

Detección automática de glaucoma mediante segmentación de la copa y disco ópticos a través de imágenes de fondo de ojo usando el método de agrupamiento de regiones K-Means

Automatic glaucoma detection by segmentation of optical cup and disc from fundus images using K-Means region clustering method

Carlos Medina Betancourt¹, Luis Manuel Ledesma Carrillo², Eduardo Cabal Yépez³

^{1,2,3}División de Ingenierías del Campus Irapuato-Salamanca, Universidad de Guanajuato
c.medinabetancourt@ugto.mx¹, lm.ledesma@ugto.mx², educabal@ugto.mx³

Resumen

El glaucoma es considerado el ladrón de la visión humana, es la principal causa de ceguera irreversible a nivel mundial y en la actualidad no se ha encontrado una cura para ella. Sus síntomas son imperceptibles en las primeras etapas de la enfermedad, por lo que su detección temprana es de vital importancia. Se diagnostica midiendo las dimensiones del disco y copa ópticos localizados en la cabeza del nervio del ojo humano. En los pacientes con glaucoma este tamaño de la copa óptica se agranda mientras que el del disco óptico se mantiene igual. Para llegar a la conclusión si una persona tiene glaucoma se utiliza la relación copa - disco, el cual es el indicativo más usado para el diagnóstico de esta enfermedad. Este artículo se basa en desarrollar una metodología para la detección del glaucoma de forma automática a partir de imágenes de fondo de ojo mediante esta relación copa - disco (RCD). Se extrae la región de interés seguido de un preprocesamiento para tratar las imágenes y posteriormente, la segmentación de las áreas mediante el método no supervisado K- Means, el cual agrupa los pixeles correspondientes a cada área del disco y copa ópticos respectivamente. Un posprocesamiento le continua para mejorar la segmentación y el cálculo de este indicativo (RCD). El desempeño de la metodología implementada se evaluó en 48 imágenes de la base de datos DRISHTI-GS, de las cuales 33 son glaucomatosas y 15 pertenecientes a individuos con visión normal, obteniendo una precisión de 72.5% en general y un 86% para las imágenes glaucomatosas, teniendo un error medio de 0.11.

Palabras clave: Detección de glaucoma, imágenes de fondo de ojo, segmentación, pre-procesamiento, pos-procesamiento, relación copa-disco, K-Means.

Introducción

Dentro de las principales causas de ceguera a nivel mundial, el glaucoma ocupa el segundo lugar después de la catarata y es la primera causa de ceguera crónica irreversible (Salud, 2023). Sin embargo, la ceguera ocasionada por glaucoma puede evitarse realizando un diagnóstico temprano y estableciendo un tratamiento oportuno. Esta afección comienza mucho tiempo antes de que se manifieste clínicamente, existen cambios genéticos, moleculares, bioquímicos, ultraestructurales y estructurales que terminan en la mayoría de los casos en un daño funcional irreversible (Díez et al., 2014).

El glaucoma se vincula a enfermedades sistémicas como diabetes o hipertensión, pero también quienes tienen familiares directos con glaucoma tienen mayor probabilidad de padecerlo. La principal causa del glaucoma es la hipertensión ocular y su evolución es silenciosa y asintomática, por lo que poco a poco se va perdiendo la capacidad visual. (Barría & Jiménez-Román, 2019).

Es una enfermedad que ataca el nervio óptico del ojo humano, formado por millones de células nerviosas que conectan al ojo con el cerebro y a través de este se envían las señales captadas por la retina. Estos cambios en la cabeza del nervio producen deformaciones a este y aparece una excavación conocida como copa óptica como se representa la figura 1 (Sellés-Navarro et al., 2019). En la parte izquierda de la imagen se aprecia un ojo de un individuo sano y en la parte derecha un ojo de un individuo afectado por la enfermedad, se puede verificar la deformación a la cual se hace referencia.



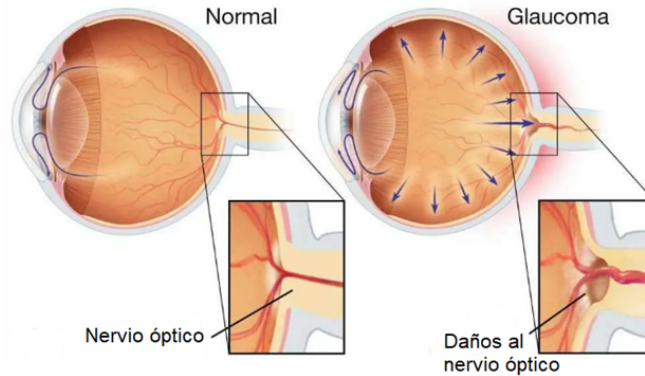


Figura 1. Ojo sano (izquierda) y ojo con glaucoma (derecha).
Fuente: Clinic, 2017.

Según datos de la Organización Mundial de la Salud (OMS) el glaucoma afecta a más de 60 millones de personas en el mundo y se calcula que casi 112 millones la adquieran para 2040 (Foundation, 2022). En México se estima que alrededor de 1.5 millones de personas la padezca y que la mitad desconoce que la tiene (Salud, 2022).

Esta enfermedad puede ser detectada basándonos en diferentes tipos de características conocidas como morfológicas y no morfológicas. Este artículo se centrará en la extracción de características morfológicas tratando de realizar un acercamiento de cómo los médicos especialistas lo hacen, pero usando una computadora. Para el cálculo del diámetro del disco y copa ópticos se utilizarán las técnicas de extracción de características morfológicas, lo cual se emplea para calcular la Relación Copa - Disco (RCD) y determinar la presencia de glaucoma en una persona; partiendo del criterio que si $RCD < 0.65$ se está en presencia de una persona sana y si $RCD \geq 0.65$ es una persona con glaucoma.

Las imágenes digitales de fondo de ojo son las más usadas para el análisis de la enfermedad porque son menos costosas e invasivas que otros métodos utilizados por los oftalmólogos tales como, la tomografía de coherencia óptica (OCT) y la tomografía de retina de Heidelberg (HRT).

En la figura 2 se muestra una imagen de fondo de ojo y su segmentación del disco y copa ópticos.




Figura 2. Imagen segmentada de fondo de ojo.
Fuente: Elaboración propia.

En la actualidad, los sistemas de visión por computadora han demostrado ser particularmente efectivos para analizar imágenes médicas y clasificar elementos de interés dentro de una imagen, por lo cual, las imágenes de fondo de ojo son una modalidad ampliamente utilizada para la detección de glaucoma (Abdullah et al., 2021).

Una particularidad de estas imágenes de fondo de ojo es que la localización del disco y copa ópticos se encuentran en las áreas de mayor intensidad, característica que usaremos para extraer la región de interés como paso inicial.

A continuación, se discutirán otros trabajos publicados en los cuales se ha utilizado un procedimiento similar para el diagnóstico del glaucoma.

En (Kavitha et al., 2012) se propone una técnica de modelo de color basada en la intensidad de las imágenes de fondo de ojo utilizando el método K-Means para delimitar entre la copa y el disco. El método se caracteriza por la detección inicial de la región de la copa seguida del borrado de los vasos sanguíneos. Se extraen características de textura y de forma para detectar mejor los sujetos patológicos. Se usó un clasificador del sistema de inferencia adaptativo neuro-difuso para reducir el tiempo de convergencia y se compara la efectividad con otros sistemas propuestos.

En (Shetty & Gutte, 2018), se propone una metodología novedosa para la detección del glaucoma utilizando el método perimetral de análisis fractal. Se realizó un preprocesamiento, primeramente, seguido del método K-Means para la segmentación de la copa óptica. Introducen el concepto de dimensión fractal que describe la dimensión de los objetos irregulares y es usado para calcular la forma más exacta de la copa óptica después de la segmentación.

(Hutami et al., 2019) presenta un método donde su primer paso es una etapa de preprocesamiento y posteriormente la segmentación de las regiones del disco y copa ópticos. El preprocesamiento tiene dos etapas: localización y preparación, que facilita la segmentación. Para la segmentación usan el método K-Means para agrupar las regiones, además de una operación morfológica para disminuir la influencia de los vasos sanguíneos y contornos activos para mejorar la extracción de las áreas.

En (Mvoulana et al., 2019) se propone una metodología totalmente automatizada para la detección y diagnóstico de glaucoma a partir de imágenes de fondo de ojo. Presentan dos nuevos enfoques para la segmentación conjunta del disco y la copa ópticos, basado en texturas y modelos. Para el enfoque basado en texturas utilizaron el método de agrupamiento K-Means usando un criterio de cercanía basado en intensidad, asignando cada área de la imagen retiniana en K grupos, siguiendo su nivel de gris. En el enfoque del establecimiento de límites basado en modelos se puede detectar adecuadamente los bordes, suavizarlos y mejorar el resultado de la segmentación.

En (Ayub et al., 2016), se centran en la detección automatizada de glaucoma a partir de imágenes de fondo de ojo. Se extrae primeramente la región de interés (ROI) mediante el método de centroide ponderado por intensidad, seguido de un preprocesamiento y una segmentación a través del método no supervisado de agrupamiento de regiones K-Means para la detección de la copa y disco ópticos. Posteriormente, se aplica un ajuste de elipse que es utilizado para mejorar la búsqueda de las regiones de interés.

En (Sharma & Verma, 2015) se propone una nueva metodología para la detección del disco óptico a partir de imágenes de la retina. Las imágenes se preprocesan utilizando un filtrado promedio espacial usando el canal verde. Se aplica posteriormente el algoritmo K-Means para la segmentación del disco óptico y el clúster que presenta una máxima intensidad se filtra utilizando el concepto de componentes conectados.

Este trabajo propone un método para el cálculo de la RCD usando el algoritmo K-Means para la segmentación, acompañado con un pre y pos-procesamiento de las imágenes, mediante la extracción de las características morfológicas usando la base de datos DRISHTI-GS. Este artículo se divide en 3 partes fundamentales: explicación y fundamentación de la problemática, descripción detallada por etapas de la metodología usada, presentación de los resultados y las conclusiones.

Metodología Propuesta

Se propone una metodología que consta de 5 etapas, la cual es mostrada en la figura 2. Como primer paso se selecciona la base de datos con la que se va a implementar el método propuesto, seguido de una etapa de preprocesamiento compuesta por la extracción de la región de interés y aplicación de filtros para mejorar las imágenes por la presencia de ruido, el algoritmo K-Means es aplicado para segmentar tanto las regiones



del disco y copa ópticos, el procesamiento posterior conformado por la aplicación de una técnica morfológica (cierre) y la eliminación de áreas excedentes de la segmentación preparan para la obtención de los diámetros de las áreas y cálculo de la RCD.

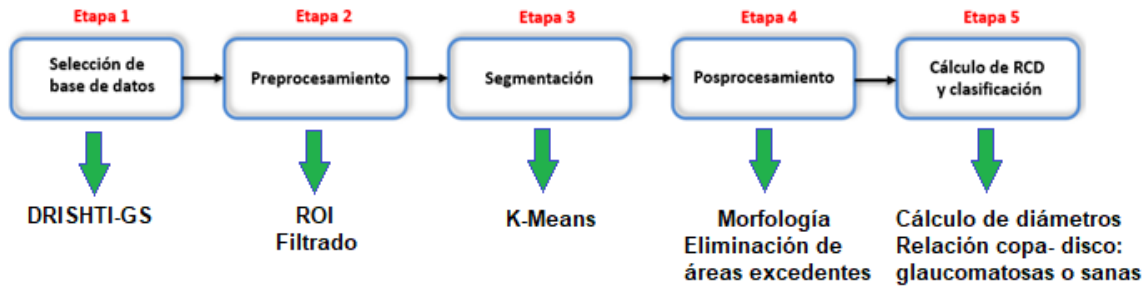


Figura 3. Metodología propuesta.
Fuente: Elaboración propia.

Etapa 1. Selección de la base de datos

La base de datos pública DRISHTI-GS es la seleccionada para implementar el método y consta de 101 imágenes, de las cuales 70 son glaucomatosas y 31 son normales, con un tamaño de 2045 x 1750 píxeles y en formato png sin comprimir. Esta base de datos se divide en dos grupos: Entrenamiento y Prueba con 50 y 51 imágenes respectivamente. Las verdades fundamentales fueron anotadas por 4 oftalmólogos con diferente experiencia, cuenta solo con la clasificación de las 50 imágenes presentes en el set de Entrenamiento y sus valores de RCD por cada especialista, no siendo el mismo caso para el set de prueba; por lo que para este trabajo se utilizará este grupo de Entrenamiento.

Etapa 2. Preprocesamiento

Extracción de la región de interés

El glaucoma afecta la cabeza del nervio óptico, el cual está localizado en la sección más brillante de la imagen, por consiguiente, lo que se encuentre fuera de esta área no ofrece ninguna otra información a considerar y puede ser eliminada, conociendo que el área del disco óptico corresponde aproximadamente al 12% de la imagen total, la extracción de la región de interés (ROI) presenta varias ventajas, como la disminución del tiempo de ejecución del algoritmo y el evitar procesar datos irrelevantes. Los resultados que se desean obtener son los representados en la figura 4, las figuras 5 y 6 muestran los pasos que se llevaron a cabo para la extracción de esta zona.




Figura 4. Extracción de la región de interés.
Fuente: Elaboración propia.

Las imágenes a color se pueden descomponer en 3 canales: rojo (R), verde (G) y azul (B), como paso inicial para la extracción se toma el canal rojo y se halla su inverso, convirtiendo los pixeles más claros en oscuros y viceversa. Este canal rojo nos ofrece más información sobre las mayores intensidades de las imágenes puesto que la sección del disco óptico va a presentar un porcentaje elevado de esta componente. Un filtro promedio es aplicado para reducir las variaciones de intensidad de pixeles vecinos, posteriormente se buscan sus mínimos, sus coordenadas y la mediana de estas coordenadas, coincidiendo con el punto medio de la región del disco óptico.

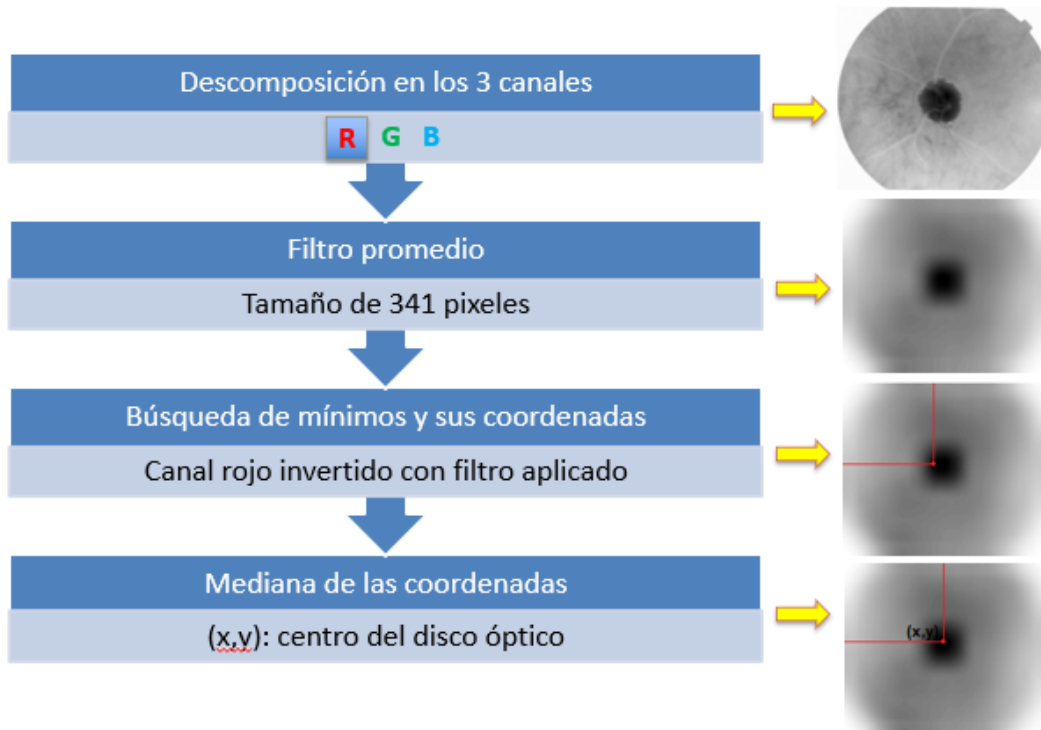


Figura 5. Pasos para la extracción de la región de interés.
Fuente: Elaboración propia.

Se realiza el ajuste del tamaño a recortar, en este caso 700 x 700 pixeles (figura 6). Este tamaño es adecuado porque la región del disco y la copa ópticos siempre se encontrarán dentro de esta área, sin afectar la segmentación que se efectúa en etapas posteriores.

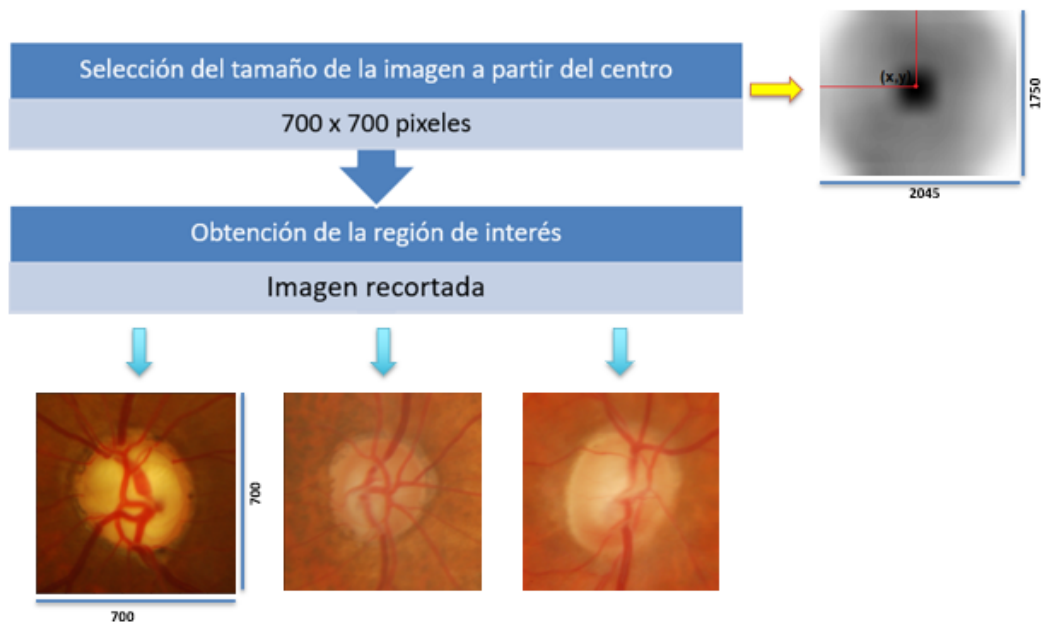


Figura 6. Pasos para la extracción de la región de interés. Resultados visuales.
Fuente: Elaboración propia.

La extracción del área de interés fue aplicado a las bases de datos DRISHTI-GS y Origa, de 101 y 650 imágenes respectivamente, obteniendo un porcentaje mayor al 90% en ambas. En las tablas 1 y 2 se reflejan los resultados alcanzados, las imágenes que fueron recortadas incorrectamente no son tomadas en cuenta para la etapa de segmentación.

Tabla 1. Resultados de la extracción de la región de interés.

Base de datos	Cantidad de imágenes	Recortadas correctamente	Recortadas incorrectamente	Porcentaje de error
Drishti-GS	101	98	3	2.97%
Origa	650	600	50	7.70%

Fuente: Elaboración propia.

Tabla 2. Resultados del porcentaje de efectividad en ambas bases.

Base de datos	Recortadas correctamente	Porcentaje de efectividad
Drishti-GS	98 de 101	97.03%
Origa	600 de 650	92.30%

Fuente: Elaboración propia.

Filtrado mediano

Para eliminar el ruido presente en las imágenes recortadas, se realiza un filtrado mediano de tamaño 15×15 píxeles. Este filtro funciona reemplazando el nivel central de una región de convolución por la mediana de sus píxeles. Se selecciona este tamaño del kernel para evitar en gran medida el suavizado de las imágenes y la pérdida de bordes.

Etapas 3. Segmentación usando K-Means

Para clasificar si una persona tiene glaucoma se usa la Relación Copa - Disco (RCD), para realizar este cálculo se tienen que extraer dos regiones: disco y copa ópticos. Para ello, se aplicará un método iterativo no supervisado que divide los datos en k grupos definidos con anterioridad. K-Means es un método de agrupamiento, que tiene como objetivo la partición de un conjunto de n observaciones en k grupos en el que cada observación pertenece al grupo cuyo valor medio es más cercano. Los centroides son colocados arbitrariamente, pero una mejor opción es colocarlos lo más lejos posible. Cada píxel se asigna al grupo donde su centroide esté más cercano y su centro se recalcula tomando la media de todos los píxeles del grupo, los dos últimos pasos se repiten hasta la convergencia, esto ocurre cuando los centroides no se mueven o se llega a un número de iteraciones definidas. Esta etapa se divide en 2 partes: la segmentación del disco óptico y la segmentación de la copa óptica.

Segmentación del disco óptico

Se convierten las imágenes recortadas y filtradas a escala de grises para trabajar con una sola matriz de datos. Haciendo uso de las funciones de Python y en este caso para la segmentación del disco óptico, se usa específicamente la relacionada con el K-Means, a la cual se le incorpora como argumentos la imagen, el criterio de parada, el número de iteraciones, inicialización del centroide (aleatorio) y la cantidad de grupos.

En la figura 7 se representa la imagen en escala de grises y el resultado de la segmentación con un agrupamiento igual a 3 ($K = 3$), esto quiere decir que el método K-Means agrupa en 3 regiones los datos y en la imagen segmentada (figura 7b) se puede apreciar que los píxeles con mayor intensidad corresponden al área del disco óptico. La figura 7c muestra la región extraída del disco tomando los otros dos grupos como fondo.




Figura 7. a) Imagen a escala de grises, b) Imagen segmentada, c) Área extraída.
Fuente: Elaboración propia.

Segmentación de la copa óptica

Partiendo del área ya segmentada como se muestra en la figura 8a y teniendo en cuenta que la copa óptica siempre se encuentra dentro del disco óptico, se procede a la segmentación y extracción. Los valores máximos de intensidad coinciden con los píxeles correspondientes a la copa (figura 8b). Se utilizan los mismos parámetros anteriores que para la segmentación del disco óptico, con la diferencia que la cantidad de grupos será igual a 4 ($K = 4$). La figura 8c representa el área extraída de la copa óptica.

Etapa 4. Posprocesamiento




Figura 8. a) Imagen ajustada, b) Imagen segmentada, c) Área extraída.
Fuente: Elaboración propia.

La influencia de los vasos sanguíneos principalmente en la segmentación de la copa es significativa (figura 9a), por lo que se tiene que aplicar una técnica de morfología matemática llamada "cierre" con el objetivo de unir estas regiones (figura 9a).

En un gran número de imágenes después de la segmentación realizada usando el método K-Means se presentan áreas excedentes que se tienen que eliminar. Estos dos pasos son importantes para luego realizar el cálculo de la Relación Copa - Disco y es aplicado primero la operación morfológica y después la eliminación del área o áreas excedentes.



Figura 9. a) Influencia de los vasos sanguíneos, b) Imagen de área con excedentes. "Fuente: Elaboración propia"

Morfología matemática: "Cierre"

Las operaciones morfológicas son un conjunto amplio de operaciones que sirven para procesar imágenes basadas en formas geométricas. La operación de cierre dilata una imagen y después, erosiona la imagen dilatada utilizando el mismo elemento estructurante para ambas operaciones. Es útil para rellenar huecos, a la vez que se conservan la forma y el tamaño de estos huecos, y objetos grandes de la imagen.




Figura 10. a) Área extraída de la copa, b) Imagen después de aplicado un cierre.
Fuente: Elaboración propia.

En la figura 10a es mostrada el área extraída de la copa óptica de una imagen y en la figura 10b la aplicación de la operación cierre a esta región, obteniendo como resultado su unión.

Eliminación de áreas excedentes

Producto de la segmentación y extracción de las áreas se encuentran algunas regiones excedentes que afectan la clasificación de las imágenes, por tal motivo se tienen que eliminar estas regiones que en su mayoría son áreas pequeñas. Para ello, se usa un concepto que se denomina "Análisis de Componentes Conectados" y es un algoritmo ya implementado en Python. El objetivo de este algoritmo es calcular todas las áreas en la imagen binarizada y mantener solo aquella que sea mayor, desechando todas las demás; estas son obtenidas mediante el cálculo de píxeles vecinos. El resultado de aplicar este método es el que se aprecia en la figura 11.




Figura 11. a) Imagen con área excedente, b) Imagen con área excedente eliminadas.
Fuente: Elaboración propia.

Etapas 5. Cálculo de la RCD y clasificación

La Relación Copa - Disco (RCD) indica si una persona tiene glaucoma o no y es obtenido usando la fórmula:

$$RCD = \frac{VDC}{VDD} \quad (1)$$

Donde VDC representa el diámetro vertical de la copa óptica y VDD es el diámetro vertical del disco óptico. La figura 12 muestra dicha relación entre los diámetros. Para la clasificación se tiene que el valor del umbral para el glaucoma es igual o superior a 0.65 mientras que para los casos normales sería inferior a 0.65.




Figura 12. Relación Copa - Disco.
Fuente: Elaboración propia.

Antes de realizar el cálculo se obtiene los diámetros de las áreas del disco y copa ópticos. A partir de las imágenes con las regiones excedentes ya extraídas, se hacen los contornos, por consiguiente, los puntos más exteriores y se traza una circunferencia que enmarque estos puntos; se usa la función `cv2.minEnclosingCircle()` de OpenCV que se basa en lo explicado anteriormente y devuelve el radio de la circunferencia tanto de la región de la copa óptica como del disco óptico (figuras 13a y 13b). Estos diámetros son usados en el cálculo de la RCD correspondiente a la fórmula 1.




Figura 13. a) Círculo circundante copa óptica, b) Círculo circundante óptico, c) Imagen con disco y copa ópticos calculados.
Fuente: Elaboración propia.

Resultados

El método propuesto se ha probado en 48 imágenes de la base de datos DRISHTI-GS, de las cuales 33 son glaucomatosas y 15 son normales. La clasificación obtenida a raíz del método propuesto es comparada con la clasificación disponible de la base de datos de las 48 imágenes resultando en un 72.5% de efectividad y para las imágenes glaucomatosas fue de 86%, esto quiere decir, que el método es mejor para identificar los individuos enfermos que los individuos sanos.

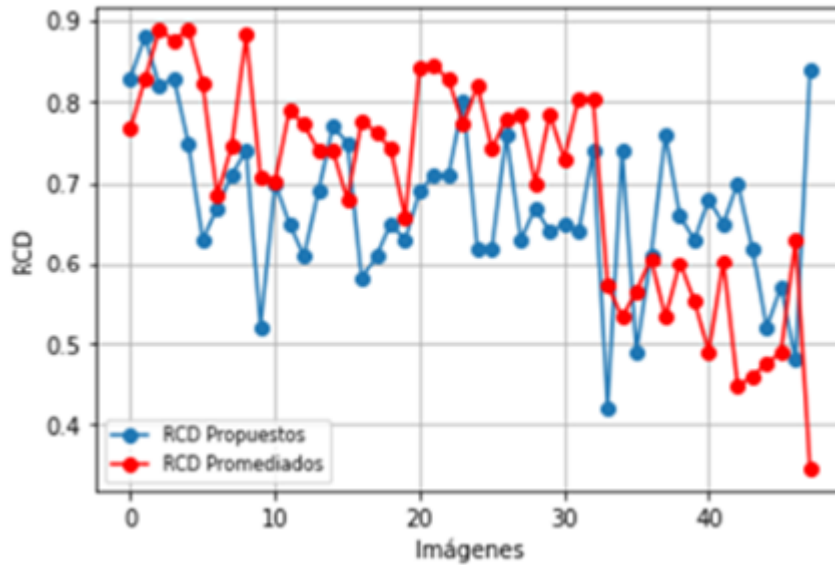


Figura 14. Relación Copa - Disco propuesto y Relación Copa - Disco promediado especialistas.
Fuente: Elaboración propia.

La RCD obtenida por el método propuesto es comparada con el promedio de la RCD de los 4 oftalmólogos (figura 14). Este promedio de la RCD realizada por los especialistas se encuentra dentro de la base de datos DRISHTI para las 50 imágenes de entrenamiento, de las cuales se usarán 48 porque las restantes 2 fueron descartadas en el proceso de extracción de la región de interés. Se puede apreciar que se obtienen valores muy similares a los promediados con excepción de algunos como por ejemplo el de la imagen 48 (último). El error absoluto de la RCD y el error medio se reflejan en la figura 15. El error absoluto está dado por la fórmula 2:

$$Error = abs(RCDp - RCDc) \quad (2)$$

Donde abs representa el absoluto del valor, la RCDp es la Relación Copa - Disco propuesta y la RCDc es la Relación Copa - Disco calculada.

La fórmula del error medio se representa como:

$$Error\ medio = \frac{Sum_Error}{Cant_images} \quad (3)$$

Donde Sum_Error es la suma de todos los errores y Cant_images es el valor total de imágenes.



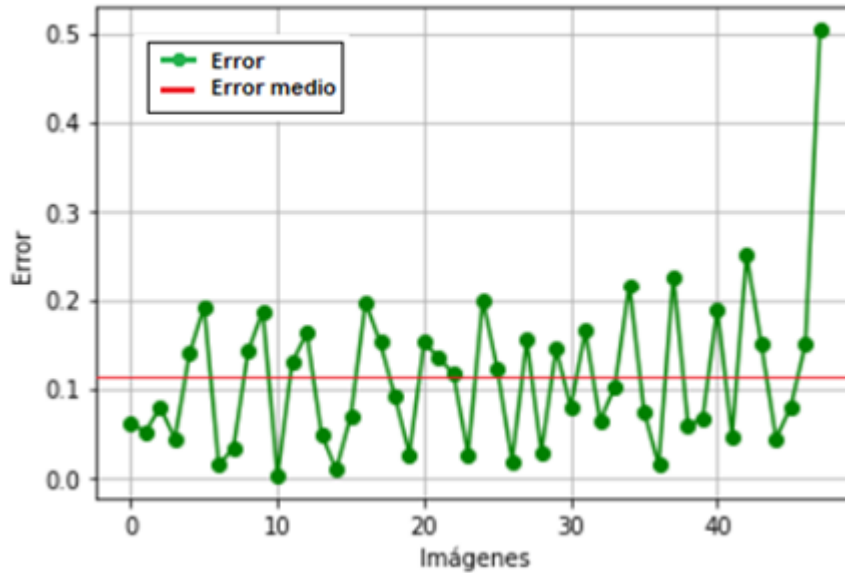


Figura 15. Error por imágenes y error medio.
Fuente: Elaboración propia.

Conclusiones

El criterio que más se utiliza para determinar si una persona tiene glaucoma es la Relación Copa - Disco (RCD). En este trabajo ha sido calculada para las 48 imágenes mediante la metodología propuesta y se ha realizado una clasificación según este valor, comparando con las RCD presentes en la base de datos DRISHTI, se obtuvo un 86% de efectividad para las imágenes glaucomatosas, resaltando que la metodología propuesta es más eficiente detectando individuos con la enfermedad. Una ventaja de esta metodología es que el tiempo de clasificación es muy pequeño, desde que se incorpora la imagen a analizar hasta que se ofrece un diagnóstico tomando casi 20 segundos y consume pocos recursos computacionales, todo este proceso se realiza de forma automática.

Agradecimientos

Se reconoce y agradece al "Consejo Nacional de Humanidades, Ciencia y Tecnología (CONAHCYT) – México", por financiar parcialmente esta investigación a través de la beca de posgrado 1252807 otorgada a Carlos Medina Betancourt.

Referencias

- Abdullah, F., Imtiaz, R., Madni, H. A., Khan, H. A., Khan, T. M., Khan, M. A., & Naqvi, S. S. J. I. A. (2021). A review on glaucoma disease detection using computerized techniques. 9, 37311-37333. DOI: 10.1109/ACCESS.2021.3061451
- Ayub, J., Ahmad, J., Muhammad, J., Aziz, L., Ayub, S., Akram, U., & Basit, I. (2016). Glaucoma detection through optic disc and cup segmentation using K-mean clustering. 2016 international conference on computing, electronic and electrical engineering (ICE Cube). DOI: 10.1109/ICECUBE.2016.7495212
- Barría, F., & Jiménez-Román, J. J. I. C. O. (2019). Guía latinoamericana de glaucoma primario de ángulo abierto para el médico oftalmólogo general. 1-49. <https://pao.org/wp-content/uploads/2016/05/Guia-Glaucoma-2019-final-para-www.pdf>



- Clinic, O. M. (2017). *Edad y antecedentes familiares son factores de riesgo importantes para glaucoma*.
<https://newsnetwork.mayoclinic.org/es/2017/06/26/edad-y-antecedentes-familiares-son-factores-de-riesgo-importantes-para-glaucoma/>
- Díez, R. C., Román, J. J., & Barbosa, M. J. I. J. R. M. d. O. (2014). Concepto de sospecha de glaucoma de ángulo abierto: definición, diagnóstico y tratamiento. *88(4)*, 153-160. DOI: 10.1016/j.mexoft.2014.02.001
- Foundation, G. R. (2022). *Datos y estadísticas sobre el glaucoma*. <https://www.glaucoma.org/es/datos-y-estadisticas-sobre-el-glaucoma>
- Hutami, A., Nugroho, H. A., Frannita, E. L., & Nurfauzi, R. (2019). Adaptive Localization and Segmentation of Optic Disc using K-means and Active Contour. 2019 5th International Conference on Science in Information Technology (ICSITech). DOI: 10.1109/ICSITech46713.2019.8987519
- Kavitha, S., Duraiswamy, K. J. I. J. o. A. i. E., & Technology. (2012). An efficient decision support system for detection of glaucoma in fundus images using ANFIS. *2(1)*, 227. ISSN: 2231-1963
- Mvoulana, A., Kachouri, R., Akil, M. J. C. M. I., & Graphics. (2019). Fully automated method for glaucoma screening using robust optic nerve head detection and unsupervised segmentation based cup-to-disc ratio computation in retinal fundus images. *77*, 101643. DOI: 10.1016/j.compmedimag.2019.101643
- Salud, G. d. M. S. d. (2022). *Se estima que en México 1.5 millones de personas padecen glaucoma*.
<https://www.gob.mx/salud/prensa/123-se-estima-que-en-mexico-1-5-millones-de-personas-padecen-glaucoma-secretaria-de-salud>
- Salud, G. d. M. S. d. (2023). *Glaucoma, enfermedad que causa ceguera irreversible*.
<https://www.gob.mx/salud/articulos/glaucoma-enfermedad-que-causa-ceguera-irreversible#:~:text=Este%20padecimiento%20es%20una%20de,y%20p%C3%A9rdida%20de%20la%20visi%C3%B3n>.
- Sharma, N., & Verma, A. J. I. J. S. E. R. (2015). Segmentation and detection of optic disc using kmeans clustering. *6(8)*, 237-240. ISSN 2229-5518
- Shetty, S. C., & Gutte, P. (2018). A novel approach for glaucoma detection using fractal analysis. 2018 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET). DOI: 10.1109/WiSPNET.2018.8538760

