

Nuevo Algoritmo para el Cálculo de la Relación Disco Óptico-Excavación Basado en Distancias de Color

F. J. Núñez¹, I. Fondón¹, M. Tirado¹, C. Serrano¹, B. Acha¹, S. Jiménez², P. Alemany²

¹ Dpto. Teoría de la Señal y Comunicaciones, ETSI, Universidad de Sevilla, Sevilla, España, kinube@gmail.com, {irenef, bacha, cserrano}@us.es

² Servicio de Oftalmología, Hospital Universitario Virgen del Mar, Cádiz, España, soledadjimenez@ono.com

Resumen

En este trabajo se presenta una nueva herramienta automática de diagnóstico asistido por computador (CAD) para programas de rastreo masivo de glaucoma mediante el cálculo de la relación de aspecto entre la excavación de la cabeza del nervio óptico y el disco óptico (Cup to Disk Ratio, CDR). El algoritmo combina métodos morfológicos, basados en intensidad y multitolerancia, junto a las técnicas de contornos activos y clustering o agrupación *K-means* adaptada a la percepción humana al trabajar sobre el espacio de color CIE $L^*a^*b^*$ haciendo uso de la distancia de color avanzada CIE94. Los resultados se han comparado con la segmentación manual a cargo de especialistas, demostrando la bondad del método. A su vez, se ha comprobado la mejora que supone la adaptación del algoritmo a la percepción humana comparando los resultados obtenidos con los que se alcanzarían con la distancia de color Euclídea.

1. Introducción

Según estudios recientes [1], el glaucoma es la segunda causa de ceguera en el mundo. La enfermedad comienza afectando a la visión periférica y progresa gradualmente hasta la pérdida total de la visión central. Hay alrededor de 4.5 millones de personas en el mundo ciegas por su causa, lo que constituye el 12.3% de todos los casos, estimándose que en la actualidad existen alrededor de 60.5 millones de personas en el mundo que podrían padecer la enfermedad [2]. Aunque el glaucoma produce daños irreversibles en el paciente, si es detectado a tiempo puede frenarse su progresión. Uno de los indicadores clínicos de la enfermedad es el CDR, que actualmente es calculado manualmente por los oftalmólogos. Además de ser una tarea lenta y tediosa, se ha comprobado [3] que su cálculo depende en gran medida de la experiencia y la habilidad del experto, problema que se resolvería gracias al uso de una herramienta CAD automática y fiable.

Los métodos desarrollados para el cálculo del CDR siguen los siguientes pasos: en primer lugar, el disco óptico (DO) es localizado en la retinografía y su borde es segmentado. Posteriormente, la excavación del nervio óptico (*cup*) es aislada del DO.

La localización del DO se ha llevado a cabo en el pasado siguiendo varios enfoques. Sinthanayothin et al. [4] asumen que la región buscada es aquella con la mayor variación de intensidad en la imagen debido a la aparición de la vasculatura (oscura) junto al fondo del DO (brillante). Muramatsu et al. [5] hacen uso del método de umbralización *p-tile* sobre el canal rojo de la imagen RGB

y, si el candidato resultante posee una circularidad superior a 0.6, es considerado como DO. Osareh et al. [6], tras normalizar las imágenes con un método de especificación de histograma, calculan la correlación espacial de cada imagen con una plantilla normalizada realizada mediante 25 DO, considerando que la región buscada es la que posee el mayor coeficiente de correlación. Reza et al. [7] preprocesan la imagen con un filtro de promediado y realizan un ajuste de contraste antes de aplicar a la imagen una transformada *watershed* controlada por marcas. Otro enfoque diferente es el presentado por Abràmoff et al. [8], ya que utilizan un modelo de regresión basado en la ubicación de la vasculatura y un clasificador *K-nn* (*K* nearest neighbor) para detectar la posición aproximada del DO.

Del mismo modo, el problema de la segmentación del DO ha sido abordado desde diferentes perspectivas. El uso de métodos basados en *level-set* [9], [10] o en contornos activos [11] está bastante extendido en la literatura actual. Xu et al. [12] proponen un método híbrido que emplea un modelo paramétrico deformable junto a la técnica de contornos activos en base al flujo del vector gradiente del contorno de la región localizada.

La segmentación de la excavación en imágenes retinográficas ha sido abordada por un escaso número de autores. En [9] los autores detectan su borde mediante la fusión de un método *level-set* y un análisis de histograma, adaptando el resultado obtenido a una elipse. Zhang et al. [13] utilizan la técnica *level-set* basada en la inicialización del umbral de forma que, tras realizar un análisis de histograma al canal verde de la imagen RGB, el umbral obtenido segmenta los píxeles correspondientes al tercio superior de los niveles de gris. A partir de este conjunto de píxeles se define un grupo convexo que posteriormente es adaptado a la forma de una elipse.

Observamos que ninguno de estos algoritmos emplea la información de color en la identificación del OD y la excavación. Así mismo, la adaptación a la percepción humana, tan necesaria en una herramienta que, si bien no pretende suplir al especialista al menos trata de emularlo, es absolutamente olvidada.

En este trabajo se presenta un nuevo método que combina distintas técnicas. Por un lado el árbol vascular es segmentado de forma adaptativa tomando como base un criterio de superficie. La localización del DO es llevada a cabo mediante una técnica de difusión anisotrópica,

comprendiendo su segmentación dos fases: en primer lugar se obtiene un borde aproximado de la región deseada mediante el método de contornos activos y posteriormente se obtiene el *DO* final mediante una apertura morfológica adaptativa del borde inicial. En cuanto a la excavación, el método empleado es el algoritmo de clustering *K-means* perceptivamente adaptado para trabajar en el espacio de color *CIE L*a*b**, donde los píxeles del *DO* son etiquetados según su información de color. La distancia de color empleada en la búsqueda de los nuevos centroides es la distancia avanzada *CIE94*. Para evitar los problemas derivados de la aparición de vasculatura sobre la excavación, se aplica sobre el conjunto de píxeles resultado una dilatación morfológica y un suavizado Gaussiano.

2. Descripción del algoritmo

El algoritmo desarrollado sigue los pasos que se describen a continuación.



Figura 1. Diagrama de flujo del algoritmo.

2.1. Preprocesado

El canal verde de la imagen *RGB* es sometido a un proceso de realce de contraste y de segmentación del árbol vascular basado en el descrito en [14] al que se ha añadido una mejora sustancial haciendo uso del conocimiento *a priori* de la extensión espacial de la vasculatura, que es aproximadamente el 10.5% de la superficie de la retinografía. Por consiguiente, la umbralización que permite la extracción de los vasos sanguíneos obtiene una imagen de árbol vascular cuya superficie se aproxima en la mayor medida posible a este valor. En la Figura 2 se muestra el resultado del preprocesado.

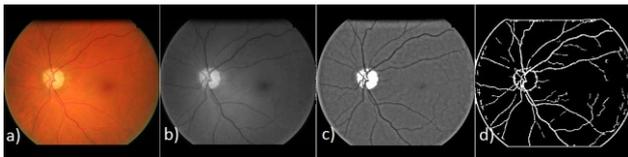


Figura 2. a) imagen original, b) canal verde de la imagen, c) realce de contraste y d) árbol vascular segmentado.

2.2. Localización del *DO*

El método de localización del *DO* hace uso de la distribución de intensidades en el canal verde de la imagen, ya que la presencia de la vasculatura (oscura) sobre el fondo del *DO* (brillante) proporciona la mayor varianza de intensidades. En primer lugar, se aplica una difusión anisotrópica en la que el valor de los coeficientes depende de la pertenencia del píxel al árbol vascular, como se describe en [15]. La imagen resultante es umbralizada con el objetivo de crear una máscara que contenga el *DO*. Por último, siguiendo el trabajo descrito en [4], se considera como centro del *DO* el píxel perteneciente a la máscara con la mayor varianza calculada en una ventana de 21 x 21 píxeles.

2.3. Segmentación del *DO*

La segmentación del *DO* es realizada en dos fases. En primer lugar se hace uso de una técnica de contornos activos [16] sobre el plano rojo de la imagen sin árbol vascular. El uso de este plano está motivado por la mayor uniformidad en la distribución de intensidades con respecto a los otros dos planos de color. La eliminación del árbol vascular se realiza mediante la sustitución de cada píxel del mismo por el valor medio de los píxeles pertenecientes a una ventana de tamaño 21 x 21 centrada en el píxel bajo estudio y que posteriormente es filtrada con un kernel de promediado de 5 x 5 píxeles para eliminar el ruido. El proceso de segmentación mediante contornos activos requiere una inicialización previa. En este caso se ha tomado como región inicial un área cuadrada de tamaño 100 x 100 centrada en el píxel considerado como centro del *DO*. Por otro lado, en esta técnica deben controlarse dos parámetros: el radio de localización, que representa la morfología del objeto a segmentar, y el número de iteraciones. Debido a que el *DO* puede considerarse como un elemento pseudo-elíptico con un tamaño definido, el radio de localización ha sido establecido en 20 píxeles, mientras que el número de iteraciones se ha fijado experimentalmente a 120. De esta forma el contorno final no es menor que el *DO* en ningún caso. Si la superficie encerrada por dicho contorno fuera mayor que la del *DO*, la segunda fase se encargará de corregir esta sobresegmentación.

Tras obtener esta aproximación del *DO*, se procede a realizar una apertura morfológica [17] sobre ella, que se ha implementado de forma adaptativa con un elemento estructural circular, dada la morfología del *DO*. En este sentido, el tamaño del radio de dicho elemento se ajusta automáticamente de forma que, partiendo de un radio inicial, en el caso de que el resultado de la apertura sea nulo, su valor es recalculado como sigue:

$$r_i = \left\lfloor \frac{1}{k_i} \sqrt{\frac{S_{ret}}{7\pi}} \right\rfloor \quad (1)$$

$$k_{i+1} = k_i + \Delta, \quad i = 0, 1, \dots, N$$

k_i es el factor de escala en la iteración i , Δ es un factor incremental, y N es el número de veces que se aplica la ecuación. Esta fórmula se basa en la evidencia fisiológica de que el radio del *DO* es aproximadamente 1/7 del radio de la retina. Sus parámetros han sido establecidos experimentalmente a $k_0 = 3$ y $\Delta = 0.1$. La superficie obtenida tras esta operación será la que empleemos en el cálculo del *CDR* en el último paso del proceso. En la Figura 3 se observan los resultados parciales y final de la segmentación del *DO*.

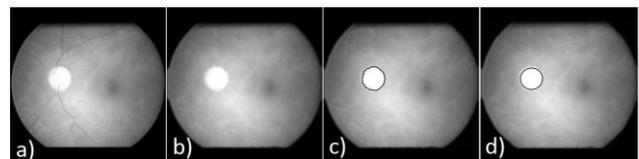


Figura 3. a) canal rojo de la imagen, b) resultado tras eliminar el árbol vascular y filtrar el ruido, c) primera aproximación mediante contornos activos y d) *DO* segmentado tras la apertura adaptativa.

2.4. Segmentación del cup

Agrupación por color. La clasificación de objetos mediante agrupación en K grupos, K -means, consiste en la realización de particiones del conjunto de datos a clasificar de forma que se minimice el error cuadrático medio, es decir, la suma de las distancia de cada elemento del grupo a su centroide. La segmentación en color basada en la técnica de agrupación toma como características de cada píxel sus tres componentes de color. Dado que las imágenes suelen almacenarse y mostrarse en el espacio RGB , los primeros trabajos de agrupación en color emplearon este espacio para la representación de las imágenes y la distancia Euclídea como métrica [18]. Hoy en día se sabe que éste y otros espacios (HSI , CMY , etc.) no están adaptados a la percepción humana. Los únicos espacios existentes que cuentan con una uniformidad aceptable son los espacios $CIE L^*u^*v^*$ y $L^*a^*b^*$, no siendo, sin embargo, perfectos. Para compensar la no uniformidad remanente, existen para el espacio $CIE L^*a^*b^*$ una serie de medidas de distancias avanzadas. De entre todas ellas la que proporciona mejores resultados en relación al coste computacional es la $CIE94$ [19]. Incluir en el proceso de K -means esta distancia avanzada necesita la elaboración de un método heurístico para el desplazamiento de los nuevos centroides dado que la compleja estructura de la fórmula imposibilita el proceso de búsqueda de mínimos por derivación e igualación a cero. El método propuesto está basado en la idea de que, para cada píxel de la imagen, el vector gradiente apunta en la dirección de máxima variación y, en consecuencia, la dirección opuesta es la de decrecimiento de la función. Este hecho puede emplearse en la búsqueda del mínimo. Así, para encontrar la localización de los nuevos centroides en cada iteración, el algoritmo calcula el gradiente y se desplaza una pequeña cantidad en la dirección contraria. En el momento en el que un nuevo desplazamiento suponga un crecimiento en la función se habrá llegado a un mínimo local. Por otro lado, en el proceso de K -means K es un parámetro de entrada. En nuestro caso K se calcula de forma automática de la siguiente forma: se realizan 8 procesos de K -means para $K=5, 6, \dots, 12$ y se determina cuál de ellos ha conseguido la segmentación más compacta según el parámetro de Dunn [20]. De todos los grupos segmentados, aquél que posea mayor brillo es el considerado como la excavación.

Identificación del borde de la excavación. Debido a la presencia de vasculatura en el DO , los píxeles obtenidos mediante la agrupación anterior suelen formar varios grupos inconexos. Por esta razón se realiza un procesado morfológico consistente en una dilatación de la superficie [17] y posterior suavizado Gaussiano del borde [21]. El resultado de esta operación es el borde de la excavación definitivo. La dilatación es realizada con un elemento estructural de forma circular cuyo tamaño debe estar en consonancia con la distancia entre los grupos inconexos de forma que, tras la dilatación, se obtenga un único grupo. Esta distancia está relacionada con la anchura de los vasos principales que cruzan el DO , cuyo valor típico con nuestra resolución de trabajo es de 15 píxeles, de

forma que el radio del elemento estructural ha sido fijado a 8 píxeles. El proceso se ilustra en la Figura 4.

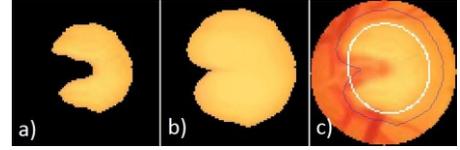


Figura 4. a) píxeles etiquetados como cup, b) dilatación del conjunto, c) cup (blanco) y borde dilatado (azul) sobre el resultado de la segmentación del DO .

2.5. Cálculo del CDR

Por último, el CDR es calculado de la siguiente manera:

$$CDR = S_{cup} / S_{DO} \quad (2)$$

S_{cup} es la superficie del cup considerada como el número de píxeles encerrados por el borde del cup y S_{DO} es la superficie del DO considerada como el número de píxeles encerrados por el borde del DO .

3. Resultados

Para evaluar el algoritmo se han empleado 47 retinografías con una resolución de 600 x 600 píxeles cedidas por el servicio de oftalmología del Hospital Puerta del Mar en Cádiz. En ellas tanto el DO como la excavación han sido segmentados manualmente por un grupo de oftalmólogos expertos, calculándose la tasa CDR (2), conformando así el criterio de certeza.

Así mismo, para evaluar numéricamente la eficacia del algoritmo se han calculado dos medidas estadísticas:

$$\mu(E) = \frac{1}{M} \sum_{j=1}^M E_j \quad (3)$$

$$\sigma(E) = \sqrt{\frac{1}{M} \sum_{j=1}^M (E_j - \mu(E))^2} \quad (4)$$

$$E_i = |CDR_j - CDR_j^{GS}|, \quad j = 1, 2, \dots, M \quad (5)$$

CDR_j^{GS} es el CDR calculado a partir de la segmentación manual de la imagen j , $\mu(E)$ es el error medio y $\sigma(E)$ es la desviación estándar del error. Estas medidas han sido realizadas para la detección de la excavación con dos medidas de distancia: la tradicional distancia Euclídea que no corrige la pequeña no uniformidad remanente en $CIE L^*a^*b^*$ y, por lo tanto no se adapta a la percepción humana, y la avanzada $CIE94$ que sí lo consigue. A su vez, se ha valorado la precisión de los resultados teniendo en cuenta el margen de error clínicamente aceptado por la comunidad oftalmológica [3].

El DO ha sido localizado correctamente en las 47 imágenes empleadas. En 5 de las imágenes se aprecia una sobsegmentación del DO debido a una alta saturación en los niveles de intensidad del canal rojo. Los resultados numéricos se muestran en las siguientes tablas:

Dist. de color	Euclídea	$CIE94$
$\mu(E)$	0.1472	0.1474
$\sigma(E)$	0.1014	0.1260

Tabla 1. Resultados obtenidos para cada distancia de color.

Clasificación del error	<0.15 CDR (intra-observador)	<0.2 CDR (inter-observador)	>0.2 CDR (Superior al límite)
Euclídea	27 (57.45%)	36 (76.60%)	11 (23.40%)
CIE94	28 (59.57%)	38 (80.85%)	9 (19.15%)

Tabla 2. Clasificación del error según los criterios aceptados de variabilidad intra e inter-observador para el cálculo del CDR.

Tanto el error medio como la desviación respecto a la segmentación manual son acordes con los obtenidos por otros autores recientemente [9], siendo similares para ambas distancias de color. Observamos que se mantienen por debajo del límite definido para la variabilidad intra-observador. No obstante se aprecia una mejora en cuanto a la clasificación del error para el CDR calculado con la distancia CIE94.

4. Conclusiones

Se ha presentado un algoritmo totalmente automático para el cálculo de la relación CDR, uno de los indicadores de glaucoma. En él se combinan diversas técnicas como umbralización, segmentación mediante contornos activos y agrupación basada en color. En este sentido, el presente trabajo maneja dos nuevos conceptos en el ámbito del cálculo automático del CDR: el uso de color en el proceso de segmentación y la adaptación del algoritmo a la percepción humana mediante el uso del espacio de color CIE $L^*a^*b^*$ y la distancia de color CIE94. A la luz de los resultados obtenidos, el algoritmo puede integrarse fácilmente en cualquier herramienta CAD dada su alta efectividad y precisión.

Referencias

[1] Resnikoff S, Pascolini D, Etya'ale D, Kocur I, Pararajasegaram R, Pokharel G, Mariotti S. Global data on visual impairment in the year 2002. *Bulletin of the World Health Organization*, vol 82, no 11, 2004, pp 887-888.

[2] Quigley HA, Broman AT. The number of people with glaucoma worldwide in 2010 and 2020. *Br. J. Ophthalmol.*, vol 90, no 3, 2006, pp 262-267.

[3] Varma R, Spaeth GL, Steinmann WC, Katz LJ. Agreement between clinicians and an image analyzer in estimating cup-to-disc ratios. *Arch Ophthalmol*, vol 107, no 4, 1989, pp 526-529.

[4] Sinthanayothin C, Boyce JA, Cook HL, Williamson TH. Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images. *Br. J. Ophthalmol.*, vol 83, no 8, 1999, pp 902-910.

[5] Muramatsu C et al. Automated segmentation of optic disc region on retinal fundus photographs: Comparison of contour modeling and pixel classification methods. *Computer Methods and Programs in Biomedicine*, 2010, Article in Press.

[6] Osareh A, Mirmehdi M, Thomas B, Markham R. Comparison of colour spaces for optic disc localisation in retinal images. *Proc. 16th Int. Conf. Pattern Recognition*, 2002, pp 743-746.

[7] Reza AW, Eswaran C, Dimiyati K. Diagnosis of Diabetic Retinopathy: Automatic Extraction of Optic Disc and Exudates from Retinal Images using Marker-controlled

Watershed Transformation. *Journal of Medical Systems*, 2010 (ISSN: 1573-689X).

[8] Abràmoff MD, Niemeijer M. The automatic detection of the optic disc location in retinal images using optic disc location regression. *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, 2006, art no 4030246, pp 4432-4435.

[9] Wong DWK et al. Intelligent fusion of cup-to-disc ratio determination methods for glaucoma detection in ARGALI. *Proceedings of the 31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society: Engineering the Future of Biomedicine*, 2009, art no 5332534, pp 5777-5780.

[10] Echegaray S, Soliz P, Luo W. Automatic initialization of level set segmentation for application to optic disc margin identification. *IEEE Symposium on Computer-Based Medical Systems - Proceedings*, 2009, art no 5255445.

[11] Yandong T, Xiaomao L, Von Freyberg A, Goch G. Automatic segmentation of the papilla in a fundus image based on the C-V model and a shape restraint. *International Conference on Pattern Recognition - Proceedings*, 2006, art no 1698863, pp 183-186.

[12] Xu J, Chutatape O, Sung E, Zheng C, Kuan PCT. Optic disk feature extraction via modified deformable model technique for glaucoma analysis. *Pattern Recognition*, vol 40, no 7, 2007, pp 2063-2076.

[13] Zhang Z et al. Neuro-retinal optic cup detection in glaucoma diagnosis. *2nd International Conference on Biomedical Engineering and Informatics - Proceedings*, 2009, art no 5305076.

[14] Núñez F, Serrano MC, Acha B, Fondón I, Jiménez S, Alemany P. Detección Automática de Microaneurismas en Retinografías para Diagnóstico Precoz de Retinopatía Diabética. *Actas del XXVII Congreso Anual de la Sociedad Española de Ingeniería Biomédica, CASEIB*, 2009, pp 581-584.

[15] Perona P, Malik J. Scale Space and Edge Detection Using Anisotropic Diffusion. *IEEE Transactions on Pattern Recognition and Machine Intelligence*. vol 12, no 7, 1990, pp 629-639.

[16] Lankton S, Tannenbaum A. Localizing region-based active contours. *IEEE Trans Image Process*. vol 17, no 11, 2008, pp 2029-2039.

[17] Soille P. *Morphological Image Analysis: Principles And Applications*. Springer-Verlag. Berlin, Heidelberg, New York, vol 1, 1999.

[18] Comaniciu D, Meer P. Robust Analysis of Feature Spaces: Color Image Segmentation. *Proc. Of CVPR '97*, 1997, pp 750-755.

[19] CIE, CIE Technical Report; Industrial Colour Difference Evaluation. *CIE Publication*, Vienna, no 116, 1995.

[20] Maulik U, Bandyopadhyay S. Performance evaluation of some clustering algorithms and validity indices. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, vol 24, no 12, 2002, pp 1650-1654.

[21] Lee TK, McLean DI, Atkins MS. Irregularity index: A new border irregularity measure for cutaneous melanocytic lesions. *Medical Image Analysis*, vol 7, no 1, 2003, pp 47-64.