

Segmentación rápida de huesos basada en bordes y regiones en imágenes TAC

J. A. Pérez-Carrasco¹, C. Suarez-Mejías², B. Acha¹, F. J. Olías-Sánchez¹, C. Serrano¹

¹ Dpto de Teoría de la Señal y Comunicaciones, Universidad de Sevilla, Camino de los Descubrimientos, s/n. 41092, Sevilla España, {jjperez2@us.es, bacha@us.es, olias03@gmail.com, cserrano@us.es}

² Hospital Universitario Virgen del Rocío, Sevilla, España, cristina.suarez.exts@juntadeandalucia.es

Resumen

En este trabajo se presenta una técnica de segmentación automática de huesos en imágenes TAC sencilla y muy rápida que permite implementar la segmentación de volúmenes TAC en cuestión de pocos segundos.

La segmentación automática de estructuras óseas es de especial interés para los radiólogos y cirujanos para analizar enfermedades óseas o para planificar algunas intervenciones quirúrgicas. Esta segmentación es una tarea complicada ya que los huesos suelen presentar intensidades que solapan con las de los tejidos circundantes (músculos, órganos, etc). Esta superposición se debe principalmente a la composición de los huesos y a la presencia de algunas enfermedades tales como osteoartritis, osteoporosis, etc. Por otra parte, la segmentación de las estructuras óseas es una tarea que requiere mucho tiempo debido a la esencia 3D de los huesos. Por lo general, esta segmentación se implementa de forma manual o con algoritmos usando técnicas simples tales como umbralización y que por tanto proporcionan malos resultados.

En este trabajo, el algoritmo propuesto hace uso de técnicas de umbralización, detección de bordes y análisis de regiones y es comparada con varias técnicas presentes en el estado del arte que utilizan Level Sets y algoritmos de maximización de flujo. Para efectuar las comparaciones se han utilizado veinte imágenes de TACs y se han calculado diferentes coeficientes como DICE, sensibilidad, sensibilidad y valor predictivo positivo (VPP) para evaluar el rendimiento de nuestra aplicación. Se obtuvieron los valores DICE y sensibilidad superiores al 0,91 y 0,97 respectivamente.

1. Motivación

La segmentación automática y precisa de los huesos es de especial interés para los radiólogos y cirujanos con el fin de analizar y localizar muchos tipos de fracturas, diagnosticar algunas enfermedades de los huesos (como la osteoartritis, la artritis reumatoide, la osteoporosis) y en la planificación de cirugía plástica. La segmentación de tales estructuras es difícil debido a la presencia de algunas enfermedades que por lo general provocan una reducción en la densidad ósea en las diferentes áreas. Además, las diferentes partes de los huesos (principalmente hueso compacto y esponjoso) presentan grandes diferencias de densidad, y, por tanto, diferentes valores Hounsfield. Esto implica una superposición de estos valores con valores Hounsfield correspondientes a otros tipos de tejido tales como músculo, grasa o algunos órganos. En la Fig. 1 se muestran diferentes estructuras óseas con sus diferentes composiciones y densidades.




Figura 1. Diferentes densidades en tejido óseo.

Una segunda dificultad en la segmentación de las estructuras óseas es su esencia 3D. Por lo tanto, se requieren algoritmos rápidos y automáticos a fin de obtener la segmentación con reducidos tiempos de computación.

La segmentación de tejido óseo ha sido abordada por muchos autores, y las diferentes técnicas utilizadas pueden ser clasificadas en cuatro categorías [1]: basados en nivel de intensidad, basados en bordes, basados en regiones, o basados en modelos. En algunas obras la técnica de segmentación se elige de acuerdo con el número de huesos o el tipo de hueso a ser segmentado [2] [3] [4]. Esta falta de generalización es un problema, ya que los radiólogos prefieren no considerar diferentes métodos de segmentación según sean las regiones a analizar. Por lo tanto, interesa un método general y adecuado que sea capaz de segmentar un amplio número de estructuras óseas sin considerar su número ni su localización. Cuando consideramos algoritmos más generales, en la literatura se prefieren algoritmos basados en conjuntos de nivel (*Level Sets*), contornos activos (*Active Contours*), cortes de grafos (*Graph-Cuts*) y metodologías basadas en técnicas de relajación convexa y maximización de flujo (*Max-Flow*, *Continuous Convex Relaxation*) [5][6][7][8]. Sin embargo, estos métodos requieren tiempos de computación elevados requiriendo del orden de minutos (u horas) para segmentar las imágenes que componen un volumen TAC, siendo por tanto no adecuados para muchos radiólogos.

En este trabajo se presenta un algoritmo para la segmentación rápida y automática de tejido óseo en volúmenes TAC combinando información de intensidad, de bordes y análisis de regiones. Además, se ha realizado una comparación con distintas técnicas (Umbralización, Level Sets y algoritmos de maximización de flujo) que existen en la actualidad. Para la realización de este algoritmo, establecimos una serie de características que debía de cumplir:

- 1.- El algoritmo debe de ser totalmente automático y no debe necesitar ni parámetros, ni recortes de regiones, ni interacción alguna con la persona que lo use.
- 2.- El algoritmo debe ofrecer los mismos resultados independientemente de la parte del cuerpo que aparezca en las imágenes.
- 3.- El algoritmo debe ser lo más rápido posible, ya que el objetivo es aplicárselo a un gran número de imágenes para poder obtener posteriormente un modelo 3D del cuerpo (o parte del cuerpo) que se esté estudiando.
- 4.- El algoritmo debe ser capaz de segmentar aún en presencia de algunas enfermedades óseas, como por ejemplo la osteoporosis. La osteoporosis es una enfermedad degenerativa de los huesos que causa una pérdida de densidad y masa ósea, lo que desemboca en un alto riesgo de fractura o micro fracturas. Esta enfermedad provoca que la densidad de mineral ósea se vea disminuida.

2. Implementación

El algoritmo que se ha desarrollado es muy simple, y, tal como se puede observar en la Fig. 2, se puede dividir en tres bloques:




Figura 2. Bloques que componen el algoritmo.

2.1. Preprocesado de la Imagen

En nuestra aplicación se han utilizado 20 imágenes extraídas de 20 volúmenes TAC. Los valores Hounsfield en los volúmenes de TAC están por lo general entre -2000 y 3000. En estructuras óseas estos valores suelen estar comprendidos aproximadamente entre 700 (hueso esponjoso) y 3000 (hueso denso). La etapa de preprocesado consiste básicamente en una etapa de umbralización y normalización seguida por una etapa de ajuste de contraste. El umbral elegido en la operación de umbralización fue elegido escogiendo el valor mínimo presente en las estructuras óseas en imágenes segmentadas proporcionadas por un experto. En segundo lugar, la imagen umbralizada es normalizada y denotada como *Inorm*. Esta normalización permite una mejora de contraste de la imagen. Para no perder generalización, los valores mínimos y máximos, y el umbral elegido que han sido utilizados durante las operaciones de preprocesado son comunes a todos los volúmenes que se han utilizado.

2.2. Detección de bordes y rellenado

La segunda etapa del algoritmo consiste en detección de bordes y rellenado. Existen dos principales familias de detectores de bordes: por un lado están los que se basan en el gradiente, es decir la primera derivada; y por otro lado, los que se basan en la Laplaciana, que se corresponde con la segunda derivada.

Para la detección de bordes se han usado dos máscaras, LoG y Canny. LoG busca las coordenadas de una imagen donde la segunda derivada toma el valor cero, mientras que los valores a su alrededor son altos. El método utilizado de detección de bordes basado en el operador Canny se basa en tres pasos: primero suaviza la imagen para eliminar ruido, posteriormente calcula el gradiente, y selecciona los máximos locales (de esta manera se evitan bordes anchos) y para finalizar, elimina los bordes creados por ruido. La principal ventaja de este algoritmo es que es muy rápido y además es muy robusto contra el ruido, pero esa es su principal desventaja también, porque en ocasiones elimina bordes reales de la imagen.

En nuestro algoritmo se usan ambos porque es muy importante que se formen bordes cerrados, y se ha comprobado que al usar ambos métodos y combinarlos se consiguen mejores resultados. Una vez que hemos detectado los bordes, hacemos una operación de dilatación con una máscara de 2x2, de esta manera cerramos algunos bordes que han quedado abiertos, intentando deformar los contornos que hemos hallado lo menos posible. Tras cerrar la mayor parte (o todos) los bordes inconexos, hacemos un rellenado de todas las regiones y seguidamente le aplicamos una operación de erosión. Como ya sabemos una dilatación seguida de una erosión se trata, en realidad, de un cierre, pero no lo hemos nombrado como tal ya que entre ambos pasos se realiza el rellenado de regiones. Lo hacemos de este modo porque en algunos casos la erosión vuelve a abrir algunos bordes que han sido cerrados por la dilatación, pero si hacemos el rellenado entre esas dos operaciones sellamos los bordes, evitando así que la erosión los vuelva a abrir. En la Fig. 3 se muestran dos imágenes obtenidas para un corte perteneciente a un TAC. La figura superior muestra el corte tras la detección de bordes. La figura central muestra el resultado de la dilatación y cómo ésta cierra algunos bordes inconexos (indicados mediante las flechas rojas). Finalmente, la última figura muestra el corte tras la operación de rellenado y erosión.

2.3. Clasificador de Regiones

La última etapa consiste en clasificar las regiones en hueso o no hueso. Como se puede observar en la Fig. 3, hay muchas regiones rellenadas que no corresponden a hueso, por lo que el siguiente paso consiste en limpiar esta imagen para deshacernos de esas regiones. Para realizar esta tarea se van a realizar una serie de cálculos de cada región en particular. Las principales medidas realizadas son:




Figura 3. Operación de detección de bordes, dilatación, rellenado y erosión.

- Área de la región: a partir del cálculo del área de la región vamos a descartar las regiones cuya área sea menor de 140 píxeles, de esta manera eliminamos regiones que han sido originadas por pequeñas calcificaciones y ruido en general.
- Longitud de los ejes de la elipse inscrita en la región: con esta medida podemos eliminar artefactos del exterior del cuerpo que aparecen en ocasiones con altos niveles de Hounsfield y elementos que han sido segmentados con formas muy alejadas a las que presentan los huesos.

3. Resultados Experimentales

En nuestra aplicación se han utilizado 20 imágenes 512x512 extraídas de 20 volúmenes TAC. Las imágenes corresponden a pacientes distintos y a TACs diferentes. Para poder medir la eficiencia de la técnica de segmentación, estas imágenes han sido segmentadas manualmente por un experto. La segmentación manual ha sido utilizada como groundtruth y se han calculado diferentes parámetros para medir la eficiencia de la segmentación implementada. Estos parámetros miden la efectividad de una técnica de segmentación en base a los verdaderos positivos (píxeles que han sido marcados como hueso y realmente lo son), verdaderos negativos (píxeles marcados como no hueso y realmente no lo son), falsos positivos (píxeles marcados como hueso que realmente no lo son) y falsos negativos (píxeles que son hueso pero que han sido marcados como negativos). Los

parámetros objetivos de eficiencia son: PPV (*Positive Predicted Value*), Sensibilidad, Especificidad y Coeficiente Dice.

Es conveniente indicar que para la obtención de todos estos resultados se ha usado un ordenador portátil Toshiba Satellite Pro, con procesador Intel Pentium Dual Core de 2GHz, y 3GB de memoria RAM en el entorno de programación Matlab R2012b. El algoritmo presentado aquí se ha comparado con las tres técnicas descritas a continuación:

3.1. Umbralización

Este método es el más básico y rápido y se ha decidido incluir porque en personas sanas y en determinadas zonas del cuerpo es capaz de dar resultados muy buenos. El umbral elegido fue aquel que daba los mejores resultados de segmentación de acuerdo a los coeficientes que hemos elegido.

3.2. Level Sets

Los level-sets son una técnica muy utilizada para encontrar formas y figuras en imágenes. La principal ventaja que se les atribuye es que no usan la parametrización de una curva, por lo que se pueden adaptar a formas difícilmente parametrizables además de poder dividirse, encontrar y separar varias figuras en una misma imagen. En este caso se ha trabajado con la implementación de Level Sets *DRLSE (Distance Regularized Level Set Evolution)*, desarrollada por Li et al. en [9]. Este algoritmo dispone de varios parámetros configurables, de los cuales sólo vamos a usar los siguientes: el parámetro que hace variar el área (α) y el que hace variar el perímetro (λ).

El principal problema encontrado con esta implementación es el muy elevado tiempo de computación cuando el tamaño de las imágenes o el número de regiones a segmentar son elevados.

3.3. Segmentación de estructuras óseas basada en métodos estadísticos y Max-flow

El algoritmo utilizado en este apartado está descrito en [10]. Este método empieza calculando el histograma local de cada píxel usando una vecindad 21x21. Se calcula la distancia de este histograma local a un histograma referencia de hueso. Tras finalizar este proceso para toda la imagen podremos formar una imagen distancia al histograma modelo. A esta imagen se le llama HDI (*Histogram Distance Image*). Esta distancia será próxima a cero en las zonas con tejido óseo, y será alta en las zonas de tejido blando. Esta información de distancia se combina con información de intensidad para crear una imagen de costes CIT (*Cost Image Term*) que tendrá valores cercanos a 0 donde no haya hueso y cercanos a 1 donde sí lo haya. Finalmente esta imagen de costes es minimizada haciendo uso del algoritmo de maximización de flujo propuesto por J. Yuan en [8]. El principal problema de este algoritmo es la computación de la distancia local de histograma para cada píxel de la imagen, requiriendo tiempos del orden de minutos para la segmentación de una sola imagen.

En la Tabla 1 se muestran los diferentes coeficientes (promedio) obtenidos para las 4 implementaciones.

	PPV	Sensibilidad	Especificidad	DICE	Tiempo Computacional
Umbralización	0,80	0,80	0,993	0,786	0,017s
DRLSE	0,54	0,94	0,889	0,603	3402s
Histograma+ MaxFlow	0,87	0,96	0,995	0,911	255s
Algoritmo Propuesto	0,93	0,90	0,998	0,911	0,823s

Tabla 1. Resultados obtenidos mediante los distintos algoritmos.

Como se puede observar, el método de umbralización es el que produce menores tiempos de computación debido a su sencillez, pero proporciona peores resultados de segmentación. El método DRLSE proporciona muy buenos resultados para imágenes compuestas por pocos huesos (piernas, brazos, etc), y malos resultados cuando hay muchas estructuras óseas, no siendo capaz de encontrarlas en muchas ocasiones. La Fig. 4 muestra los resultados obtenidos para 3 imágenes cuando se utiliza el método de Level Sets (en rojo) y el método descrito por nuestro algoritmo (en azul). Se puede comprobar cómo la implementación basada en Level Sets no es capaz de encontrar las estructuras cuando el número de ellas es elevado (ver figura derecha).




Figura 4. Comparación entre DRLSE (rojo) y el algoritmo propuesto (azul).

El método basado en Max-Flow proporciona muy buenos resultados, pero mayores tiempos de computación que el algoritmo propuesto. A la vista de los resultados queda demostrado claramente que el método más eficiente y el que proporciona tiempos de computación muy pequeños (tiempo inferior a 1 segundo por imagen) en comparación con DRLSE y MaxFlow es el propuesto en este trabajo.

4. Conclusiones

En este trabajo se presenta una técnica de segmentación automática de huesos en imágenes TAC sencilla y muy rápida que permite implementar la segmentación de volúmenes TAC en cuestión de pocos segundos. La técnica está basada en detección de bordes y análisis de regiones. Se ha llevado a cabo una comparación exhaustiva con otros métodos del estado del arte y los resultados obtenidos mediante el algoritmo propuesto son mejores en eficiencia y tiempo de cálculo. Aunque el número de imágenes utilizadas es pequeño (20 imágenes),

se ha evaluado el algoritmo con imágenes provenientes de distintas secciones del cuerpo y de distintos pacientes. En futuras implementaciones se evaluará el algoritmo con más imágenes.

El algoritmo presenta problemas cuando, debido a alguna enfermedad o artefacto en la imagen, los bordes son difusos. Sin embargo, el resto de los algoritmos con los que se ha comparado nuestra técnica también encontraban los mismos problemas. Hay que destacar el tiempo de computación, inferior a 1 segundo por imagen, muy inferior a los tiempos proporcionados por los algoritmos presentes en el estado del arte.

Agradecimientos

Este trabajo ha sido llevado a cabo gracias a los proyectos TEC2010-21619-C04-02 y P11-TIC-7727.

Referencias

- [1] Wang, L.I., Greenspan, M., Ellis, R.: Validation of bone segmentation and improved 3-D registration using contour coherency in CT data. *IEEE Transactions on Medical Imaging*. 25(3), 324–334 (2006)
- [2] Cheng, Y., Zhou, S., Wang, Y., Guo, C., Bai, J., Tamura, S.: Automatic segmentation technique for acetabulum and femoral head in CT images. *Pattern Recognition*. 46(11), 2969-2984 (2013)
- [3] Cervinka, T., Hyttinen, J., Sievnen, H.: Accurate cortical bone detection in peripheral quantitative computed tomography images. In: *IFMBE Proceedings*, pp. 289–292. (2014)
- [4] Aslan, M.S., Ali, A., Rara, H., Arnold, B., Farag, A.A., Fahmi, R., Xiang, P.: A novel 3D segmentation of vertebral bones from volumetric CT images using graph cuts. *Lecture Notes in Computer Science*. 5876 LNCS, 519-528 (2009)
- [5] Shadid, W., Willis, A.: Bone fragment segmentation from 3D CT imagery using the Probabilistic Watershed Transform. In: *Conference Proceedings - IEEE SOUTH-EASTCON* (2013)
- [6] Calder, J., Tahmasebi, A.M., Mansouri, A.-R.: A variational approach to bone segmentation in CT images. In: *Progress in Biomedical Optics and Imaging - Proceedings of SPIE* (2011)
- [7] Kratky, J., Kybic, J.: Three-dimensional segmentation of bones from CT and MRI using fast level sets. In: *Progress in Biomedical Optics and Imaging - Proceedings of SPIE* (2008)
- [8] Yuan, J., Bae, E., Tai, X.-C.: A study on continuous max-flow and min-cut approaches. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 2217–2224 (2010)
- [9] Li, C., Xu, C., Gui, C., Fox, M. D.: Distance Regularized Level Set Evolution and its Application to Image Segmentation. *IEEE Trans. Image Processing*, 19(12), 3243 – 3254 (2010)
- [10] Pérez-Carrasco, J.A., Acha, B. et al.: Statistical-based Segmentation of Bone Structures via Continuous Max-flow Optimizatio. Aceptado para ser presentado en ICIAR 2014 (International Conference on Image Analysis and Recognition), Vilamoura, Algarve, Portugal, Octubre 2014.