

Modelo de Mezcla de Gaussianas Generalizadas para Segmentación de Melanomas

A. Sarmiento¹, I. Fondón¹, M. Velasco¹, A. Qaisar^{2,3}, P. Aguilera¹

¹ Departamento de Teoría de la Señal y Comunicaciones, Universidad de Sevilla, Sevilla, España,
{sarmiento, ifrenf, mvelasco, paguilera}@us.es

² College of Computer and Information Sciences, Al-Imam Muhammad ibn Saud Islamic University, Arabia Saudi,
drqaisar@ntu.edu.pk

Resumen

El diagnóstico de melanoma depende en gran parte de la experiencia subjetiva del dermatólogo. Por este motivo, los sistemas de Diagnóstico Asistido por Ordenador (CAD) pueden ayudar a la labor del médico, proporcionando una segunda opinión objetiva. Un paso fundamental en la automatización del proceso es la segmentación del área lesionada a partir de imágenes de dermatoscopia. De entre los métodos existentes, uno de los más prometedores es el denominado algoritmo de segmentación de lesión por diferencia de textura (TDLS) basado en modelos de textura escasos. Este método consiste en la obtención de las texturas presentes en la imagen, el cálculo de una medida de diferencia de una textura con el resto y la clasificación de regiones de la imagen como piel normal o piel lesionada basándose en dicha medida. En este trabajo, se propone el uso de un modelo de mezcla de Gaussianas Generalizadas multidimensionales para el aprendizaje de las texturas presentes en la imagen. Esta familia de funciones de distribución son capaces de modelar adecuadamente un amplio rango de datos debido a su versatilidad. Para la estimación de los parámetros de la mezcla se utiliza el algoritmo EM (Expectation-Maximization). El método se ha probado en 50 imágenes, alcanzando una especificidad del 93,8%, y una precisión del 89,8%.

1. Motivación

Los melanomas malignos conforman el tercer tipo de cáncer de piel más frecuente, y se está convirtiendo en uno de los más letales, especialmente en países con población caucásica. Las cifras de incidencias estimadas por la Sociedad Americana Contra el Cáncer para el año 2014 solo en EEUU se elevan a 76100 nuevos diagnósticos y 9710 muertes por melanoma [1]. Sin embargo, la detección precoz de esta lesión de piel aumenta las probabilidades de curación, por lo que cobra gran importancia una alternativa de bajo coste que evite la evaluación de cada paciente por parte de los dermatólogos.

Las imágenes de dermatoscopia proporcionan a los dermatólogos una técnica no invasiva, en vivo, que puede mejorar la precisión del diagnóstico hasta en un 50%, en comparación con la simple inspección visual [2], siempre que el dermatólogo tenga suficiente experiencia.

En la literatura, la mayoría de los algoritmos de segmentación solo utilizan características de color. Sin embargo, estas características pueden no ser suficientes si

los bordes no están totalmente definidos por las variaciones de color, resultando de gran utilidad la información de textura debido a la diferencia de textura entre la piel sana y la zona de la lesión.

En este trabajo, proponemos una extensión del algoritmo de segmentación de lesión por diferencia de textura (TDLS) propuesto en [3], introduciendo un modelo más complejo para el conjunto de distribuciones de textura. Para ello, el modelo de mezcla Gaussiano (GMM) original es reemplazado por un modelo de mezcla de Gaussianas generalizadas (GGMM), que presenta una mayor flexibilidad a la hora de modelar los datos que los GMM, permitiendo una segmentación más eficiente. En el campo de la discriminación y recuperación de texturas, este tipo de funciones de densidad generalizadas se ha aplicado con éxito para modelar los histogramas de sub-banda de detalle con Wavelet [4-5] y para la segmentación de fondo en vídeo [6].

Este artículo está organizado de la siguiente forma. La Sección 2 describe la etapa de pre-procesado que corrige la iluminación de la fotografía original. La Sección 3 presenta el modelo de mezcla de Gaussianas generalizadas. Tras esto, la Sección 4 describe el proceso de segmentación. En la Sección 5 se presentan los resultados experimentales, para terminar con las conclusiones en la Sección 6.

2. Preprocesado

Las variaciones de la iluminación pueden dar lugar a zonas de la imagen son sombras o brillos que podrían identificarse incorrectamente como parte de la lesión en el algoritmo de segmentación. Con objeto de corregir dichas variaciones, hemos procesado las imágenes mediante un filtro de transformación homomórfica mejorada (HTF) en el espacio de color orientado a la percepción CIE L^*a^*b [7]. En la literatura, HTF es una técnica para la mejora no-lineal de imágenes y la corrección que usualmente se utiliza tanto en RGB como en imágenes en escala de grises. Sin embargo, en este trabajo hemos elegido un espacio de color relacionado con la percepción humana, consiguiendo una mejor correlación con el diagnóstico de los clínicos. El método se basa en la representación logarítmica del plano L^* como la suma de una componente de iluminación y una componente de

reflectancia [8]. Tras aplicar un filtro Butterworth paso alto a la transformada de Fourier de la imagen en escala logarítmica, las altas frecuencias (los detalles) se amplifican.

El filtro HTF representado por $H(u, v)$ se calcula como:

$$H(u, v) = (H_H - H_L) \times \left(1 - \exp \left(-Bw \left(\frac{D_o}{D(u, v)} \right) \right) \right) + H_L \quad (1)$$

donde Bw es el filtro Butterworth, $D(u, v)$ es la distancia entre el punto (u, v) y el origen de frecuencias.

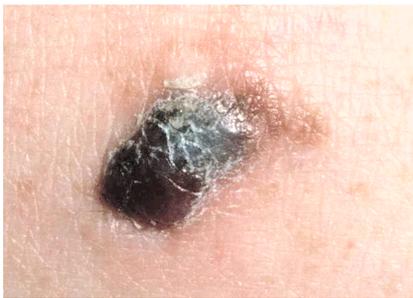
D_o es la transición normalizada, H_L y H_H son los parámetros elegidos de baja y alta frecuencia, respectivamente. La componente de Luminancia corregida se obtiene finalmente aplicando la transformada inversa de Fourier, y tomando la potencia en base 10.

Tras corregir la iluminación, se mejora el contraste mediante una función no-lineal con forma de sigmoide (NSF) en el plano L^* . Finalmente, se aplica un filtro 2D Gaussiano en el plano C^* para suavizar la imagen. Una vez corregida la imagen, se convierte al espacio de color XYZ, ya que según se desprende en [9], es el espacio de color más eficiente para la segmentación de zonas de piel de caras humanas, y por tanto, de otras zonas de piel.

En la Figura 1 (a) y (b) se muestra, respectivamente, las versiones original y corregida de la lesión de piel.



(a)



(b)

Figura 1. Ejemplo del paso de preprocesado sobre la imagen del melanoma. (a) Original. (b) Tras aplicar la mejora de contraste.

3. Modelo de textura escasos mediante mezclas de Gaussianas generalizadas

Para la extracción de los vectores de textura, se emplea un modelo estadístico de textura en el que se extrae de cada píxel de la imagen un vector que representa la textura de vecindad centrada en dicho píxel [10]. Se ha elegido una vecindad cuadrada 5×5 , obteniéndose por lo tanto para cada píxel un vector de textura $h(x)$ formado por 75 elementos. A continuación se realiza un Análisis de Componentes Principales (PCA) con el objeto de reducir la dimensión del vector de textura.

Esta caracterización mediante modelos dispersos hace posible encontrar un subconjunto de vectores del grupo de vectores de textura locales, que representa de forma más fidedigna la información de textura de la imagen, preservando sus características locales y globales. El método asume que cada vector de textura pertenece a una única distribución de textura representativa, elegida para maximizar la verosimilitud logarítmica del modelo de mezcla. La contribución principal de este trabajo es el uso de distribuciones Gaussianas generalizadas para modelar la textura, en lugar de una simple distribución Gaussiana. Con el objetivo de evitar problemas de convergencia, las distribuciones Gaussianas generalizadas se inicializan con la técnica de *clustering K-means*, donde K se fija al valor $K = 10$. Es decir, en la imagen no aparecerán más de 10 texturas distintas.

Sea $\chi = \{\vec{x}_i\}$ un conjunto de datos sin clasificar, donde cada vector \vec{x}_i contiene un serie características que describen un objeto. La distribución marginal de la variable aleatoria \vec{x}_i viene dada por

$$p(\vec{x}_i | \Theta) = \sum_{j=1}^K \pi_j p(\vec{x}_i | \Theta_j), \quad (2)$$

donde Θ representa los parámetros del modelo, así como π_j son las probabilidades a priori que satisfacen

$$\pi_j \geq 0, \quad \text{y} \quad \sum_{j=1}^K \pi_j = 1. \quad (3)$$

Las distribuciones $p(\vec{x}_i | \Theta_j)$ son Gaussianas generalizadas de dimensión D . Si suponemos que las características a modelar son independientes, las densidades Gaussianas generalizadas pueden definirse como

$$p(\vec{x}_i | \vec{\mu}, \vec{\sigma}, \vec{\lambda}) = \prod_{d=1}^D p(x_{id} | \mu_d, \sigma_d, \lambda_d) \\ = \prod_{d=1}^D \frac{\lambda_d}{2\sigma_d \Gamma(1/\lambda_d)} \sqrt{\frac{\Gamma(3/\lambda_d)}{\Gamma(1/\lambda_d)}} e^{\left(-A(\lambda_d) \left| \frac{x_{id} - \mu_d}{\sigma_d} \right|^{\lambda_d} \right)}. \quad (4)$$

El término $A(\lambda_d)$ se define como

$$A(\lambda_d) = \left(\frac{\Gamma(3/\lambda_d)}{\Gamma(1/\lambda_d)} \right)^{\lambda_d/2}, \quad (5)$$

donde $\Gamma(\cdot)$ es la función Gamma. Los vectores $\vec{\mu} = [\mu_1 \dots \mu_d]$ y $\vec{\sigma} = [\sigma_1 \dots \sigma_d]$ contienen la media y la desviación estándar, respectivamente, de cada función densidad de probabilidad en la d -ésima dimensión. Finalmente, el vector $\vec{\lambda} = [\lambda_1 \dots \lambda_d]$ contiene los conocidos como como parámetros de forma, que proporcionan una gran versatilidad a esta familia de distribuciones dado que controlan la cola de la distribución.

En este trabajo usamos el algoritmo EM [11] para estimar el conjunto de parámetros Θ . Los parámetros utilizados para la inicialización del algoritmo son extraídos de los *clusters* resultado del algoritmo *k-means*. Las reglas de actualización se pueden obtener de forma analítica [12], excepto para el parámetro de forma λ_d , para el cual hemos optado por explotar su relación con la kurtosis [13].

4. Segmentación de lesiones de piel

Al finalizar el aprendizaje del modelo de mezcla, se obtienen K distribuciones Gaussianas Generalizadas, con sus parámetros definidos, representando las distintas texturas presentes en la imagen. Cada vector textura es asignado entonces a aquella distribución que maximiza la probabilidad a posteriori, de forma que es posible asociar cada píxel de la imagen a una distribución dando lugar a un mapa de distribuciones de textura.

Tras ello, se calcula una métrica de diferencia de texturas para reducir a dos (piel sana y lesionada) el número de distribuciones de textura aprendidas [3]. Esta medida está basada en la divergencia de Kullback-Leibler (KL). En el caso de piel sana este valor será bajo, en contraste con la zonas de lesión donde el valor de diferencia será elevado. Sin embargo, a día de hoy no existe una fórmula cerrada para calcular la divergencia KL entre distribuciones Gaussianas Generalizadas con medias distintas de cero. Por ello, se ha optado por generar una muestra suficientemente grande de cada una de las distribuciones, y calcular la distancia entre ellas mediante el uso de la familia alpha-beta (AB) divergencia [14], particularizando para $\alpha=0$ y $\beta=1$, en el cual la AB-divergencia converge a la KL.

Una vez se han obtenido las diferencias de texturas, se realiza una sobre-segmentación seguido de un algoritmo estadístico de fusión de regiones (SRM). De esta forma se consigue una nueva medida de diferencia de textura, en este caso regional, para incrementar la robustez del algoritmo de segmentación frente al ruido. Finalmente, se realiza una umbralización básica sobre la imagen de diferencias texturales regionales para determinar la clasificación de los píxeles y en consecuencia la segmentación. En el algoritmo propuesto, hemos usado una versión mejorada del método de Otsu [15], debido a

que la técnica tradicional utilizada en [3] daba muchos valores erróneos, resultando en imágenes sub-segmentadas.

5. Resultados experimentales

El algoritmo ha sido implementado en MATLAB, y se ha evaluado su comportamiento sobre un conjunto de 50 imágenes dermatoscópicas de la librería DermQuest [16]. Los resultados obtenidos han sido comparados con imágenes segmentadas manualmente por expertos (verdad de referencia). En la Figura 2 se muestra una comparativa de la verdad de referencia y las segmentaciones obtenidas mediante el algoritmo original TDLS (en rojo) y el resultado obtenido con la mejora propuesta (en azul) en varias de las imágenes.

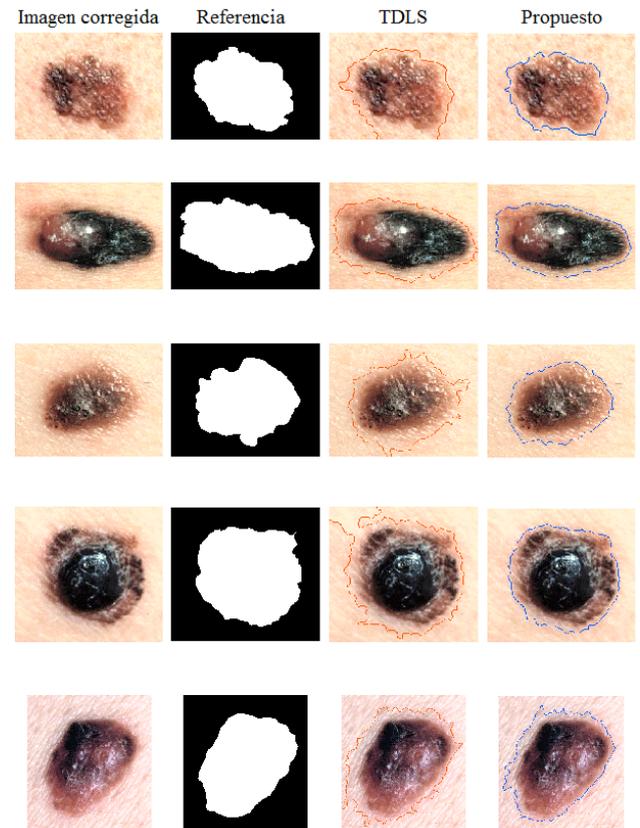


Figura 2. Segmentación de lesiones de piel. En la primera columna, se muestra la imagen tras corregir su iluminación. La segunda columna muestra la segmentación de referencia. En la tercera columna, marcamos en rojo los resultados del algoritmo TDLS, mientras que en la cuarta columna marcamos en azul los resultados del algoritmo propuesto.

Para evaluar de forma objetiva el rendimiento de la técnica propuesta, hemos promediado los valores de sensibilidad, especificidad y precisión que calculamos mediante las siguientes expresiones:

$$\text{Sensibilidad (\%)} = \left(\frac{TP}{TP + FN} \right) \times 100, \quad (6)$$

$$\text{Especificidad (\%)} = \left(\frac{TN}{FP + TN} \right) \times 100, \quad (7)$$

$$\text{Precisión (\%)} = \left(\frac{TP + TN}{TP + FN + FP + TN} \right) \times 100, \quad (8)$$

donde TP, TN, FP y FN representan los Verdaderos Positivos, Verdaderos Negativos, Falsos Positivos y Falsos Negativos, respectivamente. En la Tabla 1 se muestran los resultados del método de segmentación propuesto, cuando se compara con el método TDLS.

Resultados (%)	Sensibilidad	Especificidad	Precisión
TDLS	90.30	88.64	89.26
Propuesto	82.20	93.80	89.80

Tabla 1. Resultados de la precisión al segmentar lesiones por melanoma.

De los resultados obtenidos puede observarse que el método propuesto obtiene una mejora significativa en las medidas de especificidad y precisión, y que además el contorno resultante es muy cercano a la referencia.

6. Conclusiones

En este artículo hemos desarrollado un algoritmo para la segmentación automática de lesiones de piel basado en la información de color y textura. La principal aportación consiste en el uso de un modelo de mezcla de Gaussianas Generalizadas para favorecer el aprendizaje de las texturas representativas a partir de su representación escasa. El método propuesto comienza con una etapa de pre-procesamiento para la corrección de las variaciones de iluminación y mejora del contraste. A continuación, para cada píxel, se extraen las características locales de la textura y se construye un modelo de textura escaso en base a un modelo de mezcla de Gaussianas Generalizadas mediante el algoritmo EM. A continuación, el algoritmo calcula la diferencia local entre la textura representativa obtenida y todas las restantes mediante la divergencia de Kullback-Leibler. Esta diferencia de textura local es empleada para encontrar una imagen de diferencia de textura regional usando un algoritmo de sobre-segmentación. Finalmente, se procede a un proceso de umbralización mediante una técnica de Otsu mejorada. El algoritmo ha sido testeado experimentalmente con 50 imágenes, demostrando sus buenas prestaciones.

Agradecimientos

Este trabajo ha sido financiado parcialmente por los proyectos P11-TIC-7727 de la Junta de Andalucía (España), y el proyecto PM-IPFP/HRD/HEC/2011/3402 (Comisión de Educación Superior, Pakistán).

Referencias

- [1] Página web de la Society American Cancer. <http://www.cancer.org/cancer/skincancer-melanoma/index> (Consultada: Agosto 2014).
- [2] Kittler H., "Dermoscopy of pigmented skin lesions. *Gital Dermatol Venereol*", 2004, vol 139, nº 6, pp. 541-546.
- [3] Glaister J., Wong A., Clausi DA. "Segmentation of skin lesions from digital images using joint statistical texture distinctiveness", *IEEE Trans. Biomed. Eng.*, 2014 Apr, vol. 61, nº 4, pp. 1220-1230.
- [4] Do M.N., Vetterli M., "Wavelet-based texture retrieval using generalized Gaussian density and Kullback-Leibler distance", *IEEE Trans. Image Process.*, 2002, vol. 11, nº 2, pp. 146-158.
- [5] Choy S.K., Tong C.S., "Statistical wavelet subband characterization based on generalized gamma density and its application in texture retrieval", *IEEE Trans. Image Process.*, 2010, vol. 19, nº 2, pp. 281-289.
- [6] M. Allili, "Wavelet modeling using finite mixtures of generalized Gaussian distributions: application to texture discrimination and retrieval", *IEEE Trans. Image Process.*, 2012, vol. 21, nº 4, pp. 1452-1464.
- [7] Qaisar A., Fondón I., Celebi M. Emre, Ahmad Waqar and Qaisar M. "A perceptually oriented method for contrast enhancement and segmentation of dermoscopic images". *Skin Research and Technology*, 2012, pp. 1-8.
- [8] Shahamat H., Pouyan Ali A., "Face recognition under large illumination variations using homomorphic filtering in spatial domain", *Journal of Visual Communication and Image Representation*, vol.24, nº5, 2014, pp. 970-977.
- [9] Terrillon, J.-C., Shirazi, M.N., Fukamachi, H., Akamatsu, S., "Comparative performance of different skin chrominance models and chrominance spaces for the automatic detection of human faces in color images", *Actas del Fourth IEEE Int. Conf. On Automatic Face and Gesture Recognition*, 2000, pp. 54-61.
- [10] Scharfenberger, C., Wong, A., Fergani, K., Zelek, J.S., Clausi, D.A., "Statistical Textural Distinctiveness for Salient Region Detection in Natural Images", *Actas del IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2013, pp. 979-986.
- [11] Dempster P., Laird N.M., Rubin D.B., "Maximum likelihood from incomplete data via EM algorithm", *J.R. Stat. Soc.*, 1977, vol. 39, nº 1, pp. 1-38.
- [12] Allili, M.S.; Bouguila, N.; Ziou, D., "Finite Generalized Gaussian Mixture Modeling and Applications to Image and Video Foreground Segmentation," *Actas de Fourth Canadian Conference on Computer and Robot Vision (CRV '07)*, 2007, pp.183-190.
- [13] Box G., Tiao G., "Bayesian Inference Statistical Analysis", John Wiley and Sons, 1973.
- [14] Cichocki A., Cruces S., Amari S.-I., "Generalized Alpha-Beta Divergences and Their Application to Robust Nonnegative Matrix Factorization", *Entropy*, vol. 13, 2011, pp. 134-170
- [15] Fondón I., Serrano, C., Acha B.: Color-Texture Image Segmentation Based on Multistep Region Growing. *Optical engineering*, vol. 45, nº 5, 2006, pp. 057002-1-057002-9.
- [16] Página web Dermaquest. <https://www.dermquest.com/> (Consultada: Mayo 2014)