

Algoritmo de Crecimiento de Regiones con característicos de texturas: una aplicación en biopsias de médula ósea

Meschino Gustavo ⁽¹⁾, Moler Emilce ⁽²⁾

⁽¹⁾Laboratorio de Bioingeniería – ⁽²⁾Laboratorio de Procesos y Medición de Señales
Facultad de Ingeniería, Universidad Nacional de Mar del Plata
Juan B. Justo 4302 - B7608FDQ Mar del Plata
gmeschin@fi.mdp.edu.ar

Resumen

Se presenta un algoritmo de segmentación semi-automático que permite establecer de manera exacta la presencia de estructura trabecular en biopsias de médula ósea. El algoritmo propuesto se basa en una combinación entre técnicas de identificación de texturas y crecimiento de regiones. Se elige la semilla como un píxel perteneciente a la trabécula y el proceso de crecimiento se basa en una evaluación de distancias entre vectores de característicos calculados a partir de matrices de co-ocurrencia. El método fue probado con imágenes de biopsias de médula ósea que presentan distribuciones variadas de trabéculas. Se presentan resultados visuales que muestran una precisión superior a otras técnicas tradicionales.

Palabras Claves

Procesamiento de Imágenes – Segmentación – Crecimiento de Regiones – Textura

1. Introducción

Los informes de biopsias de médula ósea entregan resultados porcentuales de la presencia de trabéculas, células adiposas y hematopoyéticas. Dichos porcentajes se toman como criterio genérico mediante el cual se pueden determinar, entre otros factores, desórdenes metabólicos como las osteopenias, siendo la osteoporosis una de las de mayor incidencia en la población (Rubin, 1992). Sin embargo realizar una correcta identificación de la estructura trabecular no es un problema sencillo, dado que los niveles de gris que contiene son muy similares a los de las regiones de celularidad (Frisch, 1985).

Uno de los campos de mayor interés dentro del Procesamiento Digital de Imágenes (PDI) es la segmentación de una imagen en los diferentes objetos que la componen (González, 1992). En este trabajo se aplican técnicas basadas en la identificación de texturas, a través del uso de los vectores característicos y de la técnica denominada Crecimiento de Regiones. Esta combinación surge como solución para realizar una segmentación óptima en imágenes donde las formas a identificar presentan el mismo nivel de gris que el fondo. Los métodos tradicionales de Crecimiento de Regiones se basan en la comparación de niveles de gris de píxeles vecinos, y suelen fallar cuando la región a segmentar contiene intensidades similares a regiones adyacentes. Si se indica una amplia tolerancia, los límites detectados superarán la región a identificar; por el contrario, si la tolerancia se disminuye demasiado, la región identificada será menor que la deseada (Monga, 1987).

El análisis de texturas es hoy en día un campo muy explorado dentro del PDI, dado que múltiples escenas pueden verse como composición de diferentes texturas. La textura visual se refiere a la impresión de rugosidad o suavidad que presentan algunas superficies creadas por las variaciones de tonos o repetición de patrones visuales en la misma. Las técnicas de análisis de texturas se basan en la asignación de uno o varios parámetros indicadores de características de la textura presente a cada región de la imagen. Estos parámetros o características se suelen utilizar como patrones en una posterior clasificación. El tratamiento de la segmentación mediante el paradigma de texturas es adecuado en este caso, pues la textura de las trabéculas suele ser bien diferente de la del resto de los tejidos (Haralick, 1992).

Se experimentó con contornos activos (Kass, 1987) y se obtuvieron resultados aceptables, pero ante la presencia de múltiples formas cóncavas la curva no producía el ajuste necesario. Este método no se descarta, sólo requiere la utilización de alguna variante del mismo. De manera similar ocurre con los métodos que aplican técnicas de Morfología Matemática (Serra, 1982), que entregan buenos resultados pero sólo en algunos casos y encontrar el correcto elemento estructurante es una tarea difícil (Vincent, 1994).

Por lo tanto, es de interés contar con una herramienta que, a través de técnicas de Procesamiento Digital de Imágenes, contribuya a la cuantificación de las estructuras presentes, para realizar cálculos posteriores (Bullough, 1990).

En las secciones siguientes se describe un resumen de las técnicas de PDI utilizadas, como así también el algoritmo propuesto que combina estas técnicas y permite la segmentación esperada.

2. Métodos y Materiales

Se obtuvieron imágenes de biopsias por medio de un microscopio óptico Medicux-12 con una cámara CCD Hitachi KP-C550, adquiridas a través de una PC, con un tamaño de 640 x 480 píxeles. Se grabaron en disco en formato de mapa de bits de Windows (bmp) y posteriormente fueron convertidas a escala de grises de 8 bits (256 intensidades).

2.1. Fundamentos de las técnicas de Procesamiento Digital de Imágenes

- Característicos estadísticos de Texturas

Uno de los enfoques más simples para describir la textura de una imagen digital, consiste en el cálculo de los momentos estadísticos. Éstos permiten calcular medidas de contraste de niveles de gris, útiles para establecer descripciones de uniformidad o suavidad relativa. Se define el momento n-ésimo de z (variable aleatoria que representa a una imagen) como:

$$\mu_n(z) = \frac{1}{n} \sum_{i=1}^L (z_i - m)^n \cdot p(z_i) \quad \text{Ec. 1}$$

Donde $p(z_i)$ son los valores del histograma correspondiente, L el número máximo de los distintos niveles de intensidad y m es el valor medio, definido por:

$$m = \sum_{i=1}^L z_i \cdot p(z_i) \quad \text{Ec. 2}$$

En determinadas situaciones es útil considerar no sólo la distribución de las intensidades, sino también la posición de los píxeles con igual o aproximadamente igual valor de intensidad.

La dependencia espacial de los niveles de gris permite caracterizar una textura a través de la co-ocurrencia de sus niveles de gris. La textura gruesa es aquella en la que la distribución varía pobremente conforme se incrementa la distancia mientras que en la textura fina la distribución varía rápidamente.

La co-ocurrencia de los niveles de gris se puede especificar en una matriz de frecuencias relativas P_{ij} en la que dos píxeles vecinos separados por una distancia d están presentes en la imagen, uno con nivel de gris i y el otro con nivel de gris j. Estas matrices de frecuencia de dependencia espacial de niveles de gris son simétricas y función de la relación angular entre los píxeles vecinos así como función de la distancia entre ellos. Por ejemplo, para una relación angular de 0° , los valores de la matriz de frecuencias relativas denotan la probabilidad de una transición de izquierda a derecha de un nivel de gris i a otro j. El conjunto de todos los píxeles vecinos horizontales separados por una distancia d, está dado por:

$$R_H = \{((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) / k - m = 0, |l - n| = d\} \quad \text{Ec. 3}$$

Donde $(L_y \times L_x) \times (L_y \times L_x)$ es el conjunto de valores que representa la ventana de análisis; L_y es el conjunto de valores de gris en dirección vertical y L_x es el conjunto de valores de gris en dirección horizontal.

Considerando ángulos de 0° , 45° , 90° y 135° y distancia entre píxeles $d=1$, se obtienen cuatro diferentes matrices. Pueden utilizarse diversas definiciones de distancia (Moler E., 1999).

La potencialidad de la co-ocurrencia está en que caracteriza la interrelación espacial de los niveles de gris en un patrón de textura y esta relación se mantiene invariante ante transformaciones

monotónicas de niveles de gris. Su debilidad reside en captar la forma de las primitivas de nivel de gris.

A partir de las matrices de co-ocurrencia se pueden calcular diversos valores característicos. Estos valores serán elementos de un vector, denominado *vector de característicos*, que se suele utilizar como dato de entrada en algoritmos de Reconocimiento de Patrones. Algunos de los valores característicos relevantes son:

- Entropía:

$$\sum_{ij} P_{ij} \log P_{ij} \quad \text{Ec. 4}$$

- Momento Diferencial de Orden k (Contraste):

$$\sum_{ij} |i - j|^k (P_{ij})^p \quad \text{Ec. 5}$$

- Momento Diferencial inverso de orden k:

$$\sum_{\substack{ij \\ i \neq j}} \frac{(P_{ij})^p}{|i - j|^k} \quad \text{Ec. 6}$$

- Probabilidad máxima:

$$\max_{ij} P_{ij} \quad \text{Ec. 7}$$

- Crecimiento de Regiones

Este método de segmentación, de amplia aplicación, combina aspectos de umbralamiento y conectividad. Se basa en el agrupamiento de píxeles utilizando dos criterios: proximidad y homogeneidad.

La mayoría de los algoritmos que utilizan el criterio de proximidad efectúan el agrupamiento de píxeles según criterios de división (splitting) y unión (merging) de pequeñas regiones según las características estadísticas de los niveles de gris (Russ, 1995). Se consideran regiones a píxeles que tienen al menos conectividad 4.

Otro criterio es el de homogeneidad, que se implementa mediante una función que cuantifica la similitud entre regiones. Esta función se basa generalmente en una comparación de características estadísticas de las intensidades. Por ejemplo, dos regiones pueden considerarse homogéneas si sus intensidades mínimas y máximas se encuentran en un rango determinado. En la mayoría de los casos, la homogeneidad de las regiones se evalúa calculando la probabilidad de que las regiones sean realmente sub-regiones compuestas por píxeles muestreados de una región más grande. Este valor es entonces comparado con una probabilidad mínima umbral que considera a las regiones como homogéneas (Haralick, 1992).

2.2. Algoritmo propuesto: Crecimiento de Regiones por comparación de Texturas

En el algoritmo aquí presentado se propone la comparación de vectores de característicos estadísticos de texturas en lugar de intensidades de gris. Inicialmente debe elegirse un píxel correspondiente a la región (semilla), cuyo entorno sea representativo del tipo de textura a segmentar.

Teniendo el píxel semilla, se calculan los característicos en una sub–imagen determinada por el entorno del mismo, con el tamaño de la misma fijado *a priori*. Luego se van comparando los píxeles vecinos, utilizando ventanas del mismo tamaño que en el caso inicial.

Si la distancia vectorial entre el vector de característicos correspondiente al píxel en análisis y el de uno de sus vecinos es menor que un cierto umbral, entonces se indicará el píxel vecino como correspondiente a la misma textura, y se almacenará como futuro píxel a analizar. De lo contrario, se descarta, y corresponderá al límite o contorno de la región segmentada.

Se procede de igual manera con los píxeles almacenados hasta que la lista que éstos conforman se agota totalmente. Esto indicaría el final del crecimiento de la región, lo que determinaría la segmentación.

Una posible variación del algoritmo para mejorar el tiempo de procesamiento, con una pérdida mínima de la resolución de la zona detectada, consiste en tomar los vecinos separados del píxel en análisis en una distancia determinada mayor a 1, por ejemplo 3 píxeles. Esto provoca que la región crezca más rápidamente, pero en este caso los contornos quedarán menos suaves.

La elección adecuada del umbral y del tamaño de la región sobre la que se calculan los característicos es crucial para obtener resultados satisfactorios.

La Figura 1 muestra el diagrama de Chapin del algoritmo, que fue implementado en MatLab® 5.3.

La Figura 2 muestra una pantalla del entorno visual que permite una adecuada operación con los parámetros. El usuario puede optar por ver el crecimiento a medida que ocurre, o directamente, ver la región una vez terminado el algoritmo. Se muestra en todo momento el número de puntos a analizar, lo que permite estimar el tiempo de cálculo que resta. Finalmente, se pueden grabar las imágenes segmentadas en distintos formatos.

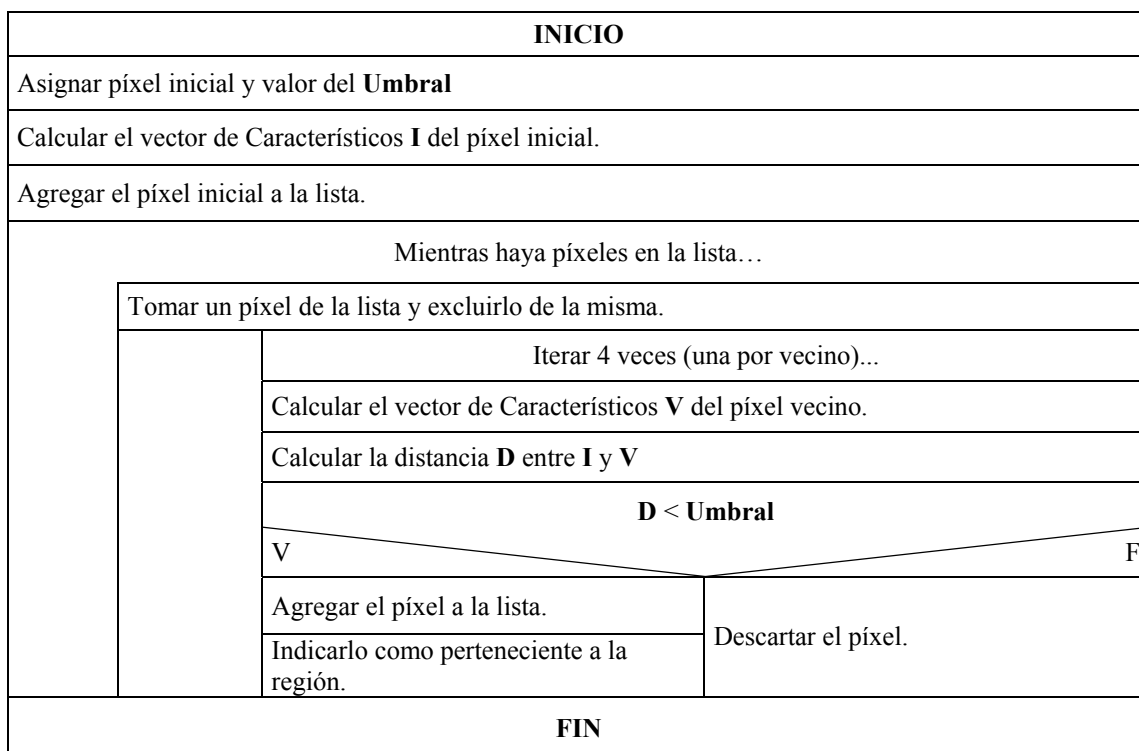


Figura 1: Diagrama de Chapin del algoritmo

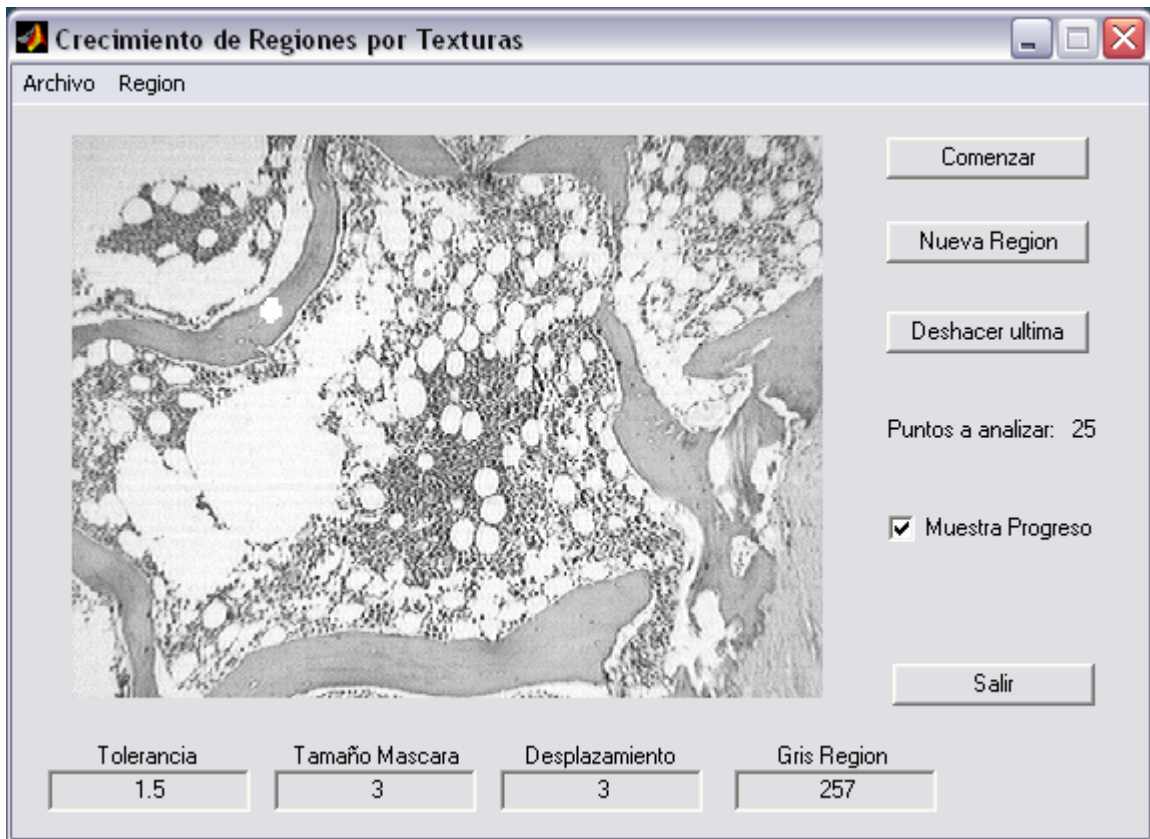


Figura 2: Interfase gráfica del algoritmo desarrollado.

2.3 Testeo del Algoritmo propuesto

Para probar el método se tomaron 25 imágenes, algunas de ellas correspondientes a los mismos pacientes, mostrando diferentes porciones de una misma biopsia.

En este trabajo se utilizaron tres matrices de co-ocurrencia con ángulos de 0°, 45° y 90°, correspondientes a las direcciones horizontal, diagonal y vertical respectivamente y distancia d=1.

El vector de características utilizado es:

$$H = [\text{cnth} \text{ cntv} \text{ cntd} \text{ engh} \text{ engv} \text{ engd} \text{ eph} \text{ epv} \text{ epd} \text{ maxh} \text{ maxv} \text{ maxd} \text{ med}]$$

Ec. 8

siendo:

cnth, cntv, cntd	Contraste en las matrices de co-ocurrencia horizontal (0°), vertical (90°) y diagonal (45°) respectivamente.
engh, engv, engd	Energía (momento diferencial de orden 0) en las matrices de co-ocurrencia horizontal (0°), vertical (90°) y diagonal (45°) respectivamente.
eph, epv, epd	Entropía en las matrices de co-ocurrencia horizontal (0°), vertical (90°) y diagonal (45°) respectivamente.
maxh, maxv, maxd	Probabilidad Máxima en las matrices de co-ocurrencia horizontal (0°), vertical (90°) y diagonal (45°) respectivamente.

med	Valor medio normalizado entre 0 y 1 de los niveles de gris de la región analizada.
-----	---


Se aplicó el algoritmo descrito con el vector **H** que da origen a los vectores **I** y **V**. El valor del umbral se determinó luego de realizar pruebas heurísticas con un lote de imágenes.

3. Resultados obtenidos

A continuación se entregan los resultados que se obtuvieron luego de aplicar el algoritmo de Crecimiento de Regiones combinado con el vector de características de identificación de texturas. La Figura 3 muestra la segmentación obtenida en imágenes de biopsias de médula ósea.

En las imágenes originales se han recuadrado zonas conflictivas para realizar la segmentación y que el algoritmo propuesto lo soluciona satisfactoriamente. En la imagen (a) se visualiza una bifurcación (Recuadro 1) que corresponde a celularidad y no es trabécula. Se observa que el resultado obtenido es el deseado. De manera similar ocurre con lo marcado en los Recuadros 2 y 3 que indican zonas difusas entre artefactos y trabéculas y que se resuelven positivamente.

Los resultados finales fueron comparados con la segmentación manual que realiza un experto donde se concluye que se cometió un error menor al 3%.






Figura 3: Imágenes originales: (a),(c),(e). Resultados obtenidos: (b),(d),(f)

4. Conclusiones

Se presentó un algoritmo que permite mejorar considerablemente la eficiencia en el reconocimiento de trabéculas que presenta una imagen microscópica de una biopsia, respecto a la segmentación lograda mediante la técnica de crecimiento de regiones por similitud de niveles de gris.

La segmentación de trabéculas en biopsias de médula ósea es un proceso complejo ya que presentan zonas difusas que dificultan la tarea de extracción de objetos. La segmentación a través de técnicas standard, como umbralamiento, en este tipo de imágenes no entrega resultados satisfactorios. Las técnicas de Crecimiento de Regiones se aproximan a la identificación de los objetos, pero no es satisfactoria en todos los casos. La elección de la tolerancia resulta muy dificultosa ya que una equivocación conduce a una segmentación por exceso o por defecto.

La identificación de texturas es una técnica adecuada para resolver este problema, aunque la elección de los característicos que conforman el vector requiere de un cuidadoso análisis previo.

Una vez optimizados los parámetros para un determinado tipo de imagen, se puede lograr una eficiente segmentación de imágenes similares, lo que facilitaría el trabajo del profesional, disminuyendo la subjetividad del análisis.

Hasta el momento el método se desarrolló en MatLab 5.3[®]. Sin embargo, luego de realizar las pruebas necesarias y recibir las opiniones de los especialistas, se podrá desarrollar en la plataforma que se requiera.

Por todo lo expuesto es que se propone el algoritmo enunciado.

5. Agradecimientos

Los autores agradecen a los especialistas: Dr. Ulises Zanetto y Dr. Fernando Pagani por su permanente asesoramiento y provisión de material histológico e instrumental.

Referencias

- Bullough, P. et al. 1990. The tissue diagnosis of metabolic bone disease. Role of histomorphometry. *Orthop Clin North Am*, 21(1): 65-79.
- Frisch, B. 1985. *Biopsy Pathology of Bone and Bone Marrow*, ed. Raven Press, New York.

- Gonzalez, R. and R. Woods. 1992. *Digital Image Processing*, ed. Addison –Wesley.
- Haralick R. and L. Shapiro. 1992. *Computer and Robot Vision*, Vol I, Addison –Wesley.
- Kass, M. et al. 1987. Snakes: Active contour model. *Int. J. Comput. Vis.*, 1: 321-331.
- Monga, O. 1987. An Optimal Region Growing Algorithm for Image Segmentation. *Int. Journal of Pattern Recognition and Art. Intell.*, 4, pp. 351-375.
- Rubin E. and Farber J. 1992. *Patología: Fundamentos*, ed. Médica Panamericana.
- Russ, J. 1995. *The Image processing Handbook*, 2nd edition, CRC Press.
- Serra, J. 1982. *Image Analysis and Mathematical Morphology – Vol I*, ed. Academic Press.
- Vincent, L. and E. Dougherty. 1994. Morphological Segmentation for Textures and Particles, in *Digital Image Processing Methods*, ed. Marcel Dekker.