

Algoritmo de segmentación de lesiones pigmentadas de la piel basado en minimización de energías

M. García-Morales¹, B. Acha¹, C. Serrano¹

¹ Departamento de Teoría de la Señal y Comunicaciones, Escuela Técnica Superior de Ingeniería, Universidad de Sevilla, Sevilla, España, {mergarciam@gmail.com, bacha@us.es, cserrano@us.es}

Resumen

El objetivo de este trabajo ha sido el desarrollo de un nuevo algoritmo de segmentación de lesiones pigmentadas de la piel basado en minimización de energía mediante relajación convexa [1], utilizando imágenes dermatoscópicas. Se han propuesto distintas funciones de minimización. Los resultados obtenidos se han evaluado con medidas de evaluación de región, de contorno y de tiempo, obteniéndose una precisión de 0.9172

1. Introducción

El cáncer de piel, a día de hoy, es uno de los cánceres con mayor incidencia. Sin embargo, no es el de mayores tasas de mortalidad gracias a su detección precoz.

Los expertos clínicos hacen uso del dermatoscopio cuando deben inspeccionar un lunar sospechoso o una lesión pigmentada. El dermatoscopio es un instrumento óptico que está formado por una lente óptica, que, además de, introducir un aumento que puede variar entre 10 y 40, permite realizar fotografías, dando la opción al experto clínico de guardar un registro de la evolución de los lunares del paciente.

Actualmente hay una gran cantidad de trabajos que proponen abordar el problema de la segmentación automática de lesiones pigmentadas utilizando distintos tipos de técnicas de segmentación, como, por ejemplo, basándose en umbralizaciones de color o texturas [2-4], en vecindarios adaptativos [5] o en problemas de optimización [6-7]. Sin embargo, hasta la fecha, no se ha propuesto ningún método de minimización de energías mediante relajación convexa, basado en [1], orientándolo a imágenes dermatoscópicas, aunque sí hay otras propuestas para imágenes procedentes de RM y TAC [8-9]

2. Metodología

El trabajo se ha dividido en tres fases, tal y como se puede apreciar en la Figura 2-1. En la primera fase, preprocesamiento, se ha realizado una pre-segmentación. En la segunda fase, segmentación, se ha obtenido la función de costes de cada píxel y se ha aplicado el algoritmo de segmentación por minimización de energía. Se han propuesto cuatro versiones diferentes para la estimación de la función de costes. Por último, en la tercera fase, postprocesamiento, se han aplicado Matemáticas Morfológicas para adecuar los resultados obtenidos tras la segmentación.

2.1. Preprocesamiento

En el procesamiento, para todas las imágenes se ha aplicado los siguientes pasos:

1. Filtrado gaussiano de tamaño 20x20.
2. Umbralización de Otsu.
3. Operación morfológica de dilatación con un elemento disco y de tamaño 5.

Como se verá en la Sección 2.2 la pre-segmentación obtenida con el algoritmo de Otsu se empleará para la estimación de los parámetros necesarios para el cálculo de las funciones de minimización al aplicar el algoritmo de relajación convexa.

2.2. Segmentación

En esta fase, se ha realizado la segmentación basada en el algoritmo de minimización de energía mediante relajación convexa. La función a minimizar en este algoritmo se define del siguiente modo [1]:

$$\min_{u_i} \sum_{i=1}^n \int_{\Omega} u_i(x) \rho_i(x) dx + \alpha \sum_{i=1}^n \int_{\Omega} |\nabla u_i| dx$$




Figura 2-1. Esquema de los algoritmos

$$\text{Sujeta a: } \sum_{i=1}^n u_i = 1; u_i \geq 0, i = 1, \dots, n$$

En esta ecuación, x representa la posición del píxel, $u_i(x) \in [0,1]$ representa las etiquetas, que en lugar de utilizar valores binarios (como ocurre en una optimización no convexa), pueden tomar valores reales entre 0 y 1. $\rho_i(x)$ es una función que toma valores bajos dentro de la región i y valores altos fuera de ella.

En este trabajo las funciones $\rho_i(x)$ se han calculado de cuatro maneras diferentes:

Algoritmo 1: Se emplean dos etiquetas en la minimización.

$\rho_0(x) = \|\mathbf{p}(x) - \boldsymbol{\mu}_0\|$ y $\rho_1(x) = \|\mathbf{p}(x) - \boldsymbol{\mu}_1\|$, en donde $\mathbf{p}(x)$ representa el color del píxel y $\boldsymbol{\mu}_0$ y $\boldsymbol{\mu}_1$ los colores medios fuera y dentro de la lesión, respectivamente. Estos dos parámetros se estiman como los valores medios fuera y dentro de la región segmentada por Otsu.

Algoritmo 2: Se emplean cuatro etiquetas para la minimización, una se corresponde con la piel sana y tres con la lesión. $\rho_i(x)$ se calcula como $\rho_i(x) = \|\mathbf{p}(x) - \boldsymbol{\mu}_i\|$, donde $\boldsymbol{\mu}_i$ se corresponde con el color medio de los píxeles pertenecientes a esa etiqueta. $\boldsymbol{\mu}_0$ se estima como en el algoritmo 1. Los otros tres parámetros se estiman como los centroides resultantes de aplicar el algoritmo de *k-means* a los colores de los píxeles pertenecientes a la región segmentada por Otsu.

Algoritmo 3: Se emplean 4 etiquetas, una correspondiente a la piel sana y tres a la lesión. $\rho_i(x)$ se calcula como la distancia χ^2 entre el histograma de la región correspondiente a esa etiqueta y el histograma local alrededor del píxel. El histograma correspondiente a la piel sana se calcula como un histograma local aleatoriamente elegido en la región exterior de la segmentación de Otsu. Los histogramas correspondientes a las regiones interiores a la lesión se calculan como histogramas locales aleatoriamente elegidos en la región segmentada por Otsu. Los histogramas se estiman empleando el algoritmo de *k-means* y 7 centroides, es decir, cada histograma tendrá 7 bins.

Algoritmo 4: Se emplean 5 etiquetas, dos correspondientes a la piel sana y tres a la lesión. La estimación de las 5 $\rho_i(x)$ se hace de manera idéntica a la descrita en el Algoritmo 3, con la diferencia de que los histogramas se estiman con 5 bins.

2.3. Postprocesamiento

El objetivo de esta última fase es mejorar la presentación de los resultados finales. Para ello se eliminan las posibles falsas segmentaciones aparecidas en las zonas sombreadas de la imagen o con artefactos. Para finalizar, se utilizan funciones basadas en matemáticas morfológicas, como *imfill*, de forma que se rellenen los posibles huecos que puedan aparecer en las regiones segmentadas.

3. Material

Las imágenes con las que se ha trabajado proceden del *Challenge* lanzado por el *IEEE International Symposium on Biomedical Imaging (ISBI)* de 2017, “Challenge on Sking Lesion Analysis Towards Melanoma Detection”. [10].

En dicho desafío se provee a los participantes de una base de datos compuesta por 2.000 imágenes de distintos tipos de lunares. Cada una de éstas viene acompañada con una imagen de referencia, denominada *Ground Truth* o verdad de referencia, o delineación de la lesión realizada por el experto clínico de manera manual o semiautomática.

Para el desarrollo de este trabajo, se han seleccionado 30 imágenes de manera aleatoria, abarcando distintos tipos de lunares.

4. Métodos de evaluación

A la hora de valorar la calidad de cada uno de los algoritmos se han obtenido medidas relacionadas con la región segmentada y con el contorno de ésta. Por último, se ha calculado el tiempo de segmentación.

4.1. Evaluación de la región segmentada

En la evaluación de la región segmentada se han utilizado las medidas de la Sensibilidad [11-12], la Especificidad [10], la Exactitud, el índice de Jaccard [13], el coeficiente Dice [14], el PPV [11] y la Conformidad [12].

4.2. Evaluación de contorno

Para la evaluación del contorno de la región se ha medido la MDCP (*Mean Distance to the Closest Point*) [15] y la distancia Hausdorff [15]. En este caso se ha medido la distancia entre el contorno obtenido por el algoritmo y la verdad de referencia.

Debido a que las imágenes proporcionadas por el desafío tienen tamaños completamente diferentes, se han agrupado por tamaños similares. Esto se ha realizado con el fin de establecer restricciones de calidad razonables para cada tipo de dimensión de imágenes. Para el caso de la MDCP se ha establecido un 5% del tamaño promedio de las imágenes de cada grupo, medido en píxeles, es el límite para considerar una segmentación de calidad aceptable. Para la distancia Hausdorff, este límite se ha establecido en un 10%.

4.3. Evaluación de tiempo

Esta medida se toma como algo orientativo, simplemente para reflejar la diferencia del coste computacional que hay entre un algoritmo y otro. Este valor está medido en segundos.

5. Resultados

A continuación, se exponen los resultados obtenidos promediados entre las 30 imágenes con las que se ha trabajado. Para el caso de las medidas de contorno, estos

resultados están promediados entre el número de imágenes que compone cada grupo de imágenes formado.

5.1. Resultados de la evaluación de la región segmentada

En la Figura 5-1 se muestran los resultados obtenidos en la evaluación de la región segmentada para los métodos basados en colores medios y los de histogramas. Se puede percibir a primera vista que los resultados conseguidos para los métodos basados en colores medios son notablemente mejores que para los métodos que se basan en histogramas.

Dentro del método de colores, que las medidas de Sensibilidad η_{sb} , Especificidad y PPV sean mejores, en el caso de 2 etiquetas respecto al de 4 etiquetas se debe a que se están obteniendo menor cantidad de falsos positivos. En otras palabras, en el método de 4 etiquetas de color se está sobreesegmentando la lesión, levemente.

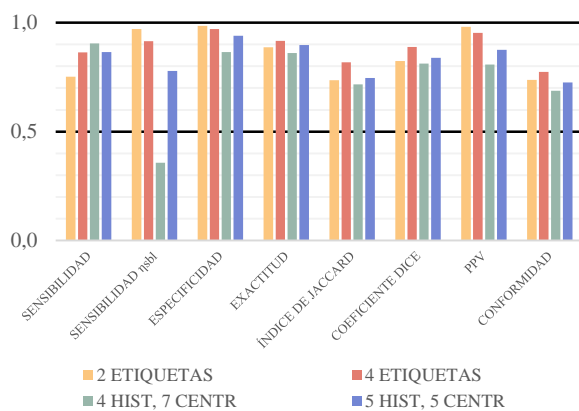


Figura 5-1. Resultados de la evaluación de la región.

5.2. Resultados de la evaluación del contorno

En las Figuras 5-2 y 5-3 se muestran los resultados obtenidos para la evaluación del contorno. En la línea de color rojo se ha señalado los límites establecidos para cada una de las medidas en función de los grupos correspondientes.

Se puede observar que, en el caso de la MDCP, Figura 5-2, salvo en el grupo 8, se cumplen dichas restricciones.




Figura 5-2. Resultados de la evaluación de contorno, MDCP.

En el caso de la distancia Hausdorff, Figura 5-3, se comprueba que las restricciones establecidas en el apartado 4.2, no se cumplen en los grupos de imágenes más grandes, especialmente para los métodos basados en histogramas,

ya que se han producido segmentaciones que difieren bastante de la verdad de referencia.

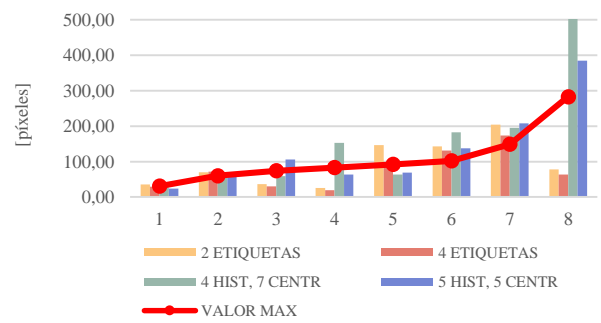


Figura 5-3. Resultados de la evaluación de contorno, distancia de Hausdorff.

5.3. Resultados de la evaluación del tiempo de ejecución

En la Figura 5-4 se observa que, el tiempo de ejecución ha ido aumentando en cuanto se ha ido incrementando la complejidad de los cálculos. Tal y como se ha comentado anteriormente, esta evaluación se ha hecho de una manera totalmente orientativa.




Figura 5-4. Resultados de la evaluación del tiempo de ejecución.

5.4. Resultados visuales

En la Figura 5-5 se muestran 4 ejemplos de los resultados obtenidos. En la primera fila de imágenes se representan las curvas de, por un lado, la verdad de referencia, mediante el color amarillo, y, por el otro lado, las de las máscaras obtenidas mediante los métodos basados en colores medios, de 2 y 4 etiquetas, representadas mediante los colores magenta y azul respectivamente.

En la segunda fila de imágenes se representan las curvas de las máscaras obtenidas mediante los métodos basados en histogramas locales, de 4 y 5 etiquetas, representadas mediante los colores verde y violeta claro respectivamente. La verdad de referencia se vuelve a representar con el color amarillo.

6. Conclusiones

El objetivo de este trabajo ha sido comparar la segmentación obtenida mediante minimización de energía por relajación convexa empleando distintas funciones objetivo. Es fácilmente observable que los métodos basados en colores se acercan mucho más a la verdad de referencia que los que se basan en histogramas, que, a

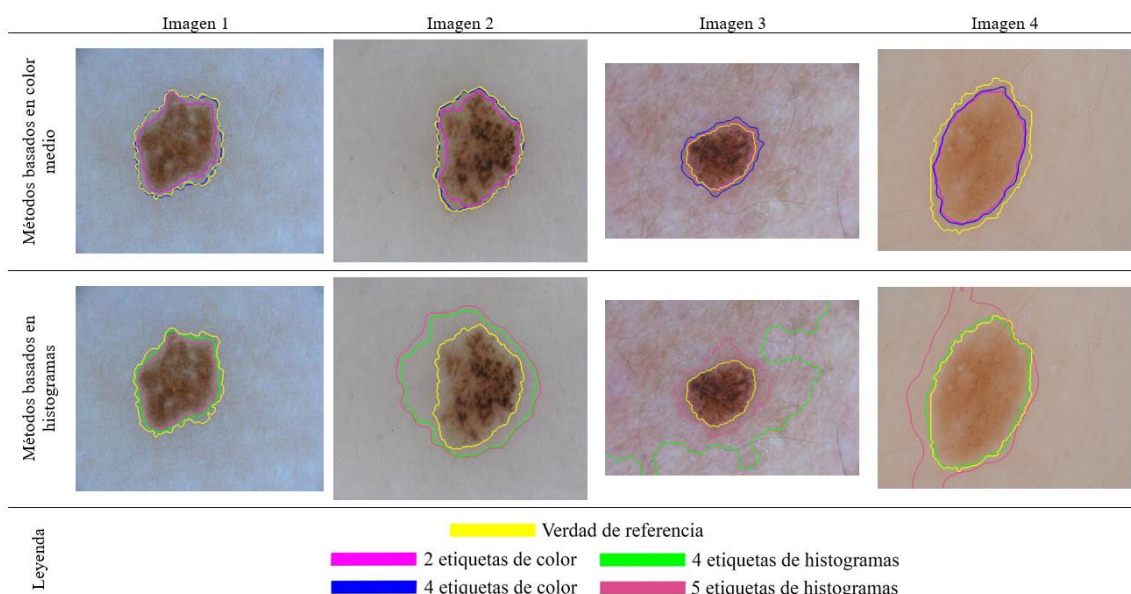


Figura 5-5. Resultados visuales de las máscaras obtenidas para los distintos tipos de métodos

veces, sobresegmentan demasiado. Obteniendo una precisión, promediada entre las 30 imágenes con las que se ha trabajado, de 0.9172 para el caso de las 4 etiquetas de color. Se debe comentar que el hecho de la aleatoriedad al seleccionar los histogramas de referencia hace que dicho método no sea tan efectivo.

Agradecimientos

Este trabajo ha sido financiado con los proyectos DPI2016-81103-R, Plan Estatal 2013-2016 Retos, y P11-TIC-7727, Proyecto Excelencia Junta de Andalucía.

Referencias

- [1] Bae E, Yuan J, Tai XC. Global Minimization for Continuous Multiphase Partitioning Problems Using a Dual Approach. *International Journal of Computer Vision*, vol 92, n° 1, 2011, pp 112-129. (ISSN: 1573-1405).
- [2] Fernández J, Ciuhu C. Automatic Imaging System With Decision Support for Inspection of Pigmented Skin Lesions and Melanoma Diagnosis. *IEEE Journal of Selected Topics in Signal Processing*, vol. 3, n° 1, pp. 14 - 25, 2009. (ISSN: 1941-0484).
- [3] Pirnóg I, Preda RO, Oprea C, Paleologu C. Automatic Lesion Segmentation for Melanoma Diagnostics in Macroscopic Images. *23rd European Signal Processing Conference (EUSIPCO)*, 2015. (ISBN: 978-0-9928-6263-3).
- [4] Humayun J, Malik AS y Kamel N. Multilevel thresholding for segmentation of pigmented skin lesions. *2011 IEEE International Conference on Imaging Systems and Techniques (IST)*, 2011. (ISBN: 978-1-61284-896-9).
- [5] González-Castro V, Debayle J, Wazaefi Y, Rahim M, Gaudy-Marqueste C, Grob JJ y Fertil B. Texture descriptors based on adaptative neighborhood for classification of pigmented skin lesions. *Journal of Electronic Imaging*, vol. 24, 2015.
- [6] Saéz A, Serrano C, Acha B. Model-Based Classification Methods of Global Patterns in Dermoscopies Images. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, vol. 33, n° 5, pp. 1137 - 1147, 2014. (ISSN: 1558-254X).
- [7] Abbas Q, Fondón I y Rashid M. Unsupervised skin lesions border detection via two-dimensional image analysis. *Computer Methods and Programs in Biomedicine*, vol. 104, n° 3, pp. e1-e15, 2011.
- [8] Suárez-Mejías C, Pérez-Carrasco JA, Serrano C, López-Guerra JL, Parra-Calderón C, Gómez-Cía T, Acha B. Three-dimensional segmentation of retroperitoneal masses using continuous convex relaxation and accumulated gradient distance for radiotherapy planning. *Medical & Biological Engineering & Computing*, vol. 55, n° 1, pp. 1-15, 2017. (ISSN: 1741-0444).
- [9] Ukwatta E, Yuan J, Rajchl M, Qiu W, Tessier D, Fenster A. 3-D carotid multi-region MRI segmentation by globally optimal evolution of coupled surfaces. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, vol. 32, n° 4, pp. 770-785, 2013. (ISSN: 1558-254X).
- [10] Página web de “ISIC 2017: Skin Lesion Analysis Towards Melanoma Detection” https://challenge.kitware.com/#challenge/n/ISIC_2017%3A_Skin_Lesion_Analysis_Towards_Melanoma_Detection (Consultada: Enero-Junio 2017).
- [11] Álvarez Cáceres R. El Método Científico en las Ciencias de la Salud. Vol 1. Ediciones Díaz de Santos, 1996 (ISBN: 9788479782375).
- [12] Chang HH, Zhuang AH, Valentino DJ, Chu WC. Performance measure characterization for evaluating neuroimage segmentation algorithms. *NeuroImage*, vol 47, 2009, pp 122-135.
- [13] Jaccard P. Étude comparative de la distribution florale dans une portion des Alpes et du Jura. *Bulletin de la Société Vaudoise des Sciences Naturelles*, vol 37, 1901, pp 547-579.
- [14] Página web de Wikipedia – Coeficiente de Sorensen-Dice https://es.wikipedia.org/wiki/Coeficiente_de_Sorensen-Dice (Consultada: Mayo-Junio 2017).
- [15] Banik S, Rangayyan RM, Boag GS. Landmarking and Segmentation of 3D CT Images, Morgan & Claypool, 2009 (ISBN: 9781598292848)