

Clasificación de lesiones de piel basada en filtros de Gabor y color

J.A. Pérez-Carrasco^{1,2}, C. Serrano², B. Acha²

¹ Instituto de Microelectrónica de Sevilla (IMSE-CNM-CSIC), Sevilla, España, jcarrasco@imse.cnm.es

² Dpto. Teoría de la Señal, ETSIT, Universidad de Sevilla, Sevilla, España, {cserrano, bacha}@us.es

Resumen

*Cuando se pretende diagnosticar un posible cáncer de piel, los médicos evalúan la lesión siguiendo diferentes reglas. Aunque la más famosa es la regla ABCD (Asimetría, Borde, Color, Diámetro), una técnica muy empleada en Dermatología es clasificar las lesiones siguiendo un análisis de patrones. Este artículo presenta un método novedoso basado en técnicas de filtrado que clasifica imágenes de color correspondientes a diferentes patrones dermatoscópicos. Hemos evaluado nuestro método usando filtros de Gabor y hemos comparado los resultados obtenidos cuando usamos dos espacios diferentes de color (RGB y $L^*a^*b^*$) y también cuando consideramos o no la información de color. Para implementar esta tarea hemos evaluado la tasa de clasificación usando 8 vectores diferentes de características. Para cada tipo de vector de características hemos usado el 80% de las imágenes de la base de datos para entrenar una red neuronal fuzzy ARTMAP. El restante 20% de las imágenes fue usado para testear la red. La mejor tasa de clasificación es del 90% cuando usamos el espacio de color $L^*a^*b^*$ para la representación de las imágenes.*

1. Introducción

En las últimas dos décadas el número de tumores de piel malignos ha estado creciendo considerablemente año tras año. Aún a día de hoy el mejor tratamiento sigue siendo el diagnóstico temprano y la rápida intervención del tumor. La Dermatoscopia (también conocida como microscopía epiluminiscente) es un método in vivo que se ha demostrado muy útil para el reconocimiento temprano de melanomas malignos. Su uso incrementa el diagnóstico entre un 5% y un 30% sobre la inspección visual clínica [1].

Cuando se pretende dar un diagnóstico, los médicos siguen habitualmente un algoritmo de dos pasos: 1) Clasificar la lesión en melanocítica o no melanocítica. 2) Para las lesiones melanocíticas, clasificarlas entre lesiones malignas o benignas. Para este segundo paso, los métodos más usados son 4: la regla ABCD de dermatoscopia (Asimetría, irregularidad de Borde, variación del Color y Diámetro mayor a 6mm o creciendo) [2][3], el checklist de 7 puntos, el método de Menzies y el análisis de patrones [4]. Para implementar todas estas tareas los sistemas de diagnóstico asistido por computador (CAD) se han convertido en herramientas muy importantes [5][6], ya que como la exactitud del diagnóstico en dermatoscopia depende entre otros factores de la experiencia del dermatólogo, los sistemas CAD pueden

ayudar a los dermatólogos en la atención primaria. La principal parte del trabajo relacionada con diagnóstico automático siempre consiste de un paso de extracción de características (color, textura y/o características de forma), un paso opcional de selección de características y el paso final de clasificación. La principal contribución de la mayoría de investigadores suele ser la elección de nuevas características que mejoran la clasificación de las lesiones y el método habitualmente utilizado para implementar el paso de clasificación final es una red neuronal multietapa (MLP) [7][8]. En [8] se pueden encontrar comparaciones entre todas estas técnicas.

En este artículo nuestro propósito es implementar una clasificación de los diferentes patrones que puede presentar una lesión siguiendo la nueva tendencia en Dermatología: buscar patrones específicos en las lesiones que guíen a los médicos especialistas a un diagnóstico. Los médicos, para clasificar entre lesiones benignas y malignas toman en consideración factores como la apariencia general del Color, el orden Arquitectural, la Simetría del patrón y la Homogeneidad (CASH). Las lesiones melanocíticas benignas tienden a tener pocos colores, orden arquitectural, simetría en el patrón y/o homogeneidad. Los melanomas malignos a menudo presentan muchos colores y un fuerte desorden arquitectural, asimetría en el patrón y heterogeneidad [4]. Según estos criterios las lesiones o patrones pueden ser clasificadas como reticular o patrón de red, globular, empedrada, homogénea, estallido de estrellas, paralela y multicomponente [6].

Los métodos comúnmente usados para caracterización de texturas pueden ser divididos en tres categorías: estadísticos, basados en modelos y basados en filtrado. La mayoría de los métodos estadísticos y basados en modelos para clasificación de texturas consideran interacciones espaciales en vecindarios relativamente pequeños. Por tanto, estos métodos son más adecuados para el trabajo con microtexturas [9]. Los métodos basados en filtrado (incluyendo wavelets, filtros de Gabor, steerable pyramids y los bancos de filtros direccionales (DFB)) caracterizan las texturas en el dominio frecuencial. Entre las tres categorías, MPEG-7 ha elegido el filtrado mediante filtros de gabor para la descripción de texturas. La razón de esto es que el córtex visual es sensible a componentes localizados de frecuencia [10]. Además, ha sido demostrado que la dirección junto con la información de escala es importante

para la percepción de textura. Una completa evaluación y comparativa de métodos de filtrado para clasificación de texturas se puede encontrar en [11].

El propósito de este artículo no es separar la lesión de piel normal sana, sino clasificar la imagen de entrada que será una muestra de uno de los diferentes tipos de patrones de lesiones de piel que vamos a clasificar. Los posibles patrones serán los siguientes: Reticular o patrón de red, globular, empedrado, homogéneo, estallido de estrellas, paralelo y multicomponente.

Una ilustración de los patrones listados se muestra en la Figura 1.




Figura 1. Imágenes de lesiones de piel correspondientes a cada uno de los posibles patrones: (a) Reticular, (b) Globular, (c) Empedrada, (d) Homogénea, (e) Estallido de estrellas, (f) Paralela, (g) Multicomponente (reticular, globular y homogénea).

Para llevar a cabo la clasificación, hemos realizado un algoritmo basado en técnicas espectrales que hace uso de un banco de filtros de Gabor y de la información de color de las imágenes para implementar un procedimiento de análisis de patrones que nos permita clasificar imágenes dermatoscópicas. Los filtros de Gabor han sido empleados en multitud de aplicaciones de procesamiento de imágenes, entre ellas clasificación y segmentación de texturas, reconocimiento de imágenes y objetos, registro, aplicaciones médicas y seguimiento de movimiento [12][13]. Sin embargo, cuando el tema a tratar es la clasificación de patrones de lesiones de piel, es difícil

encontrar trabajos relacionados [14]. Además, la adición de la información del color para la tarea de clasificación de lesiones de piel ha sido un tema poco explorado hasta día de hoy.

Para clasificar los resultados obtenidos mediante el banco de filtros, usamos un método de clasificación supervisado basado en el uso de una red neuronal fuzzy ARTMAP, la cual se ha demostrado que proporciona muy buenos resultados en tareas como la clasificación de patrones [15].

Para evaluar el algoritmo que aquí se presenta hemos utilizado una base de datos formada por 100 imágenes 40x40, cada una representando un patrón específico.

2. Implementación

El algoritmo desarrollado consta de dos etapas. La primera de ellas consiste en la extracción de características de la imagen de entrada que serán agrupadas en un vector. Este vector se obtiene aplicando un banco de filtros de gabor a la imagen de entrada. La segunda etapa consiste en, una vez obtenidas las características que describen a la imagen, clasificarla en uno de los posibles patrones de lesión de piel mencionados anteriormente.

2.1. Creación del vector de características

En nuestro trabajo hemos empleado las características propuestas por Manjunath obtenidas mediante la aplicación de wavelets de Gabor a las imágenes [16]. Aplicando filtros de Gabor en diferentes escalas y orientaciones, los patrones de textura pueden ser eficientemente descritos en el dominio frecuencial y localizados en el dominio espacial. Se obtiene un banco de filtros de Gabor mediante dilataciones y traslaciones apropiadas de una wavelet madre $g(x,y)$ [16]. La función de gabor bidimensional $g(x,y)$ tendrá la siguiente forma

$$g(x,y) = \left(\frac{1}{2\pi\sigma_x\sigma_y}\right) \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right) + 2\pi j W x\right] \quad (1)$$

donde σ_x , σ_y y W son sus parámetros geométricos característicos. A partir de esta función, un banco de filtros de gabor se puede obtener mediante la función de generación:

$$\begin{aligned} g_{s,k}(x,y) &= a^{-s} g(x',y'), \\ x' &= a^{-s} (x \cos \theta + y \sin \theta) \\ y' &= a^{-s} (-x \sin \theta + y \cos \theta) \end{aligned} \quad (2)$$

where $\theta = k\pi/K$ es la orientación del filtro respecto a la vertical, $k \in \{0, \dots, K-1\}$ es el índice de orientación, y $s \in \{0, \dots, S-1\}$ es el índice de escala. K es el número total de orientaciones y S es el número total de escalas en el banco de filtros. Los parámetros $\{\sigma_x, \sigma_y, a, \theta, W\}$ se calculan siguiendo el método descrito por Manjunath en [16].

Una vez que hemos diseñado el banco de filtros según el número de escalas y orientaciones deseado, filtramos cada

imagen usando cada uno de los filtros que componen el banco. En nuestra aplicación hemos creado un banco compuesto de 24 filtros correspondientes a 4 escalas y a 6 orientaciones. Para cada imagen filtrada W_{mn} , donde m representa la escala y n la orientación, calculamos los parámetros estadísticos media μ_{mn} y desviación típica σ_{mn} del siguiente modo:

$$\mu_{mn} = \iint |W_{mn}(xy)| dx dy \quad (3)$$

$$\sigma_{mn} = \sqrt{\iint (|W_{mn}(x,y)| - \mu_{mn})^2 dx dy} \quad (4)$$

Para incorporar la información de color en nuestro método y estudiar si es útil en la clasificación de lesiones de piel, hemos comparado nuestros resultados usando dos espacios de color diferentes (L*a*b* y RGB) en cuatro escenarios diferentes. El primero de ellos es cuando aplicamos el banco de filtros de gabor a sólo la imagen en escala de grises correspondiente a la imagen a color. De este modo obtenemos un vector de 48 características. El segundo escenario es el correspondiente a considerar solamente la media de cada plano de color sin filtrar la imagen. De este modo creamos un vector de 3 características. El tercer vector de características considerado se construye aplicando el banco de filtros a la imagen en escala de grises obteniendo el vector de 48 componentes y añadiéndole las 3 medias de cada plano de color. De este modo el vector está formado por 51 componentes. Finalmente, el cuarto escenario es cuando aplicamos el banco de filtros a cada uno de los planos de color que componen la imagen. De este modo obtenemos un vector de 144 características.

Los cuatro vectores de características considerados son los que se muestran a continuación (para abreviar mostramos solamente los vectores correspondientes al procesamiento en el espacio de color RGB, pero se han analizado además los mismos vectores considerando también el espacio de color L*a*b*):

$$f_1 = [\mu_{00}\sigma_{00}, \mu_{01}\sigma_{01}, \dots, \mu_{35}\sigma_{35}] = [\mu_{mn}\sigma_{mn}]_{m=0,\dots,3} \quad (5)$$

$n=0,\dots,5$

$$f_2 = [\mu_R \quad \mu_G \quad \mu_B] \quad (6)$$

$$f_3 = [\mu_{mn} \quad \sigma_{mn} \quad \mu_R \quad \mu_G \quad \mu_B]_{m=0,\dots,3} \quad (7)$$

$n=0,\dots,5$

$$f_4 = [\mu_{mnR} \quad \sigma_{mnR} \quad \mu_{mnG} \quad \sigma_{mnG} \quad \mu_{mnB} \quad \sigma_{mnB}]_{m=0,\dots,3} \quad (8)$$

$n=0,\dots,5$

2.2. Clasificación de características mediante una red neuronal Fuzzy ARTMAP

Una vez que hemos creado el vector de características para cada una de las imágenes que componen la base de datos, se utiliza cada vector como entrada a una red neuronal fuzzy ARTMAP [15].

Una red fuzzy ARTMAP es una clase de red neuronal que implementa un aprendizaje supervisado incremental de reconocimiento de categorías y mapas multidimensionales

en respuesta a vectores de entrada que se presentan en orden arbitrario. La red consiste en dos capas de neuronas, F1 y F2, y un subsistema de vigilancia controlado por un parámetro $\rho \in [0, 1]$. Los patrones de entrada tienen carácter analógico. Cada módulo generará unas categorías para los patrones recibidos. Estas categorías se representan por y_a y y_b las cuales tienen todas sus componentes a 0 excepto una que es 1. Para evitar el problema de proliferación de categorías es conveniente normalizar los patrones de entrada. Esto es posible hacerlo dividiendo el patrón por su norma.

Fuzzy ARTMAP construye automáticamente tantas categorías como se necesiten para aprender cualquier conjunto de entrenamiento con un 100% de precisión.

3. Resultados Experimentales

Hemos probado el algoritmo propuesto haciendo uso de una base de datos compuesta por 100 imágenes 40x40 muestra de diferentes patrones de lesiones de piel: reticular o patrón de red, globular, empedrado, homogéneo y paralelo. Para cada tipo de patrón se han usado 20 imágenes. Las imágenes han sido suministradas por la unidad de Dermatología del Hospital Virgen del Rocío (Sevilla, España). Todas las imágenes fueron obtenidas con un dermatoscopio *Fotofinder, Schuco Internacional London Limited*. Hemos realizado una validación acruzada 10 veces [17]: el 80% de las imágenes fueron usadas para entrenar (80 imágenes) y el 20% para validar. Hemos realizado comparaciones usando los distintos vectores de características descritos en la sección anterior y usando los dos planos de color.

En la Tabla 1 mostramos los diferentes vectores de características utilizados y los diferentes resultados obtenidos.

COLOR	VECTOR DE CARACTERÍSTICAS	LONG. VECT.	TASA DE CLASIF. (%)	TIEMPO CLAS. (ms)
LAB	$f=[\mu_{00L} \sigma_{00L} \dots \mu_{35L} \sigma_{35L}]$	48	70,5%	4,8
	$f=[\mu_L \mu_a \mu_b]$	3	88,5%	0,2
	$f=[\mu_{mnL} \sigma_{mnL}; \mu_{mna} \sigma_{mna}; \mu_{mnb} \sigma_{mnb}; m=0,\dots,3; n=0,\dots,5]$	144	80,5%	14
	$f=[\mu_{00L} \sigma_{00L} \dots \mu_{35L} \sigma_{35L}; \mu_L \mu_a \mu_b]$	51	90,0%	5
RGB	$f=[\mu_{00L} \sigma_{00L} \dots \mu_{35L} \sigma_{35L}]$	48	70,5%	4,8
	$f=[\mu_R \mu_G \mu_B]$	3	81,0%	0,2
	$f=[\mu_{mnR} \sigma_{mnR}; \mu_{mnG} \sigma_{mnG}; \mu_{mnB} \sigma_{mnB}; m=0,\dots,3; n=0,\dots,5]$	144	87,0%	14
	$f=[\mu_{00L} \sigma_{00L} \dots \mu_{35L} \sigma_{35L}; \mu_R \mu_G \mu_B]$	51	82,0%	5

Tabla 1. Resultados utilizando diferentes vectores de características.

Como se puede apreciar, el vector de características construido aplicando los filtros de gabor al plano L de la imagen del espacio de color L*a*b* junto con los valores medios de cada plano (L, a, b) proporciona el mejor resultado (90% de clasificación). Con estos resultados obtenidos hemos podido demostrar también que la información de color es realmente importante (con solamente el uso de la información de color obtenemos un porcentaje de clasificación bastante bueno de 88.5%).

El algoritmo propuesto ha sido implementado en Matlab 7.4 y el tiempo de computación promedio necesario para clasificar una imagen usando el vector que proporciona la mejor tasa de clasificación fue de 5 ms.

4. Conclusiones

En este trabajo presentamos un método novedoso de clasificación basado en técnicas de filtrado. La primera novedad del artículo es la metodología seguida para analizar las imágenes dermatoscópicas. Nosotros clasificamos las lesiones realizando un procesamiento de reconocimiento de patrones y no extrayendo características de forma, borde o color. Las lesiones son clasificadas en cinco tipos diferentes de patrones. En nuestro algoritmo el vector de características se crea filtrando la imagen de entrada con un conjunto de filtros de gabor. Para ello hemos probado diferentes posibilidades de vectores de características.

El paso de clasificación lo hemos implementado usando una red neuronal fuzzy ARTMAP. Hemos comparado los resultados obtenidos codificando la imagen en los espacios de color RGB y $L^*a^*b^*$ y hemos comprobado que los resultados en el espacio $L^*a^*b^*$ mejoran los obtenidos con RGB. También hemos demostrado que la información de color es realmente importante cuando consideramos el problema de clasificación de lesiones dermatoscópicas.

Las entradas al algoritmo son imágenes en color de tamaño 40x40 correspondientes cada una a un tipo de patrón de lesión de piel, y la salida de la red neuronal es la clase a la que pertenece la imagen recibida como entrada en el sistema. La tasa de clasificación obtenida es del 90%.

5. Agradecimientos

Los autores quieren dar las gracias a la doctora Amalia Serrano por proporcionar y clasificar las imágenes utilizadas en este trabajo. JAPC ha sido financiado por el proyecto andaluz P06-TIC-01417 (Brain System).

Referencias

- [1] Westerhoff K, McCarthy WH, Menzies SW., Increase in the sensitivity for melanoma diagnosis by primary care physicians using skin surface microscopy, *Br. J. Dermatology*, 143, 2000, pp 1016-20.
- [2] Schmid-Saugeon P, Guillod J, Thiran JP. Towards a computer-aided diagnosis system for pigmented skin lesions, *Computerized Medical Imaging and Graphics*, 27, 2003, pp 65-78.
- [3] Tomatis S, Bono A, Bartoli C, Carrara M, Lualdi M, Tragni G, Marchesini R. Automated melanoma detection: multispectral imaging and neural network approach for classification, *Med. Phys.*, 2, 2003, pp 212-221.
- [4] Braun RP, Rabinovitz HS, Oliviero M, Kopf AW, Saurat JH. Dermoscopy of pigmented skin lesions, *J. Am. Acad. Dermatol.*, 52, 2005, pp 109-121.
- [5] Binder M, Kittler H, Seeber A, Steiner A, Pehamberger H, Wolff K. Epiluminescence microscopy-based classification

- of pigmented skin lesions using computerized image analysis and an artificial neural network, *Melanoma Res*, 8, 1998, pp 261-6.
- [6] Serrano C, Acha B. Pattern analysis of dermoscopic images based on Markov random fields. *Pattern Recognition*, vol 42, sup 6, 2009, pp 1052-1057.
- [7] Surowka G, Grzesiak-Kopec K. Different Learning Paradigms for the Classification of Melanoid Skin Lesions Using Wavelets, *Conf Proc IEEE Eng Med Biol Soc*. 2007, pp 3136-9.
- [8] Lisboa, PJ, Taktak, AF. The use of artificial neural networks in decision support in cancer: A systematic review. *Neural Networks*, vol 19, sup 4, 2006, pp 408-415.
- [9] Speis A, Healey G, Feature extraction for texture discrimination via random field models with random spatial interaction. *IEEE Trans. Image Process*, vol 5 sup 4, 1996, pp 635-645.
- [10] Kulikowski JJ, Bishop PO. Fourier analysis and spatial representation in the visual cortex, *Experientia* 37, 1981, pp 160-163.
- [11] Randen T, HusZy JH. Filtering for texture classification: a comparative study, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol 21, sup 4, 1999 pp 291-310.
- [12] Serre T, Wolf L, Bileschi S, Riesenhuber M, Poggio T. Robust Object Recognition with Cortex-Like Mechanisms. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol 29, sup 3, 2007, pp 411-426.
- [13] Ferrari RJ, Rangayyan RM, Desautels JEL, Borges RA, Frère AF. Analysis of asymmetry in mammograms via directional filtering with Gabor wavelets. *IEEE Trans. Med. Imag*, vol 20 sup 9, 2001, pp 953-964.
- [14] Stockmeier HG, Bäcker H, Bäuml W, Lang EW. BSS-Based Feature Extraction for Skin Lesion Image Classification. *ICA 2009*, pp 467-474.
- [15] Carpenter A. Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps. *IEEE Transactions on Neural Networks*, vol 3, sup 5, 1992, pp 698-713.
- [16] Manjunath BS, Ma WY. Texture features for browsing and retrieval of image data. *IEEE Trans. Pattern Anal. Mach. Intell.*, vol 18, sup 8, 1996, pp 837-842.