

SEGMENTACIÓN Y VISUALIZACIÓN ARTERIAL EN ARM Y TC

Juan F. Carrillo^{*/**}
Marcela Hernández Hoyos^{*}
Eduardo E. Dávila^{**}
Maciej Orkisz^{**}

PALABRAS CLAVE

Arterias, esqueleto, angiografía por resonancia magnética, tomografía

KEY WORDS

Arteries, skeleton, magnetic resonance, angiography, tomography

RESUMEN

Este artículo describe un método para la extracción automática de estructuras vasculares en imágenes médicas en 3D. El método utiliza un algoritmo iterativo que adiciona puntos al esqueleto del vaso y detecta bifurcaciones que analizan el contenido de una esfera que se mueve a lo largo de su línea central. En cada iteración se realiza una segmentación (extracción del vaso) local dentro de la esfera. Esta acción emplea un algoritmo de K-medias, que separa vaso y fondo utilizando métricas diferentes para cada grupo; adicionalmente, una medida del *cilindricidad*, basada en la comparación del volumen segmentado contra un modelo construido del vaso, se usa como el criterio de parada del algoritmo. El método fue aplicado a 16 ARM y a 12 TC 3D de diversas regiones anatómicas: arterias carótidas, árbol pulmonar, arterias coronarias y aorta. El algoritmo detectó y manejó eficientemente las bifurcaciones. Cada imagen fue procesada en menos de cinco minutos, lo cual es bastante rápido como para ser utilizada en una rutina clínica.

SUMMARY

This paper describes a method for automatic extraction of vascular structures in 3D medical images. The method uses an iterative algorithm which adds points to the vessel skeleton and detects bifurcations, by analyzing the contents of a sphere sliding along the vessel centerline. At each iteration, a local segmentation (vessel extraction) is performed within the sphere. The local segmentation uses a K-Means clustering algorithm that separates vessel from background by using different metrics for each cluster. Additionally, a "vesselness" measure, based on the comparison of the segmented volume against a constructed vessel model, is used as stopping criterion for the algorithm. The method was applied to 16 MRA and 12 CT 3D images of different anatomic regions: carotid arteries, pulmonary tree, coronary arteries and aorta. It efficiently detected and managed the bifurcations. Each image was processed in less than 5 minutes which is fast enough to be used in daily physician practice.

Introducción

Este trabajo se centra en la extracción y la visualización de estructuras tubulares ramificadas en imágenes vasculares en 3D: angiografías por resonancia magnética (ARM) y tomografías

computarizadas (TC). En la actualidad, la mayoría de las consolas de posttratamiento incluyen la visualización de estructuras vasculares, como imágenes de *maximum intensity projection* (MIP) e imágenes de *multiplanar reformatting* (MPR);

^{*} Grupo Imagine-Grupo de Ingeniería Biomédica, Ingeniería de Sistemas y Computación, Universidad de los Andes, Bogotá, Colombia.
^{**}CREATIS, Université Lyon 1, INSA-Lyon, CNRS UMR 5220, Inserm U630.

así como la visualización de superficie (*surface rendering*) y de volumen (*volume rendering*).

Estas dos últimas técnicas necesitan una intervención del usuario para definir umbrales (en el caso de la visualización de superficie) o color, opacidad y brillo de las estructuras que se van a visualizar (en el caso de la visualización de volumen). No obstante, estas técnicas presentan limitaciones en caso de una baja relación señal-ruido, bajo contraste y presencia de estructuras hiperdensas cercanas al vaso (calcificaciones, grasa, huesos o cavidades cardíacas en el caso de imágenes de arterias coronarias). El principal objetivo de nuestro trabajo es desarrollar un método fiable de extracción y visualización de arterias que trate las limitaciones descritas.

Se han propuesto diversos algoritmos para extraer la línea central o el eje del árbol vascular en imágenes 3D —véase (1-4) para la descripción—. La mayoría se basa en un modelo de segmentos vasculares cilíndricos y se diseña para extraer solamente un segmento a la vez, sin tener en cuenta las bifurcaciones. Otros detectan las bifurcaciones corriendo un algoritmo adicional a lo largo del eje extraído, que busca las zonas donde los datos no coinciden con el modelo cilíndrico (5). Alternativamente, varias ramas pueden ser extraídas a partir de diversos puntos de inicio, las cuales se conectan posteriormente (6).

Las líneas centrales de las arterias se pueden ver, a menudo, como picos de intensidad en la imagen, especialmente en ARM. En Yim y cols. (7), todos los posibles picos son inicialmente detectados por un algoritmo de crecimiento de regiones, y luego se calculan las conexiones entre los puntos extremos del eje, interactivamente seleccionados por el usuario. Un criterio basado en los valores propios de la matriz hessiana usaron Descoteaux y cols. (8) para determinar el flujo geométrico y encontrar así los caminos vasculares.

Sin embargo, los últimos dos métodos son costosos en tiempo de cómputo. Algunos algoritmos extraen los ejes a partir del volumen global o localmente presegmentado (9-12). Nuestro método agrega iterativamente puntos al eje y detecta bifurcaciones basándose en la información dentro de una célula esférica alrededor del punto actual. En cada iteración, se realiza una segmentación local de la imagen dentro de la célula actual, basada en la información fotométrica y geométrica de la imagen.

Método

La extracción de la línea central de la arteria es un proceso iterativo que trabaja sobre una pila de puntos candidato. El proceso comienza cuando se agrega a la pila un candidato, escogido manualmente por el usuario, y un radio estimado automáticamente por el sistema. Termina cuando no hay más candidatos para procesar en la pila.

Para cada candidato se define un volumen de interés (VOI) como una esfera centrada en dicho punto, dentro de la cual se lleva a cabo un procesamiento local. Dado un candidato tomado de la pila, el método determina si es necesario corregirlo. Si es el caso, se corrige y se regresa a la pila. Si el candidato no necesita ser corregido, se verifica la validez del criterio de *cilindricidad* en ese punto. Si no lo cumple, se descarta. En caso contrario, se agrega al *grafo* que representa el eje de árbol vascular. Luego se predicen varios candidatos y se regresan a la pila para ser procesados posteriormente (Fig. 1).

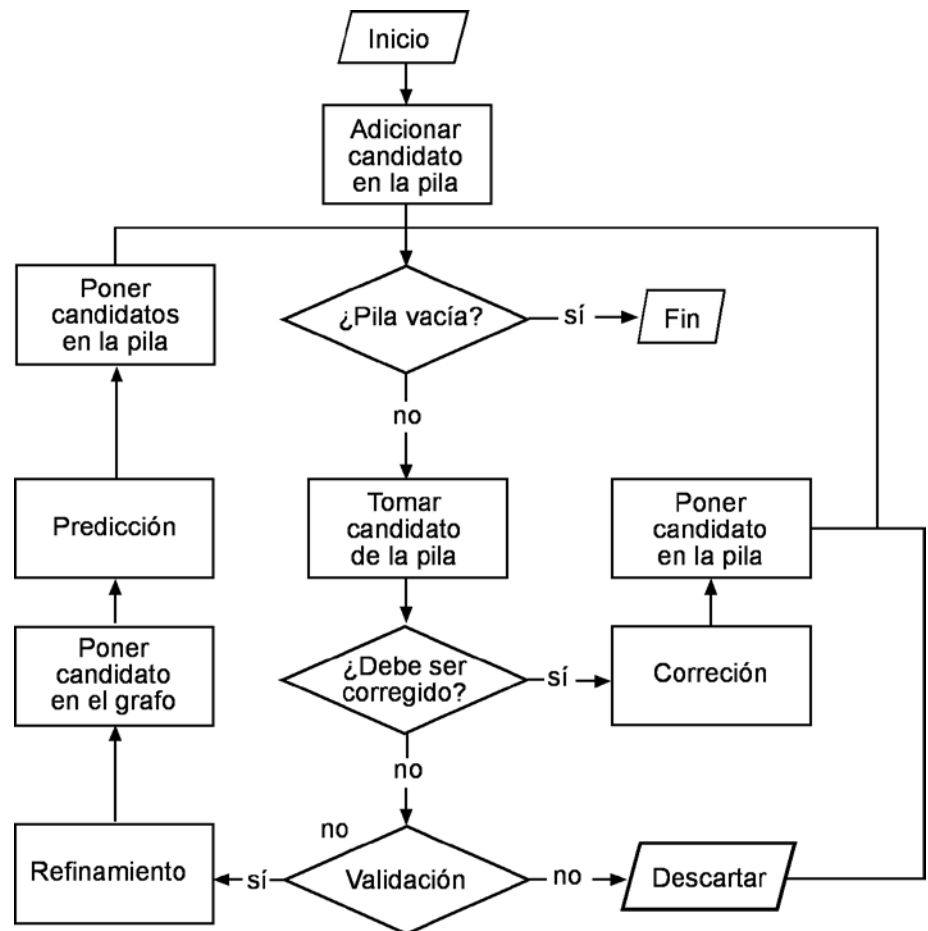


Fig. 1. Estructura del algoritmo.

Cada candidato está caracterizado por dos aspectos: (i) la ubicación espacial calculada del punto correspondiente del eje y (ii) el radio local calculado del vaso en ese punto. En el proceso de corrección, la ubicación o el radio pueden ser modificados.

En cada paso se fusiona el volumen de un vaso segmentado localmente al volumen total, que constituirá la segmentación final de la arteria (Fig. 2). Los principales pasos llevados a cabo por el algoritmo dentro del VOI son los siguientes (Fig. 3):



Fig. 2. Varias iteraciones de la segmentación del árbol vascular: ejes y unión de componentes volumétricos conexos

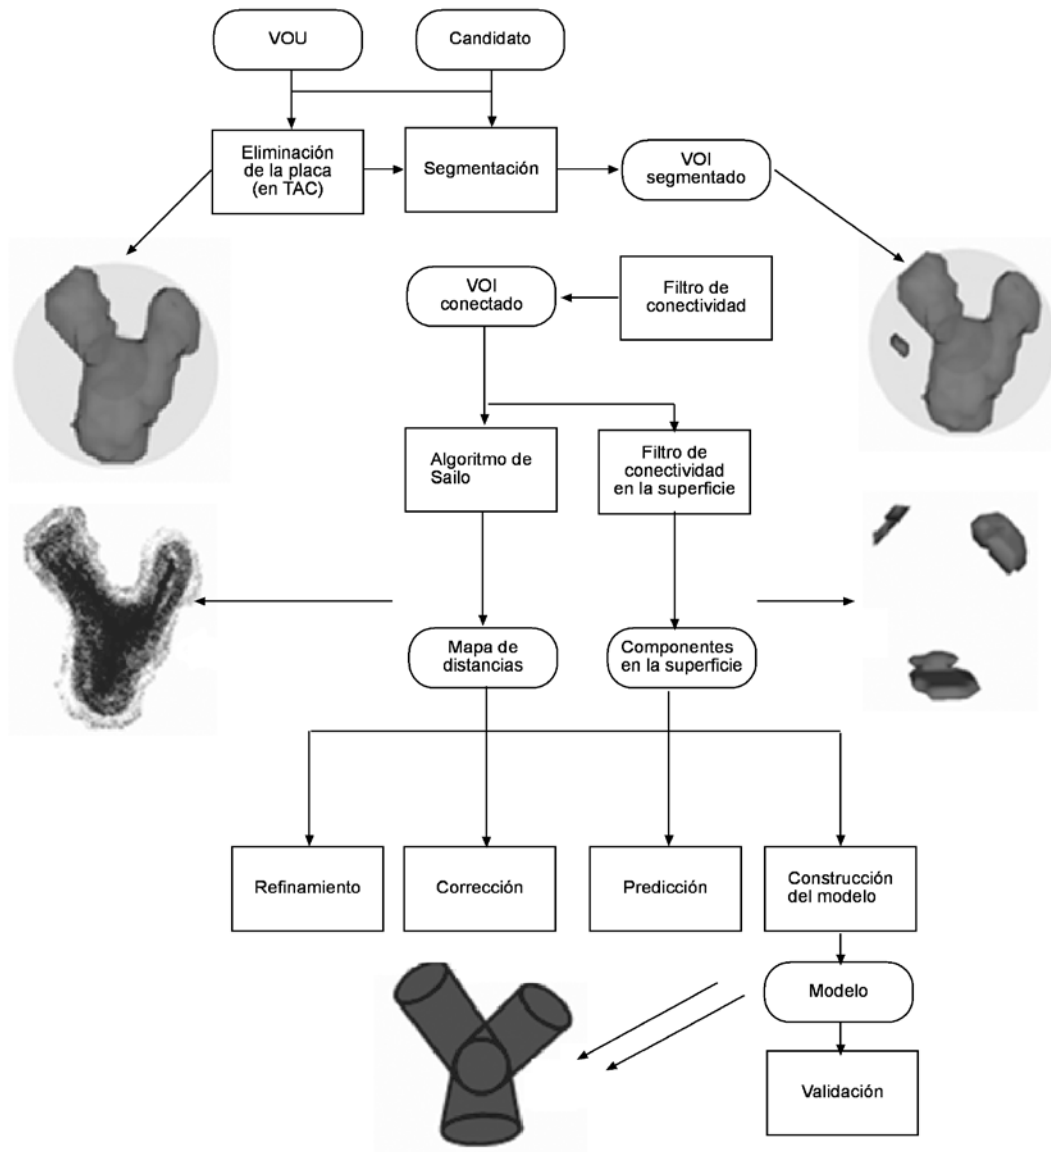


Fig. 3. Diagrama de flujo del procesamiento del VOI.

1. Segmentación local de la estructura vascular englobada en el VOI.
2. Predicción, corrección y validación de los puntos candidato del eje.
3. Refinamiento del eje.

Segmentación local de la estructura vascular

El propósito del método de segmentación es separar la imagen en dos grupos: vaso y fondo. El método se basa en el algoritmo de agrupamiento de *K-Means* (K-medias) (13). En este método, la imagen se interpreta como una *tupla* en cuatro

dimensiones: tres espaciales y la intensidad de la imagen como cuarta dimensión.

$$v = \langle x, y, z, f \rangle \tag{1}$$

La métrica de agrupación usada no es la misma para los dos grupos (Fig. 4):

- Grupo vaso: se utiliza la distancia desde el punto hasta el eje principal de inercia espacial del grupo.
- Grupo fondo: se emplea la distancia (D1) desde el punto hasta el hiperplano (P), paralelo al plano de intensidad (=0) que atraviesa el centroide del grupo.

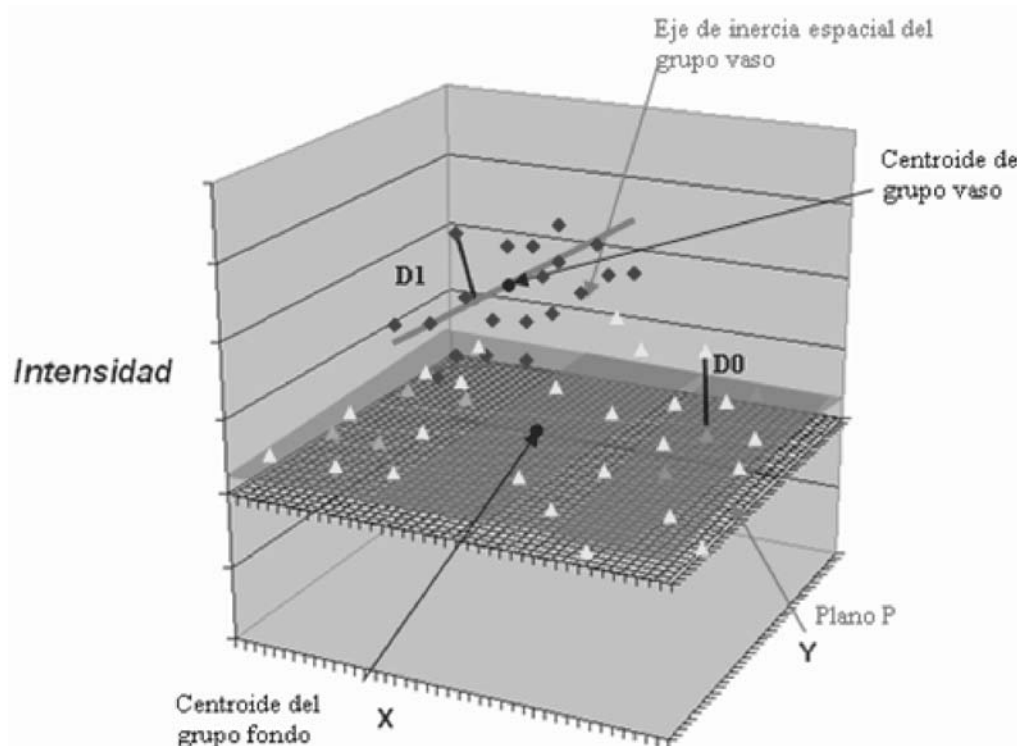


Fig. 4. La métrica seleccionada ilustrada en dimensiones espaciales.

El objetivo de la selección de estas métricas es incluir en el grupo vaso los *voxels* que están cerca al eje de inercia principal del grupo, incluso si no tienen alta densidad, y excluir aquellos que están lejos del eje, incluso si presentan alta densidad. Este criterio ayuda a la formación de formas cilíndricas en el espacio.

El algoritmo puede verse como una variación del método de selección de umbral óptimo de histogramas de Otsu (14). Este método es un caso especial de K-medias, en el cual la métrica seleccionada es la distancia al cuadrado desde el punto del centroide del grupo. En este caso, se considera una única dimensión: la intensidad de la imagen (N=1), y solamente se busca un umbral (K=2). El método de Otsu divide las imágenes en dos clases (vaso y fondo), mediante la minimización de la varianza intraclase:

$$\sigma_W^2 = \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2 \tag{2}$$

Y la maximización de la varianza interclases:

$$\sigma_B^2 = \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 \tag{3}$$

La varianza total es la suma de la varianza intraclase y de la varianza interclases:

$$\sigma_T^2 = \sigma_W^2 + \sigma_B^2 \tag{4}$$

Donde:

$\omega_0 =$ T0/M: la razón del número de puntos del grupo fondo sobre el número total de puntos.

$\omega_1 =$ T1/M: la razón del número de puntos del grupo vaso sobre el número total de puntos.

$\omega_0^2:$ la varianza del grupo fondo.

$\omega_1^2:$ la varianza del grupo vaso.

- σ_T^2 : la varianza total.
- μ_0 : el centroide del grupo fondo.
- μ_1 : el centroide del grupo vaso.
- μ_T : el centroide total.

El método de Otsu solamente considera la varianza fotométrica de las clases. Para incluir las características geométricas de la medida seleccionada es necesario agregar un término a la varianza intraclase que se va a minimizar:

$$\sigma_w^2 = \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2 + \varphi \omega_1 I_1^2 \quad (5)$$

Donde:

- I_1^2 : el momento de inercia alrededor del eje principal del grupo vaso.
- φ : el parámetro de selectividad.

El término de inercia es la suma del cuadrado de las distancias desde cada punto del grupo al eje de inercia principal del grupo. Dentro del VOI segmentado, el algoritmo descarta los voxeles no conexos al voxel central del VOI (Fig. 5). El método permite eliminar las estructuras hiperdensas cercanas al vaso, pero también podría eliminar las bifurcaciones. Esa es la razón por la cual debe agregarse el parámetro de selectividad, con el objetivo de controlar la influencia del término de inercia.

En la Figura 5 se ilustra el efecto de eliminación de estructuras en el proceso de extracción de un árbol coronario. Como se puede apreciar, el vaso está muy cerca de la cavidad cardiaca y con el método de Otsu el volumen segmentado incluye parte de la cavidad. Con el método desarrollado, el volumen segmentado no incluye la cavidad y preserva su tamaño.




Fig. 5 (a) Imagen dentro del VOI definido. (b) Volumen segmentado con el método de Otsu. (c) Volumen segmentado nuestro método.

Predicción de candidatos

El volumen segmentado toca la superficie del VOI esférico en varias áreas que forman los componentes conexos en la superficie (Fig. 6). Cada componente conexo en la superficie corresponde a una rama del vaso. Se espera que los puntos de la

línea central estén localizados dentro del volumen segmentado, tan lejos como sea posible de sus fronteras. Para esto se calcula un mapa de distancias, que asigna a cada voxel su distancia al borde del volumen segmentado más cercano.




Fig. 6 (a) Volumen segmentado dentro del VOI. (b) Componentes conexos de la superficie.

Ahora, es necesario escoger un punto dentro de cada componente conexo en la superficie. Para esto se hace una búsqueda 2D en la sección esférica, que corresponde a cada componente superficial. Son posibles dos enfoques para calcular la posición del candidato predicho: elegir el centro de gravedad del componente conexo en la superficie o elegir el punto con la distancia máxima al borde del volumen segmentado, que equivale al punto con el valor máximo en el mapa de distancias.

El máximo del mapa de distancias se usa en vez del centro de gravedad del componente conexo a la superficie, debido a que si la sección de dicho componente no es circular, su centro de gravedad podría estar cerca del borde. El radio candidato se predice como el radio del círculo máximo que puede ser incluido totalmente en la superficie del componente. Esto es, el valor del mapa de distancias en el punto predicho.

Corrección de candidatos

El proceso de predicción se basa en dos hipótesis: (i) el eje del vaso es perpendicular a la superficie del VOI esférico y (ii) cada sección de un componente conexo es aproximadamente circular. Cuando una de estas dos hipótesis no se cumple, la

posición y el radio del candidato predicho no son las reales. Entonces el candidato (posición y radio) debe corregirse con base en la información del VOI actual.

Para corregir la posición del candidato es necesario buscar el punto donde el valor del mapa de distancias sea máximo. Esta búsqueda se hace en un espacio 3D y está limitada, de modo que el candidato no se aleje demasiado del punto anterior. El radio del candidato predicho se aumenta si el volumen del vaso segmentado dentro del VOI es menor que el volumen de un cilindro perfecto incluido dentro de la esfera cuyo radio es igual a la mitad del radio de la esfera.

Validación de candidatos

Una vez calculado el volumen conexo, el mapa de distancias y los componentes conexos en la superficie, se verifica la similitud entre el volumen conexo y la forma cilíndrica de un segmento vascular por medio de un criterio de *cilindricidad*. Este criterio se basa en la comparación del volumen conexo (Fig. 7a) con un modelo del vaso construido (Fig. 7c) en la región esférica definida para el candidato actual. El modelo es la unión de varios volúmenes básicos (Fig. 7b).




Fig. 7. (a) Volumen conexo. (b) Construcción del modelo. (c) Modelo construido.

Primero, una esfera de radio igual al valor del mapa de distancias en el centro del VOI se posiciona en el centro de la región. Después, para cada componente conexo en la superficie se define un cono truncado, cuyo eje es la línea entre el punto del centro y el punto del candidato predicho para ese componente. Uno de estos radios es el radio de la esfera, calculado en el primer paso, y el otro radio es el radio del candidato predicho para ese componente. Una vez que se ha construido el modelo, se calculan cuatro valores:

- V1: número de voxeles que pertenecen al volumen conexo y al modelo.
- V2: número de voxeles que pertenecen al volumen conexo, pero que no pertenecen al modelo.
- V3: número de voxeles que no pertenecen al volumen conexo, pero pertenecen al modelo.
- V4: número de voxeles que no pertenecen ni al volumen conexo ni al modelo.

El candidato es aceptado si:

- $V1/(V1+V3) > \alpha$
- $V1/(V1+V2) > \beta$
- $(V1+V4)/(V1+V2+V3+V4) > \gamma$

α , β , γ se eligen con base en la experimentación.

Refinamiento

En pruebas preliminares se encontró un problema, debido al hecho de que para detectar bifurcaciones, la región analizada debe incluir totalmente el vaso. Los candidatos calculados quedan en la superficie de la esfera de VOI, lo cual significa que la distancia entre puntos puede ser muy grande y algunas veces la línea entre dos puntos no queda dentro del volumen segmentado (Fig. 9a).

La solución que se plantea para solucionar este problema es el cálculo de más puntos intermedios entre los puntos en la superficie de la esfera y el punto en su centro. Estos nuevos




Fig. 8. Aplicación del criterio de cilindridad.

puntos son calculados usando una implementación del algoritmo de camino de costo mínimo de Dijkstra. Como resultado se obtiene un eje que siempre pasa por volumen segmentado, pero que presenta una sinuosidad no deseada (Fig. 9b).

Esta sinuosidad es el resultado de calcular los puntos basándose en el mapa de distancias, de tal manera que estos siempre

se encuentran en el centro de un voxel. Para solucionar este problema el eje se procesa con un filtro pasabajas espacial que preserva las ubicaciones de las bifurcaciones. En la Figura 9c se puede ver el resultado del filtrado del eje. El eje final tiene una resolución menor al tamaño del voxel.




Fig. 9. Proceso de refinamiento.

Experimentos y resultados

Cuatro diferentes experimentos se realizaron para evaluar diversas características del algoritmo:

Experimento 1. Para evaluar la precisión del algoritmo. Este fue comparado cuantitativamente con un algoritmo de referencia (15-16), el cual ya había sido validado clínicamente. El algoritmo de referencia procesa un segmento vascular a la vez y fue concebido para trabajar solamente con imágenes ARM. Los dos algoritmos fueron aplicados en las mismas 16 imágenes de varias regiones anatómicas y comenzaron en el mismo punto y las distancias entre los ejes extraídos por los dos algoritmos fueron calculadas.

Experimento 2. Para evaluar la capacidad del algoritmo de extraer todas las ramas perceptibles en la imagen y evitar detecciones falsas. El algoritmo fue aplicado a 16 imágenes ARM y a 12 imágenes TC en 3D, de diversas regiones anatómicas. Sobre imágenes ARM, por medio de una inspección visual, el número de ramas extraídas fue comparado con el número de las ramas visibles en el volumen segmentado globalmente con un umbral igual al 25% de la intensidad máxima de la imagen. Para las imágenes TC el número de ramas extraídas fue comparado con el número de ramas perceptibles en los cortes nativos y en la vista MPR de la imagen.

Experimento 3. Para evaluar la capacidad de repetición del algoritmo. Este fue aplicado a la imagen ARM y a la imagen TC con el mayor número de ramas detectadas en la prueba anterior, cambiando el punto inicial.

Experimento 4. Para evaluar la sensibilidad del algoritmo a la variación del parámetro ϕ . El algoritmo fue aplicado a las mismas imágenes de la prueba anterior, pero varió el valor del parámetro ϕ entre 0 y 1 con un incremento de 0,1. En la Figura 10 presentamos tres resultados en diferentes regiones anatómicas.

El eje extraído por nuestro algoritmo está, en promedio, a una distancia menor que la mitad del tamaño del voxel con respecto al eje extraído por el algoritmo de referencia. Como el algoritmo de referencia no maneja bifurcaciones, el eje extraído cerca de estas zonas es altamente variable.

En el segundo experimento se encontraron 29 ramas faltantes de 147 posibles. Las razones principales en esta clase de imágenes eran estenosis graves, especialmente en las bifurcaciones. Se encontraron once ramas falsas en imágenes TC, mientras que no se encontró ninguna falsa en las imágenes de ARM.




Fig. 10. Resultado de la segmentación vascular (estructura opaca dentro de la imagen). De izquierda a derecha: (a) imagen aorto-iliaca, (b) imagen de arterias carótidas, (c) imagen de arterias cerebrales

En el tercer experimento, algunos casos especiales con ramas faltantes fueron encontrados en ARM y TC. Cuando el punto inicial seleccionado está en una rama secundaria con un diámetro muy pequeño con relación a la rama principal, el algoritmo no puede extraer el eje principal, porque la zona de la bifurcación no se valida como vaso.

En el cuarto experimento se encontró que para las imágenes ARM, variar el valor de parámetro no cambia mucho los resultados. Por el contrario, para las imágenes coronarias TC el algoritmo es sensible al valor de parámetro. Cuando el valor de parámetro es muy pequeño, las estructuras adyacentes no se eliminan, así que el número falsos positivos es mayor. Cuando el valor de parámetro es demasiado alto, las bifurcaciones se consideran estructuras adyacentes y se eliminan, de modo que el número de ramas faltantes es mayor. Los mejores resultados fueron encontrados para los valores entre 0,3 y 0,5.

Conclusión

Presentamos un algoritmo capaz de extraer el eje y la forma aproximada del lumen del árbol vascular. El algoritmo de extracción está basado en un método de segmentación desarrollado especialmente para eliminar las estructuras hiperdensas alrededor del vaso.

También fue propuesto un nuevo criterio de *cilindricidad*, basado en un modelo que tiene en cuenta las bifurcaciones y el tamaño variable del vaso. Según nuestra primera evaluación en imágenes de TC y de ARM, el algoritmo detecta y maneja eficientemente las bifurcaciones cuando las ramas secundarias tienen el tamaño y la intensidad similar a las ramas principales.

El algoritmo es más rápido que los de la referencia basados en el análisis de la matriz del hessiana. En general, cualquier imagen se puede procesar en menos de cinco minutos, que es bastante rápido como para ser utilizada en la rutina clínica.

Agradecimientos

Este trabajo se desarrolló con el apoyo del proyecto Colciencias 12040416468, del proyecto CIFI-UniAndes No. 24 y del proyecto ECOS Nord No. C07M04.

Referencias

1. Hernández Hoyos M, Orkisz M, Douek PC, Magnin IE. Assessment of carotid artery stenoses in 3D contrast-enhanced magnetic resonance angiography, based on improved generation of the centerline. *Mach Graphics Vision*. 2005;14(4):349-78.
2. Tizon X. Algorithms for the analysis of 3D magnetic resonance angiography images. Uppsala, Sweden: Acta Universitatis Agriculturae Sueciae; 2004.
3. Wink O. Vessel axis determination. Print Partner Ipskamp, Amsterdam: The Netherlands; 2004.
4. Kirbas C, Quek FKH. A review of vessel extraction techniques and algorithms. *ACM Comput Surv*. 2004;36(2): 81-121.
5. Toumoulin C, Boldak C, Dillenseger J-L, Coatrieux J-L, Rolland Y. Fast detection and characterization of vessels in very large data sets using geometrical moments. *IEEE Trans. Biomedical Engineering*. 2001;48(5):604-6.
6. Bullitt E, Aylward S, Smith K, Mukherji S, Jiroutek M, Muller K. Symbolic description of intracerebral vessels segmented from magnetic resonance angiograms and evaluation by comparison with X-ray angiograms. *Med Image Anal*. 2001;5(2):157-69.
7. Yim P J, Choyke PL, Summers RM. Gray-scale skeletonization of small vessels in magnetic resonance angiography. *IEEE Trans Med Imaging*. 2000;19(6):568-76.
8. Descoteaux M, Collins L, Siddiqi K. Geometric flows for segmenting vasculature in MRI: theory and validation. In: MICCAI'2004 —Med Image Computing and Computer Assisted Intervention—. Springer Verlag: Saint-Malo; 2004. p. 500-7.
9. Sauret V, Goatman KA, Fleming JS, Bailey AG. Semi-automated tabulation of the 3D topology and morphology of branching networks using CT: application to the airway tree. *Phys Med Biol*. 1999;44(7):1625-38.
10. Zahlten C, Jürgens H, Peitgen H-O. Reconstruction of branching blood vessel from CT data. In: Visualization in scient. Comput; 1994. p. 41-52.
11. Antiga L, Ene-Iordache B, Remuzzi G, Remuzzi A. Automatic generation of glomerular capillary topological organization. *Microvasc Res*. 2001;62(3):346-54.
12. Flasque N, Desvignes M, Constans J-M, Revenu M. Acquisition, segmentation and tracking of the cerebral vascular tree on 3D magnetic resonance angiography images. *Med Image Anal*. 2001;5(3):173-183.
13. MacQueen J. Some methods for classification and analysis of multivariate observations. In: LeCam LM, Neyman J, editors. Fifth Berkeley Symposium on Math. Stat. and Prob. Berkeley: University of California Press; 1967. p. 281-97.
14. Otsu N. A threshold selection method from gray-level histograms. *IEEE Trans Systems, Man and Cybernetics*. 1979;9(1):63-6.
15. Hernández Hoyos M, Serfaty JM, Maghiar A, Mansard C, Orkisz M, Magnin IE, et al. Evaluation of semi-automatic arterial stenosis quantification. *Int J Comp Assisted Radiol Surg*. 2006;1(3):167-75.
16. Saito T, Toriwaki JI. New algorithms for Euclidean distance transformations of an n-dimensional digitized picture with applications. *Pattern Recognit*. 1994;27(11):1551-65.

Correspondencia

Marcela Hernández Hoyos
Universidad de los Andes
Carrera 1a. No. 18A-10, Bogotá, Colombia
marc-her@uniandes.edu.co

Recibido para evaluación: 9 de octubre de 2006

Aceptado para publicación: 17 de noviembre de 2006