

Tipo de artículo: Artículo original

Técnicas de segmentación de imágenes de los vasos sanguíneos de la retina: una revisión

Blood vessel segmentation techniques in retinal images: a review

Enmanuel Veitia González ^{1*} , <https://orcid.org/0009-0002-0654-7616>

Alberto Taboada Crispí ² , <https://orcid.org/0000-0002-7797-1441>

¹ Dirección De Tecnología Educativa. Universidad Central "Marta Abreu" de las Villas. Carretera a Camajuaní Km. 5 y 1/2. Santa Clara. Villa Clara. Cuba. mannyveitiag@gmail.com

² Centro De Investigaciones De La Informática, Facultad de Matemática, Física y Computación. Universidad Central "Marta Abreu" de las Villas. Carretera a Camajuaní Km. 5 y 1/2. Santa Clara. Villa Clara. Cuba. ataboada@uclv.edu.cu

* Autor para correspondencia: mannyveitiag@gmail.com

Resumen

Se presentan técnicas de segmentación de vasos sanguíneos en imágenes de la retina. Estos métodos se pueden utilizar en análisis informáticos de imágenes retinales y en la detección semiautomática y automática de los vasos. Se tratará el método basado en la extracción de crestas de imágenes, que coinciden aproximadamente con las líneas centrales de los vasos, las crestas son utilizadas para componer elementos primitivos en forma de línea. Los métodos semiautomáticos disminuyen la demora en el análisis de las imágenes, frente a los métodos tradicionales manuales y contribuyen a una mejor calidad en las bases de datos.

Palabras clave: segmentación; retina; crestas; semiautomáticos; imágenes

Abstract

Blood vessel segmentation techniques in retinal images are presented. These methods can be used in computational analysis of retinal images and in semiautomatic and automatic detection of vessels. The method based on the extraction of image ridges will be discussed, which approximately coincide with the central lines of the vessels, the ridges are used to compose primitive line-shaped elements. Semiautomatic methods reduce the delay in image analysis, compared to traditional manual methods, and contribute to better quality in the databases.

Keywords: segmentation; retina; ridges; semi-automatic; images

Recibido: 09/08/2023

Aceptado: 12/12/2023

En línea: 01/01/2024

Introducción

Uno de los biomarcadores vasculares para la detección a tiempo de enfermedades, como la retinopatía hipertensiva (Fernández et al., 2022), la retinopatía diabética (Vijayan et al., 2023) y accidente cerebrovascular (Maimó Gallego et al., 2021), es el calibre de los vasos sanguíneos de la retina.



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional** (CC BY 4.0)

La fotografía de la retina requiere el uso de un sistema óptico complejo, llamado cámara de fondo de ojo (Pérez Molina & León Veitía, 2017). Es un microscopio especializado de baja potencia con una cámara adjunta, capaz de iluminar y obtener imágenes de la retina simultáneamente. Está diseñado para obtener imágenes de la superficie interior del ojo, que incluye la retina, el disco óptico, la mácula y el polo posterior.

La cámara de fondo de ojo normalmente funciona en tres modos. En la fotografía en color, la retina se examina a todo color bajo la iluminación de luz blanca. En la fotografía sin rojo, se mejora el contraste de los vasos y otras estructuras y se filtra la luz de la imagen para eliminar los colores rojos. Los angiogramas fluorescentes se adquieren utilizando el método de rastreo de colorantes. Se inyecta en la sangre fluoresceína sódica o verde de indocianina y luego se obtiene el angiograma fotografiando la fluorescencia emitida después de iluminar la retina con luz azul a una longitud de onda de 490 nanómetros (Fraz et al., 2012).

Los investigadores han estado utilizando métodos asistidos por computadora para segmentar automáticamente los vasos sanguíneos de la retina, incluidos las arteriolas y las vénulas, a partir de imágenes de la retina. Se han utilizado métodos tradicionales y no tradicionales, semiautomáticos y automáticos. El método de aprendizaje profundo (DL) posee la capacidad de clasificar cada píxel de una imagen de fondo de ojo en clases binarias (vaso/fondo) o múltiples (arteria/vena/fondo) (Lyu et al., 2022).

Los enfoques cada vez más complejos basados en arquitecturas de redes neuronales convolucionales sofisticadas han impulsado el rendimiento en conjuntos de datos de referencia bien establecidos. Se considera que la edad, la enfermedad oftalmológica y las condiciones en que se toman las fotografías, tienen una gran importancia en la segmentación, por lo que la segmentación de los vasos de la retina es una tarea desafiante. Ejemplo de ello es el caso de los niños, en donde hay un brillo prominente de las fibras nerviosas de la retina cerca de los vasos y la mácula, lo que bloquea la vista de las conexiones entre los vasos; en los adultos mayores, la hipoplasia del epitelio pigmentario de la retina deja visibles los vasos coroideos, de forma similar a la vasculatura de la retina; en las imágenes de fondo de ojo de los pacientes con retinopatía diabética pueden verse microaneurismas, hemorragias y exudados y los movimientos oculares y las operaciones incorrectas pueden provocar la pérdida de enfoque y exposición insuficiente (Lyu et al., 2022).

En el análisis de imágenes de la retina, la segmentación manual de los vasos sanguíneos de la retina requiere mucho tiempo y trabajo, a diferencia de otras tareas de preprocesamiento de imágenes de la retina, como la clasificación de arterias y venas, que es importante pero se puede hacer manualmente mientras se realizan estudios médicos (Tian et al., 2021). La segmentación semiautomática y automática de vasos es, por lo tanto, un proceso indispensable para una



interpretación cuantitativa eficiente de la vasculatura retiniana. Se han realizado muchos estudios sobre la segmentación de los vasos de la retina, incluidos los algoritmos convencionales y no. Muchos de los métodos publicados no se han evaluado en grandes conjuntos de datos o no dan buenos resultados para una gran cantidad de imágenes que se encuentran en un proceso de selección. El documento está organizado de la siguiente manera: en la sección Materiales y métodos, se explican los métodos de segmentación mencionados, se describe el clasificador utilizado y las características que se extraen en cada método. En la sección Resultados y discusión se dan una descripción de los resultados de los diferentes métodos y se discuten. En la sección Conclusiones se resume el trabajo y se exponen las conclusiones en base a la comparación.

Materiales y métodos

A) Detección de crestas

Las crestas de la imagen son indicadores naturales de los vasos, se inicia el análisis de una breve descripción general de la detección de crestas para imágenes bidimensionales de valores grises. Debido a que el canal verde de las imágenes de fondo de ojo a color, formateadas como imágenes RGB, ofrece el mayor contraste entre el vaso y el fondo, este canal se utiliza para la extracción de las crestas de la imagen (Biswas et al., 2022). Las crestas se definen como puntos en los que la imagen tiene un extremo en la dirección de la mayor curvatura de la superficie. Dicho de otra manera, buscamos los puntos en la imagen $L(\mathbf{x})$, con $\mathbf{x} = (x_1, x_2)^T$, donde la primera derivada de la intensidad en la dirección de la curvatura de la superficie más grande cambia de signo.

La dirección de mayor curvatura de la superficie es el vector propio $\hat{\mathbf{V}}$, de la matriz de derivadas de segundo orden de la imagen correspondiente al valor propio absoluto más grande λ . Esta matriz es nombrada como la matriz Hessian $\mathbf{H}$. El signo de λ determina si un mínimo local ($\lambda > 0$) o máximo local ($\lambda < 0$) es encontrado. Debido a que tomar derivadas de imágenes discretas es una operación mal planteada, se toman a escala σ utilizando la técnica de escala gaussiana. La idea principal es que las derivadas de la imagen se pueden tomar convolucionando la imagen con derivadas de una Gaussiana.

$$\begin{aligned} L_{x_j} &= \frac{\partial L(\mathbf{x}, \sigma)}{\partial x_j} \\ &= \frac{1}{2\pi\sigma^2} \int_{\mathbf{x}' \in \mathbb{R}^2} \frac{\partial e^{-\|\mathbf{x}-\mathbf{x}'\|^2/2\sigma^2}}{\partial x_j} L(\mathbf{x}') d\mathbf{x}' \quad (1) \end{aligned}$$



Donde x_j es la coordenada de la imagen con respecto a la cual se toma la derivada. Las derivadas mixtas y de orden superior se calculan tomando derivadas mixtas y de orden superior del núcleo gaussiano. Ahora es posible definir un campo escalar $\rho(\mathbf{x}, \sigma)$ sobre la imagen, que toma valor -1, para crestas de mínimos locales, 1 para crestas de máximos locales y 0 en otros lugares de la siguiente manera:

$$\rho(\mathbf{x}, \sigma) = -\frac{1}{2} \text{sign}(\lambda) |\text{sign}(\nabla L(\mathbf{x} + \epsilon \hat{\mathbf{v}}, \sigma) \cdot \hat{\mathbf{v}}) - \text{sign}(\nabla L(\mathbf{x} - \epsilon \hat{\mathbf{v}}, \sigma) \cdot \hat{\mathbf{v}})| \quad (2)$$

donde el operador de gradiente ∇ se define como $(\partial/\partial x_1, \partial/\partial x_2)^T$ y $\lambda(\mathbf{x}, \sigma)$ es el valor propio más grande por valor absoluto de $\mathbf{H} = \nabla \nabla^T L(\mathbf{x}, \sigma)$. En (2), $\hat{\mathbf{v}}$ y λ se evalúan en $(\mathbf{x}, \sigma)$. El parámetro ϵ es la precisión espacial con la que se detectan los conjuntos de puntos. En el caso continuo, se toma el límite $\epsilon \rightarrow 0$, pero en el caso de píxeles discretos $\epsilon = 1.0$ el píxel es una elección natural. Las ubicaciones en las que se evalúan los gradientes por lo general no están en un punto de cuadrícula y se usa interpolación lineal para obtener los valores de gradiente. El siguiente paso en la formación de primitivas para los vasos, es una agrupación de píxeles de cresta que pertenecen a la misma cresta. El objetivo es obtener primitivas que representen aproximadamente elementos de línea recta.

El método de agrupación es un algoritmo de crecimiento de región simple que compara un píxel de cresta ya agrupado con píxeles no agrupados en una vecindad de radio ϵ_c , donde el subíndice “c” representa conectividad. Si no hay ningún píxel agrupado disponible, se selecciona aleatoriamente uno nuevo como semilla de los píxeles de cresta sin agrupar restantes. La comparación entre el píxel agrupado y un píxel candidato dentro de la vecindad se basa en dos condiciones: 1) Las direcciones del vector propio de los píxeles de la cresta deben ser similares y 2) Si se cumple la condición 1), los píxeles deben estar en la misma cresta (y no en crestas paralelas). La primera condición puede comprobarse tomando el producto escalar de los vectores propios $\hat{\mathbf{v}}$ en la ubicación de los píxeles. Si los píxeles tienen una orientación similar el producto escalar estará cerca de 1. La segunda condición puede verificarse calculando el vector normalizado de longitud unitaria $\hat{\mathbf{r}}$ entre las ubicaciones de los dos píxeles bajo consideración y tomando el producto vectorial entre $\hat{\mathbf{v}}$ y $\hat{\mathbf{r}}$ del píxel agrupado. Si los píxeles están en el mismo segmento, el producto vectorial será cerca de 1.

Matemáticamente comprobamos las siguientes desigualdades



$$\|\mathbf{x}_g - \mathbf{x}_u\| \leq \epsilon_c \quad (3)$$

$$|\hat{\mathbf{v}}(\mathbf{x}_g, \sigma) \cdot \hat{\mathbf{v}}(\mathbf{x}_u, \sigma)| \geq \epsilon_o \quad (4)$$

$$\|\hat{\mathbf{v}}(\mathbf{x}_g, \sigma) \wedge \hat{\mathbf{r}}\| \geq \epsilon_p \quad (5)$$

donde el subíndice “g” significa agrupado, “u” desagrupado, “o” de orientación y “p” de paralelismo. El ϵ ’s determina la medida de similitud, donde $0 \leq \epsilon_c < \infty$ y $0 \leq \epsilon_o, \epsilon_p \leq 1$. Se hace referencia a estos conjuntos de (x_1, x_2) coordenadas como conjuntos afines convexos: convexos porque aproximan elementos de línea recta y afines debido a la convexidad geodésica en lugar de la convexidad de línea recta (euclidiana).

Si la detección de crestas no es perfecta, ϵ_c puede superar la discontinuidad causada por huecos en las crestas. El parámetro ϵ_o controla la cantidad de curvatura entre dos píxeles. Si se establece cerca a cero, se forman conjuntos convexos altamente curvados. Si se coloca cerca de uno, se obtienen conjuntos convexos más rectos. El parámetro ϵ_p impide el proceso de agrupación para saltar a crestas paralelas. Se recomienda un valor cerca de uno. El elemento k th en número de conjunto convexo i , que consta de K_i puntos, se denotarán por $\mathbf{c}_i(k), k = 1, \dots, K_i$. el vector $\mathbf{c}(k)$ es la ubicación $\mathbf{X}$ del elemento k th en el conjunto. El subíndice i se omite cuando no se hace referencia a ningún conjunto convexo en particular. Para cada punto en un conjunto convexo i tiene una dirección correspondiente $\hat{\mathbf{v}}_i(k)$, la dirección en la que se detecta la cresta. La imagen ahora se puede dividir en parches en función de los conjuntos convexos. Cada píxel es asignado al conjunto convexo al que es más cercano. Los parches se denominan regiones de conjuntos convexos (CSR). Una línea recta ajustada a través de un conjunto convexo se puede utilizar como eje principal de un marco de coordenadas local para los píxeles en el correspondiente RSC (Staal et al., 2004).

B) Métodos semiautomáticos:

La segmentación semiautomática de vasos sanguíneos es un proceso indispensable para una interpretación cuantitativa eficiente de la vasculatura retiniana, pues como se ha mencionado con anterioridad, la segmentación manual de los vasos sanguíneos de la retina requiere más tiempo. Los métodos basados en IA se han estudiado intensamente en los últimos años. El desarrollo y la evaluación de métodos basados en IA requieren conjuntos de datos con grandes cantidades de imágenes (Jiménez Herrera, 2021).

Se han establecido para uso público varias bases de datos de segmentación de vasos retinianos como: DRIVE, STARE, CHASE_DB1 y HRF, etc (Deng & Ye, 2022). Casi todo el trabajo de segmentación de vasos retinianos se ha



llevado a cabo en estos conjuntos de datos, incluidos los algoritmos de segmentación de vasos de última generación, como SCS-Net19, el modelo NFN y el modelo MS-DRIS-GP21. También hay algoritmos que pueden hacer una segmentación simultánea y una clasificación de arterias y venas desarrolladas en estos conjuntos de datos (Jin et al., 2022).

El modelo RETA, se ha diseñado como un método semiautomático para representar los vasos sanguíneos de la retina de grueso a fino en la imagen del fondo de ojo, donde se utilizan dos modelos de segmentación semántica basados en DL para generar automáticamente imágenes de segmentación de vasos.

Un software de etiquetado retinal asistido por computadora (CARL) se utiliza para la anotación y validación interactiva de los vasos (Lyu et al., 2022). La primera etapa es la anotación a nivel de píxel, donde un anotador humano trabaja una extensa corrección manual de vasos sobre la imagen predicha por computadora del modelo de segmentación A. Luego, se realiza el etiquetado de segmentos a nivel de estructura para clasificar todos los segmentos de vasos en arteria o vena. En la tercera etapa, se validan las anotaciones de imágenes a través de enfoques a nivel de red. El paso final es eliminar la ambigüedad de las etiquetas de píxeles en conflicto entre la máscara etiquetada manual y la máscara predicha automática (generada por el modelo de segmentación B). En este flujo de trabajo, un solo anotador humano capacitado, que realiza la anotación en varias etapas y la subsiguiente desambiguación de etiquetas, puede controlar sustancialmente la variabilidad entre anotadores y dentro de los anotadores. (Lyu et al., 2022)

C) Clasificador utilizado y características

En el caso del método de **detección de crestas**, se clasifica cada píxel de una imagen como vaso o no vaso. Para este propósito, se necesitan ejemplos etiquetados o conjuntos de entrenamiento, características y un clasificador. A partir de los conjuntos de entrenamiento se construyen vectores de características que se pueden etiquetar como vaso o no vaso, por lo que cada vector de características pertenece a una de dos clases. La idea es que los vectores de características de una clase en particular se agrupen en el espacio de características y que se pueda diseñar un clasificador que determine un límite de decisión entre las diferentes clases. Después del entrenamiento, un vector de características no etiquetado puede clasificarse determinando en qué lado del límite de decisión se encuentra. Con algunos clasificadores es posible aproximar la probabilidad, dadas las características, de que un píxel sea vaso o no. Esto se llama clasificación suave.

En **los métodos semiautomáticos** como RETA, se realiza una corrección manual en una imagen de vasos sanguíneos segmentada previamente que se adopta comúnmente en la comunidad. VGAN fue un modelo DL de



vanguardia para la segmentación de los vasos sanguíneos de la retina hace algunos años, pero aún funciona de manera excelente. Un modelo VGAN entrenado en la base de datos DRIVE, se utiliza para detectar píxeles de vasos. La imagen de fondo de entrada se redimensiona a 640×640 y la predicción suave de salida (probabilidades de los buques en [0,1]) se modifica posteriormente a partir de 640×640 a 1024×1024 dimensión.

Las imágenes binarizadas de los vasos se extraen mediante el método de umbral adaptativo local de Sauvola (Sauvola & Pietikäinen, 2000), que puede preservar mejor la conectividad de pequeños vasos. Para cada imagen de fondo de ojo, es creado un archivo mat correspondiente ("mat" es el contenedor de datos en MATLAB) juntando la imagen retiniana original, dos imágenes mejoradas y un vaso binario segmentado para la próxima corrección de vasos a nivel de píxel en CARL. El código de creación del archivo mat también es de código abierto. Se entrena el modelo de segmentación de vasos de puesta en marcha en otra base de datos para una mayor calidad de segmentación.

Resultados y discusión

En la detección de crestas, todos los experimentos llevados a cabo para el método de base primitivo, se encuentran después de un estudio piloto. Las crestas de las imágenes se extraen del canal verde a escala $\sigma = 1.5$ píxeles. Para obtener líneas aproximadamente rectas, el tamaño máximo de los conjuntos convexos se establece en 25 píxeles. Los conjuntos de entrenamiento para los conjuntos convexos se construyen contando cuántos de sus píxeles se cruzan con los píxeles del vaso en las imágenes reales de referencia etiquetadas manualmente. Si más del 50% de los píxeles en un conjunto convexo se cruzan, se etiquetan como vaso, de lo contrario, como no vaso. Las características del perfil para los conjuntos convexos se calculan con la mitad del ancho del perfil $N=15$, es decir, el perfil consta de 31 píxeles.

Para compensar las variaciones de iluminación y mejorar el contraste local, los píxeles de cada canal de color C_i de las imágenes se normalizan localmente a media cero y varianza unitaria.

$$N_i(\mathbf{x}, \sigma) = \frac{C_i(\mathbf{x}) - \mathcal{E}_\sigma\{C_i\}(\mathbf{x})}{\sqrt{\mathcal{E}_\sigma\{C_i^2\}(\mathbf{x}) - \mathcal{E}_\sigma^2\{C_i\}(\mathbf{x})}}$$

Con,

$$\mathcal{E}_\sigma\{C\}(\mathbf{x}) = \frac{1}{2\pi\sigma^2} \int_{\mathbf{x}' \in \mathbb{R}^2} C(\mathbf{x}') e^{-\|\mathbf{x} - \mathbf{x}'\|^2 / 2\sigma^2} d\mathbf{x}'$$

actuando como un operador promediador local. Es utilizado un valor de $\sigma = 8.0$ pixels. Las medidas de las crestas se extraen del canal verde y las escalas $\sigma = 0.5, 1.0, 2.0$, y se utilizan 4.0 píxeles. Con estos ajustes se extrae un total de



18 características por conjunto convexo. Para el entrenamiento del clasificador, solo se toma uno de cada cuatro conjuntos convexos. Esto reduce el tiempo de cálculo y los recursos de memoria. Para el cálculo de las características de una región de conjuntos convexos (CSR) se utilizan las siguientes configuraciones. En la fase de formación, las probabilidades *a posteriori* para los conjuntos convexos se calculan usando:

$$p(\text{vessel}) = \frac{n}{k}$$

(k son los píxeles vecinos, de los cuales n están etiquetados como vaso) de forma excluyente, es decir, los conjuntos convexos de una imagen se clasifican con un clasificador entrenado en los conjuntos convexos de las otras imágenes en el conjunto de entrenamiento. Las derivadas con respecto a los sistemas de coordenadas locales se toman a escalas $\sigma = 0.5, 1.0, 2.0$, y resultando en 27 características. Para el entrenamiento, solo cada cuarto píxeles en las direcciones $x1$ y $x2$ son utilizados. La selección de funciones también se realiza dejando uno fuera. Esto se hace para cada imagen y se promedia el valor Az de todas las imágenes para obtener un criterio sobre el cual se decide incluir como una función o no. Los clasificadores kNN para la clasificación de los conjuntos convexos y las CSR utilizan $k=101$. Debido a que los clasificadores kNN son sensibles a la escala entre diferentes funciones, en todos los experimentos, cada función se normaliza de forma independiente a la media cero y la varianza unitaria.

En **los métodos semiautomáticos**, se toma en cuenta el hecho de que calibre de las venas es significativamente más ancho que el de las arterias. Esto indica que podría haber más píxeles venosos que arteriales en una imagen retiniana. Posteriormente se verifica mediante los resultados estadísticos de máscaras A/V anotadas (el porcentaje medio de píxeles arteriales y venosos es del 41,91 % y el 58,09 %). Para reducir el tiempo de anotación, la estrategia de etiquetado A/V separa las venas de la imagen binaria del vaso y luego enmascarar las venas etiquetadas de la imagen original del vaso.

En los cruces arteriovenosos, se utiliza la finalización manual de imágenes para vincular segmentos de vasos arteriales desconectados. Las A/V son diferentes de algunos conjuntos de datos existentes. El enfoque está en la región de interés, se cambia una imagen de fondo mejorada, se localizan los puntos de bifurcación de los vasos A/V centrales y se rastrean los árboles A/V. Una regla fundamental es que el bucle vascular no está permitido en el árbol vascular trazado. La figura muestra una región OD ampliada y vasos A/V desenredados.






Figura 1. Separación de arteria/vena en relación con la región OD. (a) Imagen de fondo de ojo mejorada por abordaje de realce de contraste local (LCE). De (b) a (d), la imagen mejorada está cubierta por la máscara de la arteria, la máscara de la vena y la máscara A/V respectivamente (esta vista es el entorno de anotación real para el anotador humano en el software CARL).(Lyu et al., 2022)

Se utiliza color verde en lugar de azul para mostrar píxeles venosos para un contraste de fondo más fuerte. Hay dos vasos pequeños visualmente aislados (difícil de localizar la fuente de la raíz vascular de la imagen dada) etiquetados como vénulas en (C). Sus etiquetas A/V podrían predecirse en función de la función de topología.(Lyu et al., 2022) El calibre de los vasos varía de 1 a 20 píxeles en el punto de referencia RETA. La esqueletización de vasos se esfuerza por reducir los vasos gruesos y delgados a representaciones de 1 píxel de ancho. Como una de las estructuras tubulares, los vasos sanguíneos de la retina pueden presentarse como la envoltura de una familia de discos con puntos centrales y radios que cambian continuamente. Una imagen deseable del esqueleto de un vaso no requiere espolones (líneas espurias) en las líneas centrales extraídas. En este estudio, se implementa el método de esqueletización de Lee(Lee et al., 1994) para extraer esqueletos de vasos sin ningún estímulo no deseado en los límites o terminaciones vasculares. Sin embargo, no pudo detectar líneas centrales vasculares precisas en el borde del FOV donde la línea de sección transversal parcial del segmento del vaso está fuera del FOV. En este caso, se requiere la intervención humana para corregir estas regiones. Realizamos el enfoque anterior en la máscara arterial y la máscara venosa por separado.

Un árbol vascular A/V enraizado normal es un árbol binario en el que un vértice principal solo conecta dos vértices secundarios sin ningún círculo gráfico. Para cualquier vértice de bifurcación, se calcula el número de aristas conectadas mientras se asignan números de Strahler a las aristas del gráfico. El orden de flujo de Strahler está diseñado para reflejar la morfología del árbol vascular.



Tres propiedades geométricas importantes para los vasos sanguíneos de la retina son el calibre del vaso, el ángulo de bifurcación y la tortuosidad. La mayoría de las anomalías vasculares están estrechamente relacionadas con los cambios de estas propiedades geométricas. Los cambios de diámetro son claramente visibles en los rebordes venosos, el estrechamiento de las arteriolas/vénulas, la oclusión de la rama de la vena retiniana y la AVN. El bucle venoso es uno de los patrones de tortuosidad. Se extrajo el segmento de la máscara del vaso para cada segmento del esqueleto del vaso. Un método de estimación del diámetro del vaso se aplica para medir el diámetro del vaso de cada píxel de la línea central del segmento de la máscara del vaso. Se rastrean dos bordes secundarios que se conectan a un vértice de bifurcación y calculamos el ángulo de bifurcación entre ellos.

Se definen las anomalías geométricas de los vasos que cumplieran cualquiera de las siguientes condiciones: (1) variación del calibre focal >3 píxeles; (2) calibre medio de un segmento de vaso principal $<$ calibre medio de cualquier segmento de vaso secundario; (3) ángulo de bifurcación $>150^\circ$; (4) índice de tortuosidad del vaso >5 . Se asignó un anotador humano experimentado para revisar y actualizar las anotaciones de los vasos para todas estas anomalías candidatas. En esta etapa, se pueden identificar diferentes tipos de anomalías vasculares y producir máscaras de vasos gruesos/delgados en función de las características geométricas calculadas. Se supone que el calibre medio de un segmento de vaso grueso es mayor de 5 píxeles en RETA. El resto de segmentos de vasos están marcados como delgados.

Discusión de los resultados

Los métodos supervisados con selección de características, como la detección de crestas, constituye una solución para los problemas en los que muchas características interactúan de maneras complejas. Se puede ilustrar, en la base de datos de Hoover (Hoover et al., 2000), esto se ilustra por el hecho de que la precisión de la detección de crestas es mayor que la de un segundo observador independiente, aunque discrepan en un número de vasos pequeños con el segundo observador.

Una desventaja de los métodos supervisados es la necesidad de datos de entrenamiento etiquetados (manualmente). Para la base de datos de Utrecht, a un observador le tomó un promedio de 2 horas etiquetar una sola imagen. Se pueden distinguir dos tipos de errores. El primer tipo es la sobre segmentación y la su segmentación de los vasos. Esto es importante en aplicaciones donde se necesita determinar el ancho del vaso. El segundo tipo de error es la detección errónea o faltante de ramas de vasos. Supongamos, por ejemplo, que dos observadores etiquetan un vaso pequeño, pero en una de las segmentaciones el vaso se desplaza ligeramente para que ambos vasos no se superpongan. Esto



degradará la precisión más que si uno de los observadores no hubiera marcado ningún vaso. Se espera que los errores de tipo 2 se encuentren principalmente en vasos pequeños. Eliminando los vasos pequeños por una abertura morfológica, se puede aproximar el error de tipo 1 para los vasos grandes. La precisión entre el primer y el segundo observador aumentó de 0,947 a 0,964 en la base de datos de Utrecht y de 0,935 a 0,948 en la base de datos de Hoover.

Ciertos tipos de patología pueden detectarse y etiquetarse en un paso de preprocesamiento. Además, el método posee un desempeño imperfecto es el etiquetado incorrecto de los conjuntos convexos en los conjuntos de entrenamiento. O, lo que es peor, no se detecta ninguna cresta en la ubicación de un vaso, lo que puede suceder con vasos muy pequeños. Esto puede ocurrir porque las ubicaciones de las crestas se ven perturbadas por el desenfoque que se necesita para su detección. En el caso de los vasos grandes, los píxeles de la cresta detectados aún se encuentran dentro del vaso, pero en el caso de los vasos pequeños, pueden estar un poco desviados.

Las medidas de evaluación pueden ser más apropiadas, dependiendo de la aplicación en cuestión. Por ejemplo, si uno está interesado en examinar la tortuosidad de los vasos, el ancho de los vasos podría no ser importante, solo las líneas centrales. Las medidas utilizadas no tienen en cuenta el número de ramales, la conectividad de los vasos o el número de puntos de ramificación, que pueden ser relevantes en aplicaciones específicas. El funcionamiento de un sistema de diagnóstico asistido por ordenador para imágenes retinianas que utiliza los resultados de un algoritmo de segmentación de vasos en su análisis, puede constituir una medida de evaluación. Por otro lado, es necesario aumentar el rigor de la evaluación de las técnicas de segmentación de los vasos de la retina. El empleo de divisiones prueba/entrenamiento muy favorables, o calcular incorrectamente el rendimiento, conduce a informes de métricas infladas, que a su vez saturan los puntos de referencia públicos y brindan una falsa confianza de que la segmentación de los vasos retinianos no presenta desafíos.

Además, la selección de métricas de evaluación apropiadas para la tarea de segmentación de vasos es vital. Un conjunto dorado combinado {precisión, sensibilidad y especificidad} se adopta con frecuencia para indicar el rendimiento de la segmentación de vasos en la literatura. Varias métricas se basan en la coincidencia de píxeles (p.ej. área bajo la curva característica operativa del receptor), estas presentan el problema de la variabilidad del anotador. Las máscaras de vasos variadas (tanto en el grosor como en la ubicación de los vasos) están etiquetadas por el primer y el segundo observador en los conjuntos de datos DRIVE y CHASE_DB1. Además, estas métricas comparten el principal inconveniente de que pasan por alto la importante información geométrica y topológica de las estructuras vasculares. La medición cuantitativa de algunos biomarcadores vasculares (p.ej. FD) depende enormemente de una



topología vascular precisa. Además, una métrica justa debe tener en cuenta la relación de píxeles desequilibrada (grueso frente a delgado y vaso frente a fondo) de las imágenes de la retina.

Las técnicas de DL constituyen importantes herramientas para procesar imágenes, pero aún presenta limitaciones. Un ejemplo que nos encantaría compartir son los vasos falsos positivos detectados en el borde del FOV, el cual puede deberse a un fuerte contraste, ya que la intensidad de los píxeles fuera del FOV es cercana a cero. Y también se puede observar si utiliza el método de normalización de puntuación z (es decir, la media de todos los píxeles es 0 y la desviación estándar es 1) como método de normalización de imágenes para el entrenamiento y las pruebas del modelo DL. Una técnica de procesamiento de imágenes realmente simple puede resolver este problema. Implementamos un enfoque de relleno de píxeles artificiales en el borde FOV inspirado en el algoritmo de preprocesamiento de Soares (Soares et al., 2006). Incluso los modelos de segmentación de vasos sanguíneos basados en DL pueden ser fácilmente engañados y parece necesario un mayor estudio de los modelos DL avanzados u otras técnicas de vanguardia para los investigadores tanto en el análisis de imágenes médicas como en el dominio de la visión artificial.

Conclusiones

En este artículo se ha realizado un acercamiento a diferentes técnicas de segmentación, analizando a grandes rasgos sus métodos o procedimientos. La técnica de detección de crestas constituye un procesamiento matemático efectivo, pero que lleva trabajo de cómputo para la ejecución y solución de sus derivaciones. Dentro de los métodos semiautomáticos, el factor del especialista humano capacitado es esencial. Lo cual constituye por un lado la ventaja de que el aprendizaje se realiza de forma supervisada y que las etiquetas ayudan a una mejor organización de las bases de datos. Pero, por otro lado, toma más tiempo que otras técnicas e introduce en la ecuación el factor humano.

Cada método posee sus ventajas y desventajas, por lo que las investigaciones con respecto a la segmentación de los vasos sanguíneos deben continuar, teniendo siempre presente la rigurosidad con que deben realizarse. Un falso positivo puede llevar a un diagnóstico errado, afectar la visión del paciente y aumentar la desconfianza en los métodos de DL. No posemos pasar por el hecho, de que, sin importar el método utilizado para la segmentación de los vasos sanguíneos, todos los esfuerzos van en dirección del cuidado de la calidad de vida del paciente.

Agradecimientos

A los profesores de la Maestría en “Señales y sistemas” del Centro De Investigaciones De La Informática, Facultad de Matemática, Física y Computación en la Universidad Central “Marta Abreu” de las Villas, y a los profesores de la



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

Dirección de Tecnología Educativa y Facultad de Ingeniería Eléctrica en la Universidad Central “Marta Abreu” de las Villas, por sus excelentes enseñanzas y por su apoyo incondicional.

Conflictos de intereses

Los autores no poseen conflictos de intereses.

Contribución de los autores

1. Conceptualización: Enmanuel Veitia González y Alberto Taboada Crispi
2. Curación de datos: Enmanuel Veitia González
3. Análisis formal: Enmanuel Veitia González
4. Investigación: Enmanuel Veitia González
5. Metodología: Enmanuel Veitia González
6. Administración: Alberto Taboada Crispi
7. Supervisión: Alberto Taboada Crispi
8. Validación: Alberto Taboada Crispi
9. Visualización: Alberto Taboada Crispi y Enmanuel Veitia González
10. Redacción – borrador original: Enmanuel Veitia González, Alberto Taboada Crispi
11. Redacción – revisión y edición: Enmanuel Veitia González, Alberto Taboada Crispi

Financiamiento

La investigación no requirió fuente de financiamiento externa.

Referencias

- Biswas, S., Khan, M. I. A., Hossain, M. T., Biswas, A., Nakai, T., & Rohdin, J. (2022). Which Color Channel Is Better for Diagnosing Retinal Diseases Automatically in Color Fundus Photographs? *Life (Basel, Switzerland)*, 12(7). <https://doi.org/10.3390/life12070973>
- Deng, X., & Ye, J. (2022). A retinal blood vessel segmentation based on improved D-MNet and pulse-coupled neural network. *Biomedical Signal Processing and Control*, 73, 103467.



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

- Fernández, F. A. V., Villegas, J. A. C., Zambrano, M. C. M., & Bustamante, M. J. M. (2022). Alteraciones de la presión arterial y sus efectos en la salud visual. *RECIAMUC*, 6(3), Article 3. [https://doi.org/10.26820/reciamuc/6.\(3\).julio.2022.593-599](https://doi.org/10.26820/reciamuc/6.(3).julio.2022.593-599)
- Fraz, M. M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A. R., Owen, C. G., & Barman, S. A. (2012). Blood vessel segmentation methodologies in retinal images—A survey. *Computer Methods and Programs in Biomedicine*, 108(1), 407-433. <https://doi.org/10.1016/j.cmpb.2012.03.009>
- Hoover, A. D., Kouznetsova, V., & Goldbaum, M. (2000). Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. *IEEE Transactions on Medical Imaging*, 19(3), 203-210. <https://doi.org/10.1109/42.845178>
- Jiménez Herrera, L. G. (2021). Inteligencia artificial como potencia de herramienta en salud. *Infodir*, 36. http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S1996-35212021000300018&lng=es&nrm=iso&tlng=es
- Jin, K., Huang, X., Zhou, J., Li, Y., Yan, Y., Sun, Y., Zhang, Q., Wang, Y., & Ye, J. (2022). FIVES: A Fundus Image Dataset for Artificial Intelligence based Vessel Segmentation. *Scientific Data*, 9(1), Article 1. <https://doi.org/10.1038/s41597-022-01564-3>
- Lee, T. C., Kashyap, R. L., & Chu, C. N. (1994). Building Skeleton Models via 3-D Medial Surface Axis Thinning Algorithms. *CVGIP: Graphical Models and Image Processing*, 56(6), 462-478. <https://doi.org/10.1006/cgip.1994.1042>
- Lyu, X., Cheng, L., & Zhang, S. (2022). The RETA Benchmark for Retinal Vascular Tree Analysis. *Scientific Data*, 9(1), 397. <https://doi.org/10.1038/s41597-022-01507-y>
- Maimó Gallego, Y., Juvier Riesgo, T., Bory Vargas, N., Durán Pérez, M., Maimó Gallego, Y., Juvier Riesgo, T., Bory Vargas, N., & Durán Pérez, M. (2021). Manifestaciones neurooftalmológicas en pacientes con enfermedad cerebrovascular isquémica. *Revista Cubana de Oftalmología*, 34(1). http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S0864-21762021000100014&lng=es&nrm=iso&tlng=es
- Pérez Molina, E. C., & León Veitía, L. (2017). La fotografía de fondo de ojo como método de diagnóstico en el glaucoma. *Medicentro Electrónica*, 21(1), 3-10.



- Sauvola, J., & Pietikäinen, M. (2000). Adaptive document image binarization. *Pattern Recognition*, 33(2), 225-236. [https://doi.org/10.1016/S0031-3203\(99\)00055-2](https://doi.org/10.1016/S0031-3203(99)00055-2)
- Soares, J. V. B., Leandro, J. J. G., Cesar Júnior, R. M., Jelinek, H. F., & Cree, M. J. (2006). Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification. *IEEE Transactions on Medical Imaging*, 25(9), 1214-1222. <https://doi.org/10.1109/tmi.2006.879967>
- Staal, J., Abramoff, M. D., Niemeijer, M., Viergever, M. A., & van Ginneken, B. (2004). Ridge-based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging*, 23(4), 501-509. <https://doi.org/10.1109/TMI.2004.825627>
- Tian, F., Li, Y., Wang, J., & Chen, W. (2021). Blood Vessel Segmentation of Fundus Retinal Images Based on Improved Frangi and Mathematical Morphology. *Computational and Mathematical Methods in Medicine*, 2021, e4761517. <https://doi.org/10.1155/2021/4761517>
- Vijayan, T., Sangeetha, M., Kumaravel, A., & Karthik, B. (2023). Feature selection for simple color histogram filter based on retinal fundus images for diabetic retinopathy recognition. *IETE Journal of Research*, 69(2), 987-994.

