

Realce de retinografías mediante la aplicación de métodos basados en la transformada *wavelet*

M. García Gadañón¹, J. Poza Crespo¹, M. I. López Gálvez², C. Valverde Collar³, L. Fraile Cáceres¹, R. Hornero Sánchez¹

¹ Grupo de Ingeniería Biomédica, Universidad de Valladolid, Valladolid, España, {margar, jespoz}@tel.uva.es, fcacereslau@hotmail.com, robhor@tel.uva.es

² Hospital Clínico Universitario de Valladolid, Valladolid, España, maribel@ioba.med.uva.es

³ Hospital Medina del Campo, Medina del Campo, Valladolid, España, carmenvalverde12@hotmail.com

Resumen

El análisis de retinografías es una herramienta útil en el diagnóstico de diversas patologías oculares. No obstante, las imágenes que pueden aparecer en un entorno clínico presentan características muy diferentes de color, contraste y calidad. Por ello, es necesario incluir un método de normalización y realce para facilitar su análisis manual o como primera etapa de métodos de procesamiento automáticos más generales. En este trabajo se propone un método de realce y normalización de retinografías basado en la transformada wavelet discreta en dos dimensiones. Los coeficientes obtenidos tras la descomposición wavelet de la imagen se modifican de acuerdo con una función predefinida y la imagen se reconstruye en base a los coeficientes modificados. Se empleó una base de datos de 163 retinografías (98 imágenes de entrenamiento y 65 imágenes de test). Se eligió una imagen de referencia adicional, con características óptimas de iluminación y contraste. Los resultados se cuantificaron en base a un índice de luminosidad y dos índices de contraste. Las diferencias de estos índices con la imagen de referencia variaron entre el 11.6% y el 24.4%, lo que indica una elevada similitud entre las imágenes normalizadas y la imagen de referencia. Los resultados obtenidos sugieren que el método propuesto puede ser útil para mejorar la visualización de las imágenes y contribuir así a incrementar la precisión de los métodos de detección manuales y automáticos.

1. Introducción

La evaluación de retinografías es una herramienta útil en el diagnóstico de diversas enfermedades [1]. Determinadas anomalías vasculares y no vasculares observables en el fondo de ojo pueden considerarse como indicadores significativos de enfermedades como la diabetes o la hipertensión [2]. Entre las anomalías vasculares cabe destacar el aumento de la tortuosidad [3] o estrechamiento generalizado de los vasos sanguíneos [4], mientras que entre las anomalías no vasculares se encuentran lesiones como exudados duros, microaneurismas o hemorragias [2, 5, 6].

Los métodos automáticos de análisis de retinografías, que tienen como fin detectar y cuantificar estas anomalías, suponen una importante herramienta de ayuda al diagnóstico [5, 6]. No obstante, la precisión de dichos métodos se ve limitada por la variabilidad de las imágenes que pueden aparecer en un entorno clínico. Ésta es debida a las características físicas del paciente, como su color de

piel o iris, y al proceso de adquisición de las imágenes, que puede provocar variaciones de luminosidad y contraste dentro de la imagen. Como consecuencia, su análisis automático es más complejo y la mayoría de los métodos de análisis automático incluyen una primera etapa cuyo objetivo es normalizar las imágenes y aumentar el contraste entre las lesiones y el fondo [7].

Se han propuesto multitud de técnicas para compensar la iluminación y el contraste no uniformes en retinografías. En algunos trabajos se estiman y corrigen las variaciones de luminosidad utilizando un filtro de medianas [8]. Otros autores emplean un filtrado no lineal para realzar las regiones oscuras de la imagen [9]. Técnicas más novedosas se basan en estimar las variaciones de luminosidad y contraste en la imagen y compensarlas para obtener la imagen realzada [1]. Asimismo, existen técnicas basadas en el análisis en frecuencia de la imagen que tratan de forma diferente las variaciones lentas de intensidad en la imagen (generalmente asociadas al fondo) y las variaciones rápidas de intensidad (asociadas a estructuras oculares y lesiones) [11].

En este trabajo se propone un nuevo método de análisis espectral para el realce de retinografías basado en la transformada *wavelet*. Los objetivos del estudio fueron: (i) desarrollar un método de realce de retinografías basado en la transformada *wavelet*, (ii) cuantificar los resultados obtenidos sobre una base de datos heterogénea y (iii) evaluar la utilidad del método para su incorporación dentro de una metodología más general de ayuda al diagnóstico de la retinopatía diabética (RD).

2. Base de datos

La base de datos analizada contiene 163 retinografías proporcionadas por el Hospital Clínico Universitario de Valladolid y el Instituto de Oftalmobiología Aplicada (IOBA) de la Universidad de Valladolid. Treinta de estas imágenes fueron captadas con el retinógrafo no midriático TopCon TRC-NW6S con un campo de visión (FOV) de 45°. Las 133 imágenes restantes se captaron con un retinógrafo midriático TopCon TRC-50IX con un FOV de 50°. La resolución de estas imágenes es de 576 × 768 píxels en formato JPEG de 24 bits. Estas imágenes pertenecen a pacientes sanos (25 imágenes) o a pacientes

con RD leve o moderada (138 imágenes). Las imágenes se dividieron aleatoriamente en un conjunto de entrenamiento (98 imágenes) y un conjunto de test (65 imágenes). Una oftalmóloga especialista eligió una imagen de referencia adicional. Dicha imagen pertenece a un paciente joven y sano. Se considera que sus características de contraste y calidad son óptimas. Dicha imagen se captó con el retinógrafo midriático TopCon TRC-50IX con un FOV de 50°. Su resolución es de 3008 × 2000 píxels en formato JPEG de 24 bits.

3. Métodos

El método consta de 4 etapas: (i) delimitación del área de interés de la imagen, (ii) descomposición *wavelet*, (iii) modificación de los coeficientes *wavelet* y (iv) reconstrucción *wavelet*. En la etapa de modificación de los coeficientes *wavelet* fue necesario ajustar experimentalmente un parámetro ($G_{\text{óptima}}$), para lo que se empleó un método de regresión. Se partió de la componente verde de la imagen original, G_o , ya que presenta mayor contraste que otros planos de color y se ha utilizado en estudios previos para la posterior detección de lesiones asociadas a la RD en retinografías [5, 6].

3.1. Delimitación del área de interés de la imagen

En esta primera etapa se creó una máscara para diferenciar los píxels que pertenecen a la retina o FOV del borde negro circundante. Para ello se obtuvo la circunferencia que delimita el área retiniana. El radio de la circunferencia se calculó como la mitad de la distancia entre el máximo y el mínimo del perfil de intensidad a lo largo de una diagonal de la componente roja de la imagen original, R_o . Posteriormente, se aplicó la transformada de Hough para determinar su centro [11].

3.2. Análisis *wavelet*

La transformada *wavelet* proporciona una localización eficiente en espacio y en frecuencia para una imagen [12]. Utiliza una base de funciones ortogonales para proyectar una señal sobre el nuevo espacio que éstas representan.

Una familia *wavelet* $\psi_{a,b}(x)$, donde $a, b \in \mathbb{R}$, $a \neq 0$, se genera a partir de la dilatación y traslación de una *wavelet* madre, $\psi(x)$. La transformada *wavelet* discreta (DWT) proporciona una representación no redundante de la señal. Sus valores son los coeficientes de la serie *wavelet* y la información puede organizarse en un esquema jerárquico, llamado análisis multiresolución [13]. Para este estudio se ha empleado la DWT en dos dimensiones (2D-DWT), puesto que la componente G_o es una señal bidimensional. En este caso, la 2D-DWT de una imagen $G_o(x,y)$ se puede calcular empleando una descomposición piramidal [13].

3.3. Modificación de los coeficientes *wavelet*

La etapa de descomposición *wavelet* proporciona un conjunto de coeficientes de aproximación y de detalle. Dichos coeficientes pueden ser modificados con el fin de conseguir el realce de la imagen [14]. En este trabajo se modificaron los coeficientes *wavelet* en función del nivel de descomposición al que pertenecían de acuerdo con la siguiente función [14]:

$$C_m^N(x, y) = C_o^N(x, y) \cdot [G_{\text{óptima}}]^{1/2 \cdot N}, \quad (1)$$

donde C_o^N representa el coeficiente original, C_m^N es el coeficiente modificado, N es el nivel de descomposición y (x,y) representa la posición de la función *wavelet*. $G_{\text{óptima}}$ es una ganancia que se obtendrá por regresión a partir de datos experimentales. Esta modificación se aplicó a los coeficientes de aproximación y a los de detalle.

3.4. Reconstrucción *wavelet*

Una vez modificados los coeficientes *wavelet*, se lleva a cabo la reconstrucción de la componente verde de la imagen realzada, G_e , a partir de los coeficientes C_m^N . En la Fig. 1 se muestra un ejemplo de imagen realzada.

3.5. Ajuste de la ganancia óptima

En la etapa de modificación de los componentes *wavelet* es necesario determinar la ganancia que se aplicará en la ecuación (1). El objetivo es conseguir que G_e se parezca




Figura 1. (a) Retinografía original. (b) Máscara que delimita el área de interés de la imagen. (c) Componente verde de la imagen original, G_o . (d) Componente verde de la imagen realzada, G_e .

lo más posible a la componente verde de la imagen de referencia, G_{ref} . Como medida de similitud se empleó la distancia euclídea entre la intensidad media de G_e y la intensidad media de G_{ref} , teniendo en cuenta únicamente la intensidad de los píxeles pertenecientes al FOV:

$$d = \sqrt{(\mu[G_{ref_FOV}] - \mu[G_{e_FOV}])^2} \quad (2)$$

La ganancia más adecuada (i.e., la que permite obtener una menor d) varía en función de las características de cada imagen. $G_{\text{óptima}}$ se determinó de forma experimental. Para ello se aplicaron diferentes ganancias sobre las 98 imágenes de entrenamiento y se determinó d en cada caso. De estos datos se obtuvo la gráfica mostrada en la Fig. 2, donde se relaciona la intensidad media de G_o para cada imagen de entrenamiento teniendo en cuenta únicamente los píxeles pertenecientes a la FOV ($\mu[G_{o_FOV}]$) con la ganancia que proporciona la menor d en ese caso.

Para poder extender estos resultados al conjunto de imágenes de test, fue necesario obtener una expresión general que relacionase $\mu[G_{o_FOV}]$ con $G_{\text{óptima}}$. Para ello se empleó un modelo de regresión que ajustase la curva de la Fig. 2. Se empleó un modelo polinómico de grado 4, puesto que con él se obtuvo un ajuste óptimo en base a diversas medidas de la bondad de ajuste.

4. Resultados

4.1. Configuración del método *wavelet*

Para la elección de la familia *wavelet* más adecuada para el análisis de las retinografías de nuestra base de datos, se obtuvo la curva que relacionaba $\mu[G_{o_FOV}]$ con $G_{\text{óptima}}$ sobre el conjunto de entrenamiento para diferentes familias *wavelet*. Se analizaron las familias Haar, Daubechies, Symlet, Coiflet, Meyer y biortogonal, con diferentes órdenes. La *wavelet* elegida fue la bior 1.1, puesto que con ella se obtuvieron buenos resultados en cuanto a la normalización de las imágenes y su tiempo de ejecución fue el menor de todas las familias analizadas. El nivel de descomposición empleado fue 9, máximo nivel de descomposición posible para el tamaño de las imágenes de entrada y la *wavelet* elegida.

4.2. Ajuste del modelo de regresión

La aplicación del método *wavelet* propuesto requiere determinar $G_{\text{óptima}}$ para cada imagen. Se partió de la curva que relaciona $\mu[G_{o_FOV}]$ con $G_{\text{óptima}}$ para el conjunto de




Figura 2. $G_{\text{óptima}}$ en función de $\mu[G_{o_FOV}]$ para el conjunto de entrenamiento (curva azul) y para el conjunto de test (curva amarilla) empleando la *wavelet* bior 1.1.

entrenamiento (Fig. 2) y la *wavelet* bior 1.1 y se trató de ajustar dicha curva en base a distintos modelos. Concretamente se estudiaron: funciones polinómicas de grados 1 a 9, función exponencial, función de potencia y regresión logística. El modelo más adecuado se eligió en base a las siguientes medidas de la bondad de ajuste: suma de errores cuadráticos (SSE, *Sum of Squares due to Errors*), error cuadrático medio (RMSE, *Root Mean Squared Error*) y coeficiente de determinación (R^2). En base a estos estadísticos se eligió el ajuste mediante un polinomio de grado 4 (SSE=0.182, RMSE=0.042, $R^2=0.991$). Así, la ecuación (1) se transforma en:

$$C_m^N = C_o^N \cdot (6.83 - 55.65 \cdot \mu[G_o] + 207.30 \cdot \mu[G_o]^2 - 353.70 \cdot \mu[G_o]^3 + 223.30 \cdot \mu[G_o]^4)^{1/2 \cdot N} \quad (3)$$

4.3. Resultados finales

El algoritmo completo se evaluó sobre un nuevo conjunto de 65 imágenes de nuestra base de datos (conjunto de test). Los resultados se obtuvieron en base a un índice de luminosidad (σ_μ) y dos índices de contraste (μ_σ y μ_c). Para calcularlos, cada imagen de test se dividió en $N=24$ bloques de 150×150 píxeles. Para cada bloque se calculó su intensidad media, μ_i , la desviación típica de los niveles de intensidad, σ_i , y los valores de los percentiles correspondientes al 10% y a 90% de la distribución de intensidad, r_{90} y r_{10} , respectivamente [1]. A partir de estos parámetros, se calcularon σ_μ , μ_σ y μ_c [1]:

$$\sigma_\mu = \sqrt{\frac{1}{N} \cdot \sum_i (\mu_i - \mu_\mu)^2} \quad (4)$$

$$\mu_\sigma = \frac{1}{N} \cdot \sum_i \sigma_i \quad (5)$$

$$\mu_c = \frac{1}{N} \cdot \sum_i c_i \quad (6)$$

donde $c_i = r_{90} - r_{10}$.

En la Tabla 1 se muestran los valores promedio obtenidos con estos índices para G_e en el conjunto de test y el valor obtenido para G_{ref} . También se muestra el porcentaje de diferencia entre estos índices.

5. Discusión y conclusiones

En este trabajo se propone un método automático para el realce de retinografías basado en la transformada *wavelet*, donde los coeficientes resultantes de la etapa de descomposición *wavelet* se modifican en función de las características de cada imagen.

Sobre el conjunto de test (65 imágenes) se calcularon un índice de luminosidad y dos índices de contraste. Éstos índices permitieron comparar los resultados de la normalización con la imagen de referencia. Los resultados mostrados en la Tabla 1 indican que las diferencias entre las imágenes realzadas y la imagen de referencia no son muy elevadas, obteniéndose un máximo de un 24.4% de diferencia cuando se emplea el índice σ_μ .

Asimismo, se ha comparado el valor de estos índices para las imágenes originales (G_o) y las imágenes normalizadas

Índice	$\sigma_\mu[G_e]$	$\sigma_\mu[G_{ref}]$	Porcentaje diferencia	$\mu_\sigma[G_e]$	$\mu_\sigma[G_{ref}]$	Porcentaje diferencia	$\mu_c[G_e]$	$\mu_c[G_{ref}]$	Porcentaje diferencia
Valor	0.127	0.320	24.4%	0.074	0.1579	13.0 %	0.289	0.0832	11.6%

Tabla 1. Índices de luminosidad y contraste promedio para las imágenes de test y la imagen de referencia.

(G_e). Se observó que el índice σ_μ obtenido tras la normalización era menor que antes de la normalización en 35 de las 65 imágenes. Esto indica que el método propuesto permite obtener una iluminación más uniforme en más de la mitad de las imágenes. En cuanto a los índices de contraste, se ha conseguido un aumento de μ_σ en 28 imágenes y de μ_c en 31 imágenes, lo que indica que en estos casos el contraste de la imagen mejora tras el proceso de normalización.

Los índices utilizados para cuantificar los resultados han sido utilizados previamente por otros autores sobre un conjunto de 33 imágenes [1]. En este estudio se consiguió un valor promedio de $\sigma_\mu=0.054$, $\mu_\sigma=0.061$ y $\mu_c=0.143$. Aunque las comparaciones entre ambos métodos no son totalmente objetivas, puesto que la base de datos es diferente, se pueden señalar algunas diferencias en base a estos resultados. En primer lugar, el método propuesto en este estudio es, en general, más eficaz a la hora de aumentar el contraste en las imágenes normalizadas, puesto que se obtienen valores mayores de μ_σ y μ_c . En segundo lugar, la iluminación de las imágenes normalizadas no es tan uniforme como en [1]. Esto es debido a que en [1] la normalización se aplicó sobre subregiones de la imagen, adaptándose mejor a las variaciones locales de iluminación. El método propuesto se aplica de la misma forma sobre toda la imagen, independientemente de si existen zonas con diferencias de iluminación importantes en la misma. En futuros estudios se tratará de mejorar el método propuesto para tener en cuenta las características de iluminación locales. Asimismo, se tratará de englobar dentro de un algoritmo más general de procesamiento de retinografías para ayuda al diagnóstico de la RD, en el que también se emplea la componente G_o para hacer una primera segmentación de las lesiones presentes en una retinografía [5, 6].

Como conclusión, los resultados de este trabajo indican que los métodos automáticos de normalización de retinografías son una etapa fundamental en su procesamiento automático y análisis. En este sentido, el método propuesto puede ser útil para ayudar a mejorar el diagnóstico de diversas patologías.

Agradecimientos

Este trabajo ha sido financiado parcialmente por los proyectos de investigación: PI10/02664 del Ministerio de Ciencia e Innovación y el Instituto de Salud Carlos III, TEC2011-22987 del Ministerio de Economía y Competitividad y FEDER; “Proyecto Cero 2011 on Ageing” de la Fundación General CSIC, Obra Social La Caixa y CSIC; y VA111A11-2 de la Consejería de Educación de la Junta de Castilla y León.

Referencias

[1] Foracchia M, Grisan E, Ruggeri A. Luminosity and contrast normalization in retinal images. *Medical Image Analysis*, vol 9, no 3, 2005, pp 179-90.

[2] Ege BM, Hejlesen OK, Larsen OV, Møller K, Jennings B, Kerr D, Cavan DA. Screening for diabetic retinopathy using computer based image analysis and statistical classification. *Computer Methods and Programs in Biomedicine*, vol 62, no 3, 2000, pp 165-75.

[3] Henegan C, Flynn J, O’Keefe M, Cahill M. Characterization of changes in blood vessel width and tortuosity in retinopathy of prematurity using image analysis. *Medical Image Analysis*, vol 6, no 4, 2002, pp 407-29.

[4] Hubbard L, Brothers R, King W, Clegg L, Klein R, Cooper L, Sharrett A, Davis M, Cai J. Methods for evaluation of retinal microvascular abnormalities associated with hypertension/sclerosis in the atherosclerosis risk in communities study. *Ophthalmology*, vol 106, no 12, 1999, pp 2269-80.

[5] García M, Sánchez CI, Poza J, López MI, Hornero R. Detection of hard exudates in retinal images using a radial basis function classifier. *Annals of Biomedical Engineering*, vol 37, no 7, 2009, pp 1448-63.

[6] García M, López MI, Álvarez D, Hornero R. Assessment of four neural network based classifiers to automatically detect red lesions in retinal images. *Medical Engineering and Physics*, vol 32, no 10, 2010, pp 1085-93.

[7] Teng T, Lefley M, Claremont D. Progress towards automated diabetic ocular screening: a review of image analysis and intelligent systems for diabetic retinopathy. *Medical and Biological Engineering and Computing*, vol 40, no 1, 2002, pp 2-13.

[8] Øien GE, Osnes P. Diabetic retinopathy: Automatic detection of early symptoms from retinal images. *Proceedings of the Norwegian Signal Processing Symposium*, 1995, pp 135-40.

[9] Wang H, Hsu W, Goh KG, Lee ML. An effective approach to detect lesions in color retinal images. *Proceedings of the 19th IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2000, pp 181-6.

[10] Agurto C, Murray V, Barriga E, Murillo S, Pattichis M, Davis H, Russell S, Abramoff M, Soliz P. Multiscale AM-FM methods for diabetic retinopathy lesion detection. *IEEE Transactions on Medical Imaging*, vol 29, no 2, 2010, pp 502-12.

[11] Sánchez CI, Hornero R, López MI, Aboy M, Poza J, Abásolo D. A novel automatic image processing algorithm for detection of hard exudates based on retinal image analysis. *Medical Engineering and Physics*, vol 30, no 3, 2008, pp. 350-7.

[12] Nirmala SR, Dandapat S, Bora PK. Wavelet weighted blood vessel distortion measure for retinal images. *Biomedical Signal Processing and Control*, vol 5, no 4, 2010, pp. 282-91.

[13] Gonzalez RC, Woods RE. Digital image processing. Pearson Education International, 2008.

[14] Vidaurrezaga M, González E, Domínguez W. Mejoramiento de imágenes de resonancia magnética basado en la transformada wavelet. *Memorias II Congreso Latinoamericano de Ingeniería Biomédica*, 2001.