

Segmentación automática de aneurismas aórticos abdominales a partir de imágenes de resonancia magnética basada en Modelos Activos de Forma y Modelos de Textura.

J. Tarjuelo Gutiérrez^{1,2}, B. Rodríguez Vila^{1,2}, E.J. Gómez Aguilera^{1,2}

¹ Grupo de Bioingeniería y Telemedicina, ETSI de Telecomunicación, Universidad Politécnica de Madrid, Madrid, España, {jtarjuelo,brvila,egomez}@gbt.tfo.upm.es

² Centro de Investigación Biomédica en Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN), España

Resumen

Se presenta un algoritmo semiautomático de segmentación de aneurismas aórticos abdominales (AAA) basado en modelos activos de forma (ASM) y modelos de textura. La información de textura viene dada por un conjunto de cuatro imágenes 3D de resonancia magnética (RM) compuestas por cortes axiales de la zona abdominal. En estas imágenes son visibles la luz aórtica, la pared aórtica y el trombo intraluminal (ILT). Dado el tamaño limitado del conjunto de imágenes de RM, se han implementado un ASM que capture las características específicas del conjunto de entrenamiento compuesto por 35 imágenes de tomografía axial computarizada (CTA), de modo que la variación de forma pueda ser adecuadamente caracterizada. La textura se caracteriza a partir de las imágenes de RM. Para la evaluación del algoritmo se ha llevado a cabo una validación cruzada dejando uno fuera sobre el conjunto de imágenes de RM.

1. Introducción

Un aneurisma aórtico es una dilatación localizada de la aorta y puede encontrarse en cualquier parte de la misma, siendo el más común el aneurisma aórtico abdominal (AAA) [1]. En algunos casos es posible que la sangre se estanque en la dilatación, induciendo la formación de un trombo intraluminal (ILT) [2]. De este modo, se pueden distinguir tres estructuras en un AAA: luz aórtica, pared aórtica e ILT.

La mayoría de publicaciones sobre la segmentación automática de AAA se centran en la segmentación de la luz en imágenes con contraste. En los últimos años varios autores han propuesto métodos para segmentar la pared aórtica. Subasic et al propone una técnica basada en el método de contornos activos y otra aproximación basada en modelos 3D deformables y level sets [3-4], utilizando imágenes de angiografía por tomografía computarizada (CTA). de Bruijne et al utiliza técnicas de segmentación basadas en modelos usando imágenes tanto de CTA como de RM [5-6].

El objetivo pues es construir un algoritmo automático para segmentar las tres estructuras de interés de manera independiente. La luz se segmenta utilizando imágenes de RM con contraste. La cara interna de la pared se segmenta utilizando modelos activos de forma (ASM) y un modelo de textura personalizado. Se realiza un inflado de la misma para segmentar la cara externa de la pared. El ILT es el espacio existente entre las segmentaciones de la luz y de la cara interna de la pared. Estas segmentaciones se

utilizan para construir un modelo de la anatomía aórtica, específico para cada paciente y que distinga entre las diferentes estructuras de interés presentes, con el fin de aplicarlo al guiado de catéteres en el tratamiento de AAA.

2. Metodología

El modelo específico de paciente se construye a partir de imágenes 3D compuestas de cortes axiales del abdomen, donde son visibles la luz, la pared y el ILT. La luz se segmenta a partir de imágenes de RM con contraste de manera semiautomática utilizando level sets basados en intensidad. La pared y el trombo se segmentan utilizando imágenes de RM sin contraste del mismo paciente. El registro entre las imágenes (con contraste y sin contraste) de un mismo paciente permite situar la segmentación de la luz sobre la imagen sin contraste, de modo que sirva para la inicialización de la segmentación semiautomática de la pared aórtica y del ILT al establecer las landmarks iniciales, siendo capaz de distinguir entre ambas estructuras.

Cuando se segmentan estructuras anatómicas es común tratar con estructuras variables y complejas. En la zona abdominal se encuentran una gran variedad de tejidos diferentes que se solapan y son difícilmente distinguibles en las imágenes médicas. Los métodos basados en modelos ofrecen soluciones a estas dificultades usando información *a priori* del problema. El esquema original del ASM fue propuesto por Cootes y Taylor [7]. La idea principal es generar modelos que representen de manera realista las variaciones “legales” que puedan ocurrir entre las diferentes formas de una misma estructura, tanto intra como inter paciente.

La razón principal para la elección de imágenes de RM es que estas imágenes permiten distinguir entre las estructuras de interés, como se muestra en la Fig. 1. Otras ventajas de RM sobre CTA son: la ausencia de radiación ionizante y agentes de contraste nefrotóxicos, una sensibilidad aumentada a las fugas y un contraste mejorado en tejido blando, lo que permite evaluar la consistencia del trombo [8]. Aunque el AAA puede encontrarse también situado en las arterias iliacas, por el momento en este trabajo se utilizarán estudios que comienzan en la bifurcación entre la aorta y las iliacas. El diagrama de flujo de la Fig. 2 muestra una visión global del proceso.




Figura 1. Corte de una imagen de RM obtenida de modo que se distinguen la luz, el ILT y la pared.

2.1. Entrenamiento de los modelos de forma y textura de la pared aórtica

Con el fin de segmentar la pared de manera automática se utiliza una aproximación basada en modelos. En particular se ha decidido usar ASM y un modelo de textura personalizado.

1) Modelos activos de forma

Para construir un ASM es necesario definir un conjunto de entrenamiento formado por N imágenes volumétricas segmentadas manualmente. La forma más simple y genérica para representar las formas del conjunto de entrenamiento es mediante un conjunto de puntos distribuidos a lo largo de la superficie de la forma. Estos puntos se denominan landmarks y sus coordenadas, concatenadas en un vector x describen las formas.

Las variaciones entre las formas del conjunto de entrenamiento se describen utilizando un modelo de distribución de puntos (PDM). El modelo de forma se utiliza para generar nuevas formas, similares a las que conforman el conjunto de entrenamiento y caracterizar las variaciones permitidas.

a. Alineamiento

El primer paso consiste en alinear las formas mediante un proceso de traslación, rotación y escalado, de modo que queden representadas en un mismo sistema de coordenadas. Cada forma del conjunto se coloca de modo que el centroide de la estructura interna de la pared (luz e ILT donde éste esté presente) se sitúe en la coordenada física (0,0,0).

b. Selección de los modos de variación

Una vez alineado el conjunto, el siguiente paso es encontrar los modos de variación que mejor describan la variabilidad presente en el mismo. Para ello se utiliza el análisis de componentes principales (PCA) [9] para capturar los estadísticos del conjunto. La idea básica del PCA es establecer, a partir del conjunto de entrenamiento, un patrón de variaciones “legales” entre las formas. Sin embargo, una de las principales restricciones es la necesidad de establecer una correspondencia entre puntos de distintas formas. Se calcula la forma media del conjunto y se obtiene la matriz de covarianza. Los modos principales de variación se obtienen como la solución del autosistema derivado de dicha matriz (Eq. 2), donde S es la matriz de covarianza, ϕ_k son los autovectores y λ_k son los autovalores.

Los autovectores representan los modos de variación, y los autovalores determinan la cantidad de variación por modo. Si x contiene los t autovectores correspondientes a los mayores autovalores, cada forma del conjunto de entrenamiento x puede ser aproximada mediante

donde b es un vector que define un conjunto de parámetros de un modelo deformable y viene dado por

Con el fin de generar formas plausibles, se debe restringir b en un hiperelipsoide (Eq. 5), donde el umbral ϵ se elige usando la distribución

c. Aumento de variaciones

La cantidad de datos disponible para el entrenamiento es un factor clave para la robustez de un modelo estadístico. En este caso se trabaja con imágenes 3D, cuya cantidad es habitualmente muy baja, debido a que rara vez se dispone de suficientes imágenes para conformar el conjunto de entrenamiento, además del hecho de que deben ser segmentadas manualmente, lo cual consume mucho tiempo. Esto se traduce en modelos sobre-restringidos que no representan a los datos de manera precisa. Con el fin de aumentar la flexibilidad del modelo, se ha seguido la estrategia de PDM extendido presentada por de Bruijne et al [9], que propone aumentar la flexibilidad del modelo de forma para objetos tubulares modelando independientemente los ejes y las secciones transversales, lo que mejora la capacidad del modelo de generalizar formas desconocidas. En el caso de este trabajo, se utiliza únicamente el modelo transversal, que caracteriza el inflado y desinflado del aneurisma, puesto que al estar el proceso de segmentación de la pared y el trombo inicializado por la luz, siguen las variaciones de la línea central, por lo que el modelo del eje no aporta información adicional y no presenta mejoras significativas en los resultados.

2) Modelos de textura

Como se ha mencionado, el conjunto de entrenamiento de imágenes de RM disponible es muy reducido. Por esta razón, no es posible aplicar los modelos activos de apariencia (AAM) estándar propuestos por Cootes y Taylor [10] debido a que no se dispone de suficientes datos para construir un modelo de textura robusto a partir de las imágenes de entrenamiento.

Bailleul et al [11] proponen otra aproximación a este problema, en la cual se basa la solución llevada a cabo en este trabajo. Esta técnica consiste en extraer las características de intensidad de los bordes de las imágenes del conjunto de entrenamiento en las áreas alrededor de las estructuras de interés. Se ha definido una región característica de 5x5 píxeles en un mismo corte alrededor de una landmark.

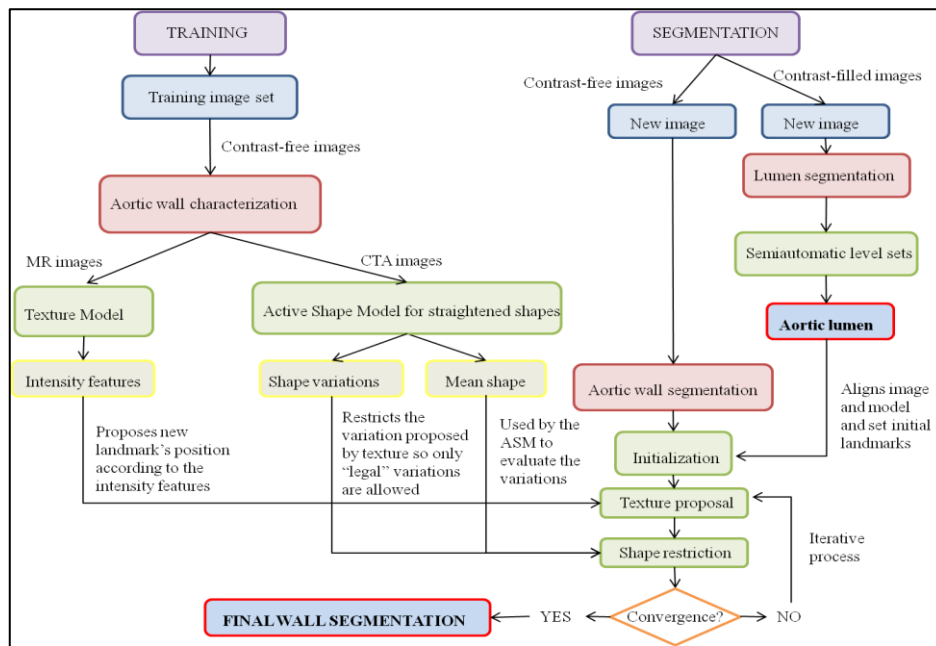


Figura 2. Diagrama de flujo de los procesos de entrenamiento de modelos y de segmentación.

El algoritmo debe distinguir entre píxeles internos (correspondientes a las estructuras que quedan envueltas por la pared aórtica) y externos (que corresponden a la misma pared y las estructuras externas adyacentes). Los píxeles de esta región se clasifican de acuerdo con la distancia de referencia, que se define como la distancia entre el centroide de la estructura interna y la landmark. Las características de intensidad se obtienen de manera separada para los píxeles interiores (g_{int}) y exteriores (g_{ext}), ya que es la diferencia entre ellas la que caracteriza la intensidad de las estructuras de interés. Los estadísticos se han elegido de manera empírica, y son:

- Diferencia de las medias Interior/Exterior:
- Diferencia de los mínimos Interior/Exterior:
- Diferencia Landmark/Mínimo exterior:
- Desviación típica externa:
- Diferencia de desviación típica Externa/Interna:

Con el fin de poder combinar los diferentes estadísticos, éstos se deben normalizar. Se han definido los estadísticos de modo que la maximización de su suma indica la mejor posición para la landmark actual.

2.2. Proceso de segmentación de nuevas imágenes

1) Segmentación de la luz

La segmentación de la luz se lleva a cabo utilizando imágenes de RM con contraste del paciente. El inconveniente de usar imágenes con contraste es que éste

enmascara las estructuras adyacentes a la luz. La segmentación es un proceso semi-automático puesto que el método utilizado, consistente en level sets basados en intensidad [12], requiere situar una semilla (o varias) sobre la estructura de interés para su inicialización. Esta segmentación provee una serie de landmarks que se utilizan para inicializar la segmentación de la pared.

2) Aplicación del modelo

Una vez que se han construido los modelos de forma y de textura, se pueden aplicar a una imagen nueva. A partir de la segmentación de la luz de la arteria se obtiene el centroide de la luz en el corte de la bifurcación, punto con el cual se realiza un alineamiento inicial. Mediante el registro de ambas imágenes, se superponen las landmarks de la luz sobre la imagen sin contraste sobre la que se realiza el proceso de segmentación de la pared y el trombo y se definen regiones de 5x5 píxeles en torno a cada una de ellas. Cada punto de esta región es candidato a ser la mejor posición de esa landmark. Se obtiene el valor de textura de cada punto de la región del mismo modo que en la fase de entrenamiento. El modelo de textura propone entonces como nueva posición de la landmark el punto de la región que tenga una suma de estadísticos mayor. Cuando el modelo de textura ha hecho su propuesta para todas las landmarks, se estiran las formas para que sólo influya la dilatación de la aorta, y el modelo de forma restringe el movimiento global de todas ellas de modo que sus variaciones de posición sean consideradas “legales”. Si las variaciones son aprobadas por el ASM, no se produce modificación alguna. En caso contrario el ASM establece las landmarks en las posiciones “legales” más cercanas a las propuestas por el modelo de textura (eq. 5). Las formas se devuelven a su posición original. Este es un proceso iterativo y converge cuando el modelo de textura no propone variación en las posiciones de las landmarks, o esas variaciones se consideran despreciables.

3. Resultados y discusión

Se han llevado a cabo experimentos validación cruzada dejando uno fuera (leave-one-out) sobre un conjunto de 4 imágenes de RM con el cual se han caracterizado las variaciones de textura. Debido al reducido tamaño de este conjunto de entrenamiento se ha utilizado otro conjunto de 35 imágenes CTA para modelar las variaciones de forma (no de textura) para representar una mayor cantidad de posibles aneurismas. El número de modos de variación significativos para las formas estiradas es de 5. La Fig. 3 muestra los dos principales modos de variación de las formas estiradas entre $\bar{\mu}$, donde μ es el autovalor asociado al autovector que determina la variación.




Figura 3. Dos principales modos de variación del ASM estirado de un AAA variando entre $\bar{\mu}$.

Los resultados de la primera iteración del algoritmo se presentan en la Fig. 4. Las posiciones iniciales se muestran a la izquierda, las propuestas de textura en el centro, y las restricciones del ASM a la derecha. Como se puede observar, las posiciones iniciales no están posicionadas exactamente en el contorno de la luz ya que la imagen con contraste y la imagen sin contraste no se registran perfectamente. El modelo de textura propone mejores posiciones para las landmarks, situándolas en la cara interna de la pared, y el ASM restringe la forma, evitando las variaciones ilegales.




Figura 4. Posiciones iniciales (izquierda), propuestas de textura (centro) y restricciones del ASM (derecha) en la primera iteración.

A pesar de que el conjunto de imágenes disponible es muy reducido, los resultados iniciales, aunque preliminares y susceptibles de mejora parecen prometedores y la segmentación de la cara interna de la pared parece abordable.

4. Conclusiones y trabajos futuros

Se propone un algoritmo semiautomático de segmentación para AAA basado en ASM y modelos de textura. La textura de las imágenes de entrenamiento se caracteriza mediante un conjunto de estadísticos que se

obtienen de la observación empírica de las estructuras de interés. Posteriormente las variaciones se restringen según el ASM. Se han llevado a cabo experimentos de validación cruzada dejando uno fuera. Los resultados presentados son preliminares y se sigue trabajando en la mejora del algoritmo y la ampliación del conjunto de entrenamiento de imágenes de RM con el fin de realizar una validación más amplia y robusta. Los trabajos futuros van en este sentido y pretenden evaluar el proceso global de segmentación y segmentar la cara externa de la pared.

Agradecimientos

Este trabajo está parcialmente financiado por el proyecto SCATh FP7-ICT-2009-4-248782. Los autores agradecen al Dr. Peter Verbrugge del Hospital Universitario de Lovaina (Bélgica) por proporcionar las imágenes de RM.

Referencias

- [1] Fauci AS, Braunwald E, Kasper DL, Hauser SL, Longo DL, and Jameson JL. J. Loscalzo. Harrison's Manual of Medicine, 17th ed., McGrawHil, 2009.
- [2] Gloviczki P, and Ricotta JJ. Aneurysmal vascular disease, In: Townsend CM, Beauchamp RD, Evers BM, Mattox KL, eds. Sabiston Textbook of Surgery. 18th ed., Philadelphia, 2007.
- [3] Subasic M, Kovacevic D, and Loncaric S. Segmentation of abdominal aortic aneurysm using deformable models, *Technical report*, Faculty of Electrical Engineering and Computing, University of Zagreb, 2000.
- [4] Subasic M, Loncaric S, and Sorantin E. 3D image analysis of abdominal aortic aneurysm, In: *Sonka, M., Fitzpatrick, M. (eds.) Medical Imaging: Image Processing, Proceedings of SPIE*, vol. 4684, 2002, pp. 1681–1689. SPIE Press, Bellingham.
- [5] de Bruijne M, van Ginneken B, Niessen WJ, Loog M, and Viergever MA. Model-based segmentation of abdominal aortic aneurysms in CTA images, In: *Proc. SPIE Med. Imaging*, vol. 5032, 2003, pp. 1560–1571.
- [6] de Bruijne M, van Ginneken B, Bartles L, van der Laan M, Blankensteijn JD, Neissen WJ, and Veirgever M. Automated segmentation of abdominal aortic aneurysms in multi-spectral MR images, *Proc. MICCAI*, vol. 2879, 2003, pp.538 - 545.
- [7] Cootes TF, Taylor CJ, Cooper DH, and Graham J. Active shape models—their training and application, *Computer Vision and Image Understanding*, vol 61(1), 1995, pp.38–59.
- [8] Haulon S, Lions C, McFadden E, Koussa M, Gaxotte V, Halna P, and Beregi J. Prospective evaluation of magnetic resonance imaging after endovascular treatment of infrarenal aortic aneurysms, *European Journal of Vascular and Endovascular Surgery*, vol 22(1), 2001, pp. 62–69.
- [9] de Bruijne M, van Ginneken B, Viergever MA, and Niessen WJ. Adapting active shape models for 3D segmentation of tubular structures in medical images, In: *Taylor, C.J., Noble, J.A. (eds.) IPMI 2003. LNCS*, vol. 2732, 2003, pp. 136–147.
- [10] Cootes TF, and Taylor C. Statistical models of appearance for computer vision, *Tech. rep., University of Manchester, Wolfson Image Analysis Unit, Imaging Science and Biomedical Engineering, Manchester M13 9PT, United Kingdom*. 2004.
- [11] Bailleul J, Ruan S, Bloyet D, and Romaniuk B. Segmentation of anatomical structures from 3D brain MRI using anatomically-built statistical shape models, *Proc. ICIP*, vol 4, 2004, pp. 2741–2744.
- [12] Yushkevich PA, Piven J, Cody H, Gee S, and Gerig JC. User-Guided Level Set Segmentation of Anatomical Structures with ITK-Snap, *Insight J. and Proc. ISC/NAMIC/MICCAI Workshop Open-Source Software*. 2005.