la base de datos DRIVE se puede apreciar en la Fig. 6 el proceso seguido. El flujo de trabajo inició con la extracción del canal verde (G). Posteriormente se aplicó un filtro gaussiano adaptable, cuyo parámetro se ajustó de manera que se mantuviera un balance: suficiente suavizado para reducir ruido sin llegar a difuminar en exceso los detalles vasculares. Dicho valor variaba de una imagen a otra, se puede decir que este tipo de filtro se puede adaptar a la imagen.




Fig. 6. Imagen representativa al efectuar el preprocesamiento propuesto.

En una segunda etapa se empleó un filtro homomórfico con el objetivo de realzar el contraste y corregir las variaciones de iluminación características de las imágenes de fondo de ojo. Para optimizar sus parámetros se utilizó la entropía como función objetivo, en combinación con un algoritmo PSO. El enjambre consistió en 30 partículas evaluadas durante un máximo de 50 iteraciones. En la Tabla 1 se presentan los valores finales seleccionados para γ_H , γ_L y D_0 , tras el proceso de optimización. El efecto de este procesamiento se puede apreciar en la imagen de la Fig. 7: en la que se muestra el histograma del filtro gaussiano y, después del filtro homomórfico, la redistribución de intensidades en escala de grises con menor dispersión se interpreta como una compresión del rango tonal lo que indica una mejora en la calidad visual de la imagen. Cuantificando la entropía inicial de la imagen y posterior al filtro paso de un valor 5.7 a 6.2 bit/píxel.

TABLA 1
PARÁMETROS DEL FILTRO HOMOMÓRFICO

γ_H	γ_L	D_0
0.249	1.241	20




Fig. 7. Histograma antes y después del filtrado homomórfico en la imagen representativa.

Se analizó la base de datos completa para evaluar con mayor precisión el efecto del filtro (véase la Fig. 8). Como puede observarse, los valores de entropía se modificaron de manera consistente, lo cual se refleja en el cambio de la distribución en escala de grises: las imágenes mejoraron en calidad sin llegar a oscurecerse.




Fig. 8. Efecto del filtro homomórfico en la base de datos.

Este incremento en la entropía se debe a la adecuada selección de los parámetros del filtro homomórfico específicamente las variables γ_H , γ_L y D_0 los cuales cambiaron dinámicamente para cada imagen. Como se muestra en la Fig. 9, estos parámetros fueron ajustados individualmente, lo que posibilitó el máximo incremento de la entropía de salida. Este resultado indica que la estrategia empleada logro un incremento en el contraste y en la distribución de datos en las imágenes procesadas. El aumento en la entropía favoreció una mejor diferenciación entre las estructuras vasculares y el fondo retiniano, lo que permitió identificar un mayor número de píxeles pertenecientes a los vasos. En consecuencia, la sensibilidad clínica aumentó al detectar con mayor precisión las estructuras vasculares.




Fig. 9. Parámetros γ_H , γ_L y D_0 del filtro pasa-altas del filtro homomórfico aplicado a todas las imágenes.

Después de realizar la etapa de preprocesamiento con el filtro gaussiano adaptable y el filtro homomórfico optimizado, se implementó el filtro de Frangi con la finalidad de resaltar las estructuras vasculares en las imágenes de fondo de ojo. Posteriormente, se llevó a cabo una binarización por umbral adaptativo, seleccionando un porcentaje de los píxeles con mayor respuesta a la convolución, con el objetivo de separar claramente la red vascular del fondo de la imagen.

En las Figs. 10 y 11 se presentan los resultados obtenidos mediante esta metodología para las bases de datos STARE y DRIVE. Se utilizaron imágenes tanto normales como con presencia de patología (RD). En el caso de la base de datos DRIVE, la binarización logró detectar correctamente la red vascular, incluso en imágenes con RD, aunque con ciertos problemas. Esto se debe a que en las imágenes con RD contiene elementos irregulares, lo cual dificulta la detección por parte del filtro Frangi que está enfocado para formas tubulares bien definidas.

Por el contrario, la base de datos STARE presentó resultados más limitados. La calidad general de las imágenes es menor en comparación con DRIVE, lo que afecta directamente el desempeño del proceso de segmentación. Además, se observó que, al igual que en DRIVE, las imágenes con patología presentan dificultades adicionales debido a que las estructuras vasculares pierden su morfología lineal esperada, reduciendo así la eficacia del filtrado y la binarización.



Fig. 10. Segmentación de la red vascular en imágenes de fondo de ojo sin anomalías, obtenida mediante el método propuesto: a) Base de datos DRIVE, b) Base de datos STARE.




Fig. 11. Segmentación de la red vascular en imágenes de fondo de ojo con RD, obtenida mediante el método propuesto: a) Base de datos DRIVE, b) Base de datos STARE.

IV. LIMITACIONES Y TRABAJOS FUTUROS

Si bien el método propuesto mostró resultados satisfactorios en la segmentación de los vasos principales, aún presenta ciertas limitaciones que es importante considerar. Los vasos más prominentes se identificaron correctamente con este método, mientras que los vasos más delgados en algunos casos no lograron detectarse adecuadamente. A pesar de los avances en la segmentación automática de vasos retinianos, los métodos presentan dificultades cuando se aplican a imágenes de baja calidad. Este fue el caso al aplicar el método propuesto en las imágenes de la base de datos STARE, ya que, a diferencia de las de DRIVE, estas presentaban poco contraste e iluminación irregular. Por lo tanto, la calidad de la imagen es un aspecto importante a destacar para la correcta aplicación de este método. En cuanto a las imágenes que contenían patologías, como exudados y lesiones, si bien se realizó la segmentación, el método no las manejó de manera adecuada, lo que representó un factor que complicó el proceso de segmentación.

Dada su simplicidad y bajo costo computacional, la estrategia propuesta es adecuada como herramienta de apoyo en la evaluación preliminar de las imágenes en entornos clínicos donde la eficiencia es prioritaria, y puede aportar imágenes vasculares segmentadas que sirven de apoyo a la lectura clínica, sin requerir entrenamiento ni infraestructura especializada. No obstante, su desempeño disminuye en imágenes con bajo contraste u iluminación irregular o con lesiones como exudados, hemorragias, entre otros. Por ello, su uso se recomienda emplearse en etapas iniciales o complementaria a métodos más complejos como lo son las redes neuronales. Esta combinación de preprocesamiento y segmentación seguida de análisis avanzado o revisión clínica que permite equilibrar la rapidez y eficiencia con la necesidad de robustez en escenarios reales.

15

V. CONCLUSIONES

Los resultados encontrados en este trabajo muestran un efecto positivo en cada etapa del procesamiento para la mejora de la calidad de la segmentación vascular en las imágenes de fondo de ojo. Primero, el uso de un filtro gaussiano adaptativo por imagen ayudó a mejorar la nitidez sin dañar la eliminación de ruido lo que es clave para mantener la integridad de los vasos sanguíneos para etapas posteriores.

En segundo lugar, la aplicación del filtro homomórfico mejorado contribuyó al aumento en la entropía de las imágenes, mostrado por una mejor repartición de tonos grises y un aumento del contraste de los vasos sanguíneos. Este cambio fue importante para facilitar la detección posterior de zonas específicas.

Finalmente, el filtro de Frangi, con la ayuda de la binarización se obtuvo una segmentación adecuada en la mayoría de los casos, sobre todo en imágenes correspondientes a la base de datos DRIVE. Si bien se presentaron desafíos en imágenes con patologías avanzadas o baja resolución como algunas de la base STARE, el método logró mantener un desempeño aceptable, resaltando las regiones vasculares más prominentes.

Como recomendaciones futuras del trabajo se sugiere utilizar técnicas complementarias con estructuras vasculares atípicas o de baja calidad como enfoques basados en aprendizaje profundo que permitan identificar patrones no lineales y adaptarse mejor a variaciones patológicas. También se aconseja incorporar métricas adicionales, así como validar las propuestas en bases de datos mas amplios y diversos.

CRedit (Contributor Roles Taxonomy)

Contribuciones de los autores: Conceptualización: **EBBC**; Metodología: **AAR, EBBC, AASR**; Software: **EBBC, AAR**; Investigación: **EBBC, AAR**; Redacción y preparación del borrador original: **EBBC**; Redacción, revisión y edición: **AASR, AAR**; Supervisión: **AASR, AAR**; Análisis formal: **AAR, EBBC**; Administración del proyecto: **AAR**; Adquisición de fondos: No aplica.

Financiamiento: Los autores declaran que este trabajo fue desarrollado de forma académica.

Declaración de disponibilidad de datos: Los datos se encuentran en el artículo.

Agradecimientos: Los autores agradecen a la Unidad Profesional Interdisciplinaria en Ingeniería y Tecnologías Avanzadas del IPN por el respaldo institucional y académico durante el desarrollo del proyecto.

Conflicto de interés: Los autores declaran que no existe conflicto de interés.

REFERENCIAS

- [1] M. D. Abràmoff, M. K. Garvin, M. Sonka, “Retinal Imaging and Image Analysis,” *IEEE Reviews in Biomedical Engineering*, vol. 3, pp. 169–208, 2010, doi: [10.1109/RBME.2010.2084567](https://doi.org/10.1109/RBME.2010.2084567)
- [2] S. Yu, V. Lakshminarayanan, “Fractal Dimension and Retinal Pathology: A Meta-Analysis,” *Applied Sciences*, vol. 11, no. 5, Art. no. 5, Jan. 2021, doi: [10.3390/app11052376](https://doi.org/10.3390/app11052376)
- [3] K. B. Khan *et al.*, “A review of retinal blood vessels extraction techniques: challenges, taxonomy, and future trends,” *Pattern Anal Applic*, vol. 22, no. 3, pp. 767–802, Aug. 2019, doi: [10.1007/s10044-018-0754-8](https://doi.org/10.1007/s10044-018-0754-8)
- [4] S. Dubey, M. Dixit, “Recent developments on computer aided systems for diagnosis of diabetic retinopathy: a review,” *Multimed Tools Appl*, vol. 82, no. 10, pp. 14471–14525, Apr. 2023, doi: [10.1007/s11042-022-13841-9](https://doi.org/10.1007/s11042-022-13841-9)
- [5] M. R. K. Mookiah *et al.*, “A review of machine learning methods for retinal blood vessel segmentation and artery/vein classification,” *Medical Image Analysis*, vol. 68, p. 101905, Feb. 2021, doi: [10.1016/j.media.2020.101905](https://doi.org/10.1016/j.media.2020.101905)
- [6] A. Khandouzi, A. Ariaifar, Z. Mashayekhpour, M. Pazira, Y. Baleghi, “Retinal Vessel Segmentation, a Review of Classic and Deep Methods,” *Ann Biomed Eng*, vol. 50, no. 10, pp. 1292–1314, Oct. 2022, doi: [10.1007/s10439-022-03058-0](https://doi.org/10.1007/s10439-022-03058-0)
- [7] W. Wang, W. Wang, Z. Hu, “Retinal vessel segmentation approach based on corrected morphological transformation and fractal dimension,” *IET Image Processing*, vol. 13, no. 13, pp. 2538–2547, Nov. 2019, doi: [10.1049/iet-ipr.2018.5636](https://doi.org/10.1049/iet-ipr.2018.5636)
- [8] O. Ramos-Soto *et al.*, “An efficient retinal blood vessel segmentation in eye fundus images by using optimized top-hat and homomorphic filtering,” *Computer Methods and Programs in Biomedicine*, vol. 201, p. 105949, Apr. 2021, doi: [10.1016/j.cmpb.2021.105949](https://doi.org/10.1016/j.cmpb.2021.105949)
- [9] S. Biswas, M. I. A. Khan, M. T. Hossain, A. Biswas, T. Nakai, J. Rohdin, “Which Color Channel Is Better for Diagnosing Retinal Diseases Automatically in Color Fundus Photographs?,” *Life*, vol. 12, no. 7, p. 973, Jul. 2022, doi: [10.3390/life12070973](https://doi.org/10.3390/life12070973)
- [10] S. Misra, Y. Wu, “Chapter 10 - Machine learning assisted segmentation of scanning electron microscopy images of organic-rich shales with feature extraction and feature ranking,” in *Machine Learning for Subsurface Characterization*, S. Misra, H. Li, J. He, Eds., Gulf Professional Publishing, 2020, pp. 289–314. doi: [10.1016/B978-0-12-817736-5.00010-7](https://doi.org/10.1016/B978-0-12-817736-5.00010-7)
- [11] R. Bansal, G. Raj, T. Choudhury, “Blur image detection using Laplacian operator and Open-CV,” in *2016 International Conference System Modeling & Advancement in Research Trends (SMART)*, Moradabad, India, Nov. 2016, pp. 63–67. doi: [10.1109/SYSMART.2016.7894491](https://doi.org/10.1109/SYSMART.2016.7894491)

- [12] Á. Chavarín, E. Cuevas, O. Avalos, J. Gálvez, M. Pérez-Cisneros, “Contrast Enhancement in Images by Homomorphic Filtering and Cluster-Chaotic Optimization,” *IEEE Access*, vol. 11, pp. 73803–73822, 2023, doi: [10.1109/ACCESS.2023.3287559](https://doi.org/10.1109/ACCESS.2023.3287559)
- [13] R. C. Gonzalez, R. E. Woods, *Digital Image Processing*, 4th ed., Harlow, Essex, England: Pearson, 2018.
- [14] D.-Y. Tsai, Y. Lee, E. Matsuyama, “Information Entropy Measure for Evaluation of Image Quality,” *J Digit Imaging*, vol. 21, no. 3, pp. 338–347, Sep. 2008, doi: [10.1007/s10278-007-9044-5](https://doi.org/10.1007/s10278-007-9044-5)
- [15] A. F. Frangi, W. J. Niessen, K. L. Vincken, M. A. Viergever, “Multiscale vessel enhancement filtering,” in *Medical Image Computing and Computer-Assisted Intervention — MICCAI’98*, W. M. Wells, A. Colchester, and S. Delp, Eds., Berlin, Heidelberg: Springer, 1998, pp. 130–137. doi: [10.1007/BFb0056195](https://doi.org/10.1007/BFb0056195)
- [16] A. Khawaja, T. M. Khan, K. Naveed, S. S. Naqvi, N. U. Rehman, S. Junaid Nawaz, “An Improved Retinal Vessel Segmentation Framework Using Frangi Filter Coupled with the Probabilistic Patch Based Denoiser,” *IEEE Access*, vol. 7, pp. 164344–164361, 2019, doi: [10.1109/ACCESS.2019.2953259](https://doi.org/10.1109/ACCESS.2019.2953259).
- [17] D. Jimenez-Carretero, A. Santos, S. Kerkstra, R. D. Rudyanto, M. J. Ledesma-Carbayo, “3D Frangi-based lung vessel enhancement filter penalizing airways,” in *2013 IEEE 10th International Symposium on Biomedical Imaging*, San Francisco, CA, USA, Apr. 2013, pp. 926–929. doi: [10.1109/ISBI.2013.6556627](https://doi.org/10.1109/ISBI.2013.6556627)
- [18] A. Khawaja, T. M. Khan, K. Naveed, S. S. Naqvi, N. U. Rehman, S. Junaid Nawaz, “An Improved Retinal Vessel Segmentation Framework Using Frangi Filter Coupled With the Probabilistic Patch Based Denoiser,” *IEEE Access*, vol. 7, pp. 164344–164361, 2019, doi: [10.1109/ACCESS.2019.2953259](https://doi.org/10.1109/ACCESS.2019.2953259)