

Un enfoque integrado de segmentación para extracción de superficies en imágenes digitales 3D

Mariana del Fresno¹, Marcelo Vénere^{1,2}, Alejandro Clausse^{1,2,3}

¹ Universidad Nacional del Centro, Pinto 399, Tandil, Argentina

² CNEA

³ CONICET

mdelfres@exa.unicen.edu.ar

Abstract

This paper describes an efficient novel strategy for the segmentation of surfaces contained in 3D images, based on deformable models or “snakes”. The proposed method starts by determining a rough but robust approximation of the objects of interest using the results of a region-growing algorithm. Then, the closed surface mesh that encloses the region is constructed and used as the initial geometry of a deformable model for the final refinement. This integrated strategy provides an alternative solution to one of the flaws of traditional deformable models, achieving good refinements of internal surfaces in few steps and times much reasonable than the reported by others authors. Experimental segmentation results of complex structures on both simulated and real data are presented, and the method is assessed by comparing with standard reference segmentations. The obtained results show that the approach achieves high quality segmentations with low computational complexity.

Keywords: Signal processing, 3D image segmentation, surface visualization.

Resumen

En este trabajo se describe una estrategia eficiente y novedosa para la segmentación de superficies contenidas en imágenes digitales 3D, basada en modelos deformables o “snakes”. El método propone una inicialización aproximada pero robusta de los objetos de interés a partir del resultado de un algoritmo de crecimiento de regiones. Luego, se construye una malla de superficie cerrada que contiene a la región, la cual se usa como la geometría inicial de un modelo deformable para el refinamiento final. Esta estrategia integrada provee una alternativa de solución a una de las falencias de los modelos deformables tradicionales, logrando refinar la superficie en pocos pasos y en tiempos más razonables que los reportados por otros autores. Se presentan resultados experimentales de segmentación de estructuras complejas, validando los resultados por comparación con segmentaciones de referencia. Los resultados obtenidos muestran que el enfoque es capaz de lograr segmentaciones de alta calidad con bajo costo computacional.

Palabras clave: Procesamiento de señales, segmentación de imágenes 3D, visualización de superficies.

1. Introducción

La segmentación es un proceso fundamental en el análisis de imágenes, el cual ha sido ampliamente estudiado en la literatura y diferentes técnicas han sido propuestas [1]. En general, los métodos se basan en propiedades locales de la imagen, particularmente en características de discontinuidad y similitud. Los métodos basados en discontinuidad se conocen como métodos basados en bordes, mientras que los basados en alguna propiedad de similitud son los basados en regiones.

Los métodos basados en bordes se orientan a la búsqueda de las fronteras entre regiones de la imagen, por medio de la detección de discontinuidades abruptas de niveles de gris y requieren en general de un proceso de conexión posterior de los bordes resultantes para obtener regiones cerradas [2]. Estos métodos trabajan bien en datos con buen contraste, pero son altamente sensibles al ruido y variación de intensidades, sobre todo en la transición entre objetos, lo que comúnmente se presenta en el caso de estudios médicos por ejemplo.

Los algoritmos de crecimiento de regiones (RG) [3], básicamente se orientan a la búsqueda de regiones homogéneas y operan uniendo los elementos próximos de la imagen que satisfacen un criterio dado de homogeneidad, a partir de un conjunto inicial de puntos. Este enfoque ofrece varias ventajas sobre otras técnicas convencionales. En lugar de identificar bordes, estos métodos trabajan siempre sobre regiones cerradas en cada paso del algoritmo y así se evita la aplicación de algún post-procesamiento para recuperar los límites de los objetos. El algoritmo resulta generalmente más estable con respecto al ruido y además el criterio de homogeneidad puede estar basado en múltiples condiciones sobre las características de los datos de la imagen, permitiendo eventualmente la incorporación de información a priori sobre la imagen y las estructuras a ser segmentadas.

Por otro lado, también se han propuesto algoritmos híbridos que tratan de combinar diferentes métodos. Particularmente, considerando la naturaleza complementaria de la información basada en bordes y en regiones, es posible integrar ambos tipos de criterios con el fin de obtener resultados de mayor precisión que cuando ambos son aplicados individualmente [4-6]. Esto es especialmente importante en el caso de imágenes médicas donde la segmentación es considerada por lo general un problema complejo, principalmente debido al ruido, variación y superposición de intensidades, complejidad de las estructuras anatómicas, etc.

En numerosas aplicaciones de procesamiento de imágenes se requiere la detección de subestructuras presentes en la imagen y la consecuente extracción de representaciones geométricas de las superficies asociadas. El enfoque más popular consiste en usar algoritmos de *marching cubes* [7], los cuales son rápidos y capaces de detectar correctamente los límites de superficies bien definidas. Sin embargo, no siempre garantizan la creación de superficies cerradas y pueden presentar dificultades al procesar estructuras complejas o ruidosas, pudiendo generar errores topológicos tales como pequeños ganchos (*handles*) en la iso-superficie calculada [8,9].

Un enfoque alternativo de segmentación orientado a la detección de contornos es provisto por los modelos deformables, los cuales se basan en la evolución de una curva (en 2D) o superficie (en 3D), que es forzada a evolucionar atraída por los bordes de la región a través de la minimización de funciones de energía apropiadas [10]. Contrariamente a los métodos basados en voxels, estos modelos pueden ser aplicados sobre el dominio continuo, logrando representaciones geométricas suaves, con una precisión subpixel o subvoxel, según la dimensión de la imagen. Sin embargo, la principal limitación de los modelos deformables tradicionales es su dependencia respecto de su inicialización, la cual debe ser suficientemente cercana a la solución final a fin de lograr resultados satisfactorios. Por esta razón, los modelos deformables suelen fallar al segmentar objetos 3D con estructuras complejas, perdiendo detalles de la superficie las cuales pueden resultar demasiado suavizadas. Con el fin de abordar esta limitación, se han planteado diferentes enfoques para la inicialización de modelos deformables [8,9, 11,12], aunque el problema sigue en investigación.

En este trabajo se propone una metodología para la detección y generación de superficies contenidas en imágenes digitales 3D, basada en la integración de algoritmos RG y modelos deformables. El procedimiento implementa una estrategia de crecimiento en dos pasos, utilizando información sobre regiones y bordes, para generar una entrada apropiada al modelo de snakes. Este enfoque sigue la tendencia reciente a la construcción de esquemas híbridos tomando los aspectos ventajosos de las diferentes técnicas de segmentación [5].

2. Segmentación inicial mediante crecimiento de regiones

La entrada al algoritmo de segmentación consiste de una imagen digital tridimensional (3D), considerada como un campo de intensidad $I(x,y,z)$ definido en un espacio discretizado de voxels, $v=(x,y,z)$, los cuales se asocian con valores de intensidad de acuerdo a la modalidad de imagen considerada y a la técnica utilizada para su adquisición.

Como se mencionó anteriormente, el enfoque basado en RG proporciona una opción flexible y poderosa de segmentación que permite la detección de regiones de interés, a partir de uno o más puntos iniciales (conocidos como semillas) dentro de cada región. Si bien se han propuesto algunas estrategias para definir semillas automáticamente [4,12], la práctica generalizada involucra la intervención directa del usuario experto [13], la cual en este trabajo se propone guiada por herramientas gráficas para facilitar la exploración de la imagen. Típicamente, se requiere la especificación de varias semillas dentro de cada región, especialmente cuando los objetos poseen formas complejas o amplio contraste de intensidades. A partir de cada uno de estos puntos, el proceso de crecimiento incorpora los voxels adyacentes a la región, hasta que no existen puntos que satisfagan el criterio de similitud establecido. La salida del algoritmo consiste en conjuntos de voxels conectados que representan las regiones de interés detectadas.

En general, los algoritmos RG resultan apropiados para la segmentación de estructuras volumétricas complejas, como las que pueden presentarse en imágenes médicas. A fin de utilizar la información completa de la imagen y obtener segmentaciones más precisas, es conveniente entonces aplicar el algoritmo de segmentación directamente sobre la estructura tridimensional, debido a que los voxels de una misma región pueden estar desconectados en un corte de la imagen 3D mientras se mantienen vinculados a través de cortes adyacentes del volumen. Este enfoque ha mostrado resultados satisfactorios en la segmentación de vasos sanguíneos en MRA, en la derivación de modelos de estructuras vasculares en datos radiológicos o en CTA, en la detección y visualización de bronquios, detección de cerebro en MRI [14], entre otros numerosos trabajos.

2.1 Primera etapa de crecimiento

El criterio de similitud usado en la primera etapa se basa en la comparación de intensidades de voxels. Este criterio debe ser aplicado con cierta tolerancia, debido a que comúnmente puede presentarse cierto ruido o heterogeneidades en imágenes reales.

Considerando a $S(r)$ como el conjunto de todos los voxels en el entorno- r de cualquiera de las semillas definidas en una región dada, la intensidad característica $IC(r)$ y el desvío característico $\sigma(r)$ de la región se pueden calcular como:

$$IC(r) = \frac{1}{N(r)} \sum_{v \in S(r)} I(v) \quad \sigma(r) = \frac{1}{N(r)} \sqrt{\sum_{v \in S(r)} [I(v) - IC(r)]^2} \quad (1)$$

donde $N(r)$ es la cantidad de voxels en $S(r)$. El entorno- r de cada semilla s se toma como el conjunto de todos los puntos dentro de un cubo de lado $2r+1$, que tienen a s como punto central. Mediante experimentos numéricos, se ha comprobado que este procedimiento es adecuado, obteniéndose valores de tolerancia convenientes en la mayoría de los casos analizados. Esta estimación permite

reducir la incertidumbre acerca del valor de tolerancia y sirve de base para posteriores ajustes por parte del usuario. En cada paso, el voxel evaluado v se considera como perteneciente a la región si se satisface la siguiente desigualdad:

$$s_v(k, r) = \frac{1}{k} \left\langle \frac{|I(v') - IC(r)|}{\sigma(r)} \right\rangle \leq 1 \quad (2)$$

donde $\langle \bullet \rangle$ representa el promedio de disimilitud respecto de la intensidad característica sobre los voxels v' vecinos a v , respecto del desvío.

El crecimiento evoluciona de manera iterativa de acuerdo a una estrategia BFS (Breadth First Search), manteniendo los voxels visitados en una lista auxiliar asociada a cada región de interés, la cual inicialmente incluye las semillas especificadas para cada región. A fin de proveer información para la segunda etapa, se guarda la posición de la frontera de cada región. Para esto, cuando un voxel se descarta de la región, el voxel vecino previamente agregado se agrega a una lista *RG-list* que mantiene los puntos de borde.

2.2 Segunda etapa de crecimiento

El proceso de crecimiento inicial proporciona en general resultados aceptables, evitando problemas de sobre-segmentación, aunque los bordes de los objetos resultan definidos aproximadamente. Por este motivo se aplica una segunda etapa de crecimiento —denominada “push”—, la cual resulta análoga a la primera etapa con la diferencia de que al encontrarse la región próxima a los bordes, se relajan las tolerancias y se aplica una condición adicional relacionada al gradiente de la imagen en los puntos de borde. En este caso, el crecimiento se reanuda a partir de los voxels incluidos en la *RG-list* durante la etapa anterior.

El criterio adicional requiere el cálculo del gradiente en un entorno- r ($r \geq 1$) de cada voxel visitado $v = (x, y, z)$, el cual se define como:

$$grad_v(r) = \max\{Gx_v(r), Gy_v(r), Gz_v(r)\} \quad (3)$$

donde

$$\left. \begin{aligned} Gx_v(r) &= \frac{1}{r} \sum_{i=1}^r |I(x+i, y, z) - I(x-i, y, z)| \\ Gy_v(r) &= \frac{1}{r} \sum_{j=1}^r |I(x, y+j, z) - I(x, y-j, z)| \\ Gz_v(r) &= \frac{1}{r} \sum_{k=1}^r |I(x, y, z+k) - I(x, y, z-k)| \end{aligned} \right\} \quad (4)$$

Dado un coeficiente de ponderación pg , que puede tomar valores entre 0 y 1, y un valor precalculado max_gr , correspondiente al máximo gradiente según las intensidades de la imagen, un voxel v puede considerarse dentro de la región si satisface:

$$grad_v(r) \leq pg \cdot max_gr \quad (5)$$

De esta manera, en la segunda etapa se exige que las ecuaciones (2) y (5) sean satisfechas. El análisis del entorno local de cada voxel puede incrementar levemente el costo computacional, pero por lo general ayuda a prevenir problemas de sub-segmentación debidos al ruido y de sobre-segmentación por desborde hacia otras regiones.

Además, el algoritmo implementado ofrece la posibilidad de limitar el número de niveles permitidos en el recorrido durante la etapa de push. De este modo, se produce una búsqueda de tipo

DLS (Depth-Limited Search), la cual resulta útil para controlar interactivamente el proceso de crecimiento, especialmente en imágenes muy ruidosas o con límites difusos.

3. Construcción del modelo de superficie final

Una vez determinada una aproximación inicial de la región, la etapa siguiente consiste en generar la malla final que representa la superficie buscada. El procedimiento recomendado consiste en aplicar un modelo deformable o snake, a partir de la inicialización provista.

3.1 Inicialización del modelo deformable

Una snake se define como una curva (en 2D) o superficie (en 3D) en el dominio de la imagen que pueden ser movidas bajo la influencia de fuerzas virtuales internas y externas. Una superficie deformable se representa digitalmente por una malla de triángulos definida por un conjunto de vértices $s_i(t, x_i, y_i, z_i)$, donde t es el tiempo e i corresponde al índice del vértice.

En lugar de considerar una superficie inicial definida por el usuario como en los enfoques tradicionales, la geometría del modelo deformable en este caso es construida usando la información de la *RG-list* generada durante el proceso de crecimiento de regiones. El algoritmo determina las caras de los voxels de la *RG-list* que corresponden a la frontera de la región (o sea aquellas caras que separan un voxel perteneciente a la región de un voxel en el exterior de la misma). En cada una de estas caras, se especifican dos triángulos rotulando sus vértices en sentido horario, vistos desde el interior de la región, a fin de asegurar una malla cerrada y orientada. La superficie resultante presenta un aspecto escalonado, ya que los triángulos son perpendiculares entre sí (Fig. 1-izq).




Figura 1. Mallas de superficie generadas mediante RG: original (izq.), luego de aplicar el filtro de suavizado (der.)

Con el fin de mejorar su apariencia, la malla puede ser procesada mediante un filtro de suavizado aplicado a cada vértice [15]. Sin embargo, este filtro puede fallar cuando dos o más voxels están débilmente conectados (o sea, que solo comparten un único vértice o arista). Para evitar efectos no deseados, se verifica la existencia de disposiciones conflictivas de voxels durante el proceso de generación de la malla inicial, resolviéndolas mediante el re-rotulado de los vértices comunes en uno de los triángulos conflictivos. Este procesamiento permite generar superficies suaves y sin huecos ni irregularidades (Fig. 1-der) evitando los inconvenientes de los enfoques convencionales basados en iso-superficies [8,9].

3.2 Evolución del modelo deformable

Diferentes técnicas han sido propuestas para la evolución de una snake, tales como diferencias finitas, elementos finitos o programación dinámica. En este trabajo se ha aplicado la formulación propuesta en [16], donde cada vértice s_i de la superficie deformable evoluciona de acuerdo a la siguiente ecuación de movimiento:

$$\gamma_i \frac{ds_i}{dt} - a\alpha_i(t) + b\beta_i(t) = q\rho_i(t) + pf_i(t) \quad (6)$$

donde $\alpha_i(t)$, $\beta_i(t)$, $\rho_i(t)$ y $f_i(t)$ son las fuerzas de tensión, flexión, inflación y externa respectivamente, y γ_i es un coeficiente de amortiguación.

La energía interna simula las características de una membrana elástica. La fuerza de tensión representa la resistencia de la *snake* al estiramiento, mientras que la fuerza de flexión representa la resistencia a deformaciones de curvatura. Ambas actúan sobre cada nodo i de la superficie y se calculan a partir del Laplaciano y el Laplaciano cuadrado, como una aproximación a la segunda y cuarta derivadas respecto de la posición, tomando en cuenta la topología en una malla local alrededor del nodo i :

$$\alpha_i(t) = \frac{1}{m} \sum_{j \in N(i)} s_j(t) - s_i(t) \quad (7)$$

$$\beta_i(t) = \frac{1}{m} \sum_{j \in N(i)} \alpha_j(t) - \alpha_i(t) \quad (8)$$

donde $N(i)$ es el conjunto de nodos s_j vecinos al nodo s_i y m es la cantidad de estos vecinos.

En el lado derecho de la Ec (7), la fuerza de inflación ρ_i , que es aplicada de modo de guiar la superficie hacia los bordes del objeto, se calcula como:

$$\rho_i(t) = n_i(t) F(I(s_i)) \quad (9)$$

siendo n_i el vector normal unitario a la superficie en el nodo i y F una función binaria que relaciona ρ_i al campo de intensidades de la imagen I :

$$F(I(s_i)) = \begin{cases} +1, & \text{si } \frac{|I(s_i) - IC(r)|}{k\sigma(r)} \leq 1 \\ -1, & \text{en otro caso} \end{cases} \quad (10)$$

$IC(r)$ y $\sigma(r)$ corresponden a la intensidad característica y desvío de la región según se definió en las Ec. (2). De acuerdo a la Ec. (10), F toma un valor 1 cuando la intensidad $I(s_i)$ está limitada en $k\sigma$ de la intensidad característica, y -1 en caso contrario, haciendo que la *snake* se contraiga en caso de que avance sobre puntos que ya no cumplirían con el criterio de la región.

La fuerza externa f_i de la imagen, que contiene la expansión de la *snake* en bordes significativos, actúa en cada nodo simulando un gradiente de potencial:

$$f_i(t) = G[\varphi(S_i)] \quad (11)$$

donde G es el vector gradiente numérico y el potencial φ se define como:

$$\varphi(S_i) = -grad[FI(s_i)] \quad (12)$$

El gradiente escalar $grad(\cdot)$ se calcula a partir de la Ec. (3) y $FI(s_i)$ es la intensidad $I(s_i)$ correspondiente a s_i a partir de la imagen mediante la convolución con un filtro de suavizado [2].

Como la estimación inicial provista por el algoritmo de crecimiento es una aproximación cercana a la superficie final, la Ec. (6) puede ser resuelta directamente aplicando un esquema de Euler explícito de primer orden, considerando pasos de tiempo suficientemente pequeños:

$$\mathbf{x}_i^{(t+\Delta t)} = \mathbf{x}_i^{(t)} - \frac{\Delta t}{\gamma} (-a\alpha_i^{(t)} + b\beta_i^{(t)} - q\rho_i^{(t)} - p\mathbf{f}_i^{(t)}) \quad (13)$$

El proceso iterativo procede hasta que el desplazamiento de los nodos no excede un valor de convergencia dado. A continuación se muestran ejemplos de evolución sobre imágenes sintéticas simples a partir de una malla inicial obtenida con el algoritmo RG. En la Figura 2, la evolución se lleva a cabo a partir de una malla aproximada sin suavizar, mientras que en la Figura 3 la malla inicial corresponde a una semiesfera suavizada, bastante lejana al objeto buscado.




Figura 2. Evolución del modelo deformable: (a) malla inicial sin suavizar obtenida a partir de RG, (b) snake luego de 20 iteraciones, (c) snake luego de 100 iteraciones.




Figura 3. Evolución del modelo deformable: (a) malla inicial a partir de RG y suavizada, (b) snake luego de 20 iteraciones, (c) snake luego de 100 iteraciones.

4. Resultados experimentales

La metodología descrita fue aplicada a la detección y construcción de superficies de estructuras anatómicas en imágenes médicas. Se realizó un análisis de sensibilidad de la influencia de los principales parámetros de control usando la base BrainWeb de datos simulados, disponible en el sitio web <http://www.bic.mni.mcgill.ca/brainweb> del McConnell Brain Imaging Centre en el Montréal Neurological Institute (MNI). Esta imagen corresponde a una MRI de cerebro pesado en modalidad T1, la cual provee simulaciones con resolución interslice de 1×1 mm, con espaciado entre cortes desde 1 a 9 mm. El tamaño de las imágenes analizadas fue de $181 \times 217 \times 181$ voxels of 1 mm^3 . El simulador permite ajustar dos parámetros principales: ruido y no-uniformidad (INU). Además, se proporciona un modelo de referencia por medio de funciones que indican la probabilidad de pertenencia de cada voxel a los diferentes tejidos [17]. Así, esta base sirve como un modelo para la evaluación de los algoritmos propuestos en imágenes de diferente calidad y proporciona un modo cuantitativo de validación a través de un fantoma computacional. La Figura 4 muestra un corte de las imágenes elegidas para la experimentación, con 0%, 5% y 9% de ruido. El algoritmo fue aplicado a la detección de materia blanca, comparando el resultado obtenido con la clasificación provista por el simulador en cada caso.




Figura 4. MRI simuladas pesadas en modalidad T1 con diferentes niveles de ruido: a) 0%, b) 5% y c) 9%.

A fin de evaluar los resultados, se aplicó la métrica AOM (Average Overlap Metric), considerada en varios trabajos como un indicador cuantitativo de calidad de segmentación [6,18]:

$$AOM = \frac{2 \cdot |V_i \cap V_a|}{|V_i| + |V_a|} \quad (14)$$

donde V_i y V_a son los conjuntos de voxels clasificados como el tejido correspondiente en el fantoma del simulador y mediante el algoritmo. De esta manera, AOM representa el número de voxels simultáneamente contenidos en ambas segmentaciones relativa al promedio de voxels de ambas segmentaciones. Esta métrica alcanza el valor 1 para resultados similares y 0 si no hay voxels en común. Además, se evaluaron los siguientes indicadores:

$$CP = \frac{|V_i \cap V_a|}{|V_i \cup V_a|} \quad FNP = \frac{|V_i - V_a|}{|V_i \cup V_a|} \quad FPP = \frac{|V_a - V_i|}{|V_i \cup V_a|} \quad (15)$$

siendo CP es el porcentaje de coincidencias entre V_i y V_a , y FNP y FPP son los porcentajes de falsos negativos y falsos positivos, respectivamente.

La Figura 5 muestra la sensibilidad de las métricas de performance a las variaciones en el parámetro k del algoritmo RG definido en la Ec. (2), para $r=2$. A medida que k aumenta, el número de falsos negativos decrece, pero para valores de k mayores que cierto umbral, los falsos positivos comienzan a aparecer en los resultados. Esta competencia produce una curva de AOM que muestra un valor óptimo alrededor de $k=2$ para la imagen sin ruido y $k=1.5$ para la de 9% (Figura 6). Se puede ver cómo presencia de ruido en la imagen deteriora la performance, si bien la tendencia general se conserva.

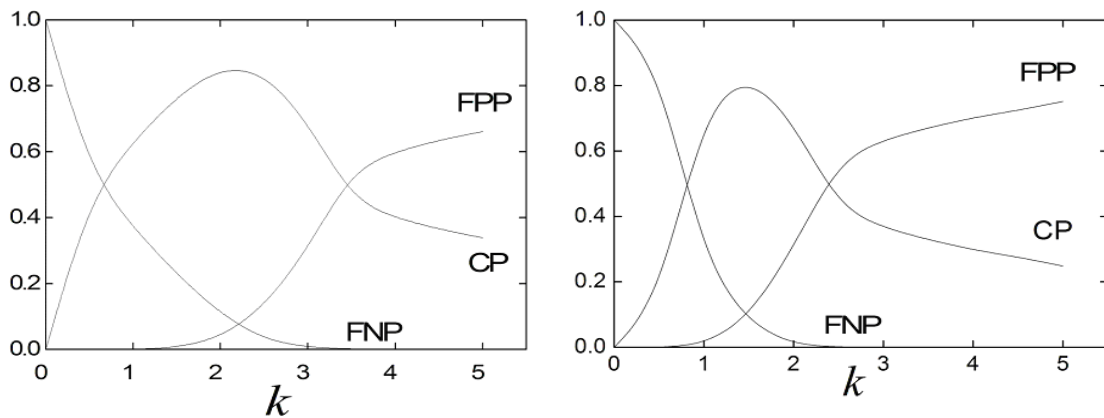


Figura 5: Influencia de k en la segmentación de imágenes: libre de ruido (izq.), con 9% de ruido (der.)

La Figura 7 muestra la influencia del parámetro r , la dimensión del radio local. La mejor performance fue lograda para $r=1$, alcanzando valores de AOM superiores a 0.94 en imágenes con

bajo ruido ($\leq 5\%$) y 0.92 para la imagen con ruido alto (9%). A medida que r crece, los indicadores disminuyen. También se puede notar que cuando los voxels son evaluados en forma aislada (o sea, $r=0$) los resultados de segmentación son pobres (AOM varía entre 0.71 y 0.81 según el ruido).




Figura 6. Comparación de performance de segmentación para diferentes niveles de ruido en la imagen.




Figura 7. Dependencia de la performance de segmentación en el parámetro r .




Figura 8. Segmentación de imagen MRI de cerebro: a) cortes del fantoma, b) resultado de RG ($k=2$, $r=1$).

La Figura 8 muestra la clasificación del fantoma y el resultado de la segmentación inicial usando el algoritmo de crecimiento sobre una imagen del cerebro sin ruido, sobre diferentes cortes de la imagen pudiendo observar que los objetos son muy similares. La Figura 9 presenta diferentes vistas de la superficie correspondiente a esta imagen, obtenida a partir del refinamiento mediante el modelo deformable. Se puede apreciar que el método se comporta satisfactoriamente en la detección de esta estructura compleja, la cual presenta múltiples fisuras y circunvoluciones.




Figura 9. Rendering de las superficies de cerebro reconstruidas a partir de una imagen sin ruido ($a=30$, $b=20$, $p=3$, $q=5$ y $\Delta t=0.005$): (a) vista axial, (c) coronal y (d) sagital de la segmentación final.

Las Tablas 1 y 2 resumen los valores típicos hallados para los indicadores de calidad calculados sobre imágenes con diferentes niveles de ruido e INU. Puede observarse que la calidad de los resultados es altamente satisfactoria, considerando la complejidad anatómica de la estructura. En particular, aunque la calidad de la segmentación se deteriora gradualmente en la presencia de ruido y variaciones de intensidad, la robustez del método desarrollado resulta excelente aún comparado con los resultados de otras estrategias de segmentación [6].

AOM	Ruido 0%	Ruido 5%	Ruido 9%
INU = 0%	0,94105	0,94096	0,91371
INU = 20%	0,92043	0,92210	0,90494
INU = 40%	0,88824	0,88819	0,87354

Tabla 1. Métrica AOM para segmentaciones de imágenes simuladas de cerebro (BrainWeb).

		Ruido 0%	Ruido 5%	Ruido 9%
INU = 0%	PC	0.88867	0.88851	0.84113
	PFN	0.09655	0.05643	0.06254
	PFP	0.01479	0.05505	0.09633
INU = 20%	PC	0.85260	0.85547	0.82639
	PFN	0.04951	0.05987	0.08962
	PFP	0.09788	0.08466	0.08400
INU = 40%	PC	0.79895	0.79887	0.77548
	PFN	0.14076	0.12883	0.14959
	PFP	0.06029	0.07230	0.07493

Tabla 2. Porcentaje de coincidencias (PC), falsos negativos (PFN) y falsos positivos (PFP) para la segmentación de cerebro en imágenes simuladas de cerebro (BrainWeb).

En cuanto al costo computacional, en un equipo Pentium(R) D 2.8 GHz, 2Gb RAM, GeForce 7300 GS, la segmentación del cerebro mediante RG tomó aproximadamente 5 seg, la generación de la malla de superficie inicial unos 20 seg y la deformación de la malla mediante el modelo de snakes (463000 nodos) 75 seg. El tiempo total de segmentación es entonces de alrededor de 100 seg, resultando considerablemente menor que los reportados por otras técnicas [9,14].

El método fue evaluado también sobre estudios reales de MRI a fin de analizar la performance en la segmentación de las estructuras anatómicas. En la Figura 10 se muestran diferentes vistas 3D obtenidas en la segmentación de cerebro en un estudio de MRI de $256 \times 256 \times 85$ puntos. Los parámetros usados por el algoritmo RG fueron $r=1$ and $k=1.5$, resultando una malla de 370486 vértices. El modelo deformable requirió unas 50 iteraciones para alcanzar el resultado mostrado, usando parámetros $a=b=10$, $p=3$, $q=5$ and $\Delta t=0.001$. La Figura 11 muestra el resultado de la segmentación de otra imagen de MRI de $256 \times 256 \times 124$ voxels, en la cual se detectó un tumor cerebral. En (a) se muestra el resultado sobre un corte del volumen, en (b) se puede apreciar la malla de superficie obtenida a partir del algoritmo RG ($r=1$, $k=1.5$) y en (c) se presenta el resultado final del modelo deformable ($a=5$, $b=3$, $p=2$, $q=5$ y $\Delta t=0.005$), luego de 30 iteraciones.




Figure 10: Vistas sagital (a), axial (b) y coronal (c) de la superficie del cerebro reconstruida a partir de una MRI real.




Figura 11. Segmentación de tumor cerebral: (a) corte de la imagen MRI, (b) malla inicial con RG, (c) modelo de superficie final (30 iteraciones).

5. Conclusiones

En este trabajo se presentó un método para la segmentación de estructuras contenidas en imágenes digitales 3D, el cual se basa en la combinación de un algoritmo de crecimiento de regiones y modelos deformables. El enfoque presenta ventajas comparado con estrategias de segmentación previas similares. Una de las más importantes es que el algoritmo siempre permite generar mallas de superficie cerradas y orientadas, que encierran la región segmentada.

La segmentación inicial con RG provee una detección inicial conveniente de las estructuras de interés con una intervención limitada por parte del usuario requerida para la selección de puntos semilla. El algoritmo de crecimiento incorpora información sobre el entorno local de los voxels, la

cual sustancialmente reduce el efecto del ruido y evita desbordes hacia otras regiones. Al utilizar las segmentaciones obtenidas con RG como inicialización de modelos deformables, es posible recuperar en pocas iteraciones representaciones de superficie suaves aún de objetos de geometrías complejas. El enfoque ofrece una alternativa interesante frente a otras propuestas basadas en *marching cubes* para generar mallas iniciales para modelos de snakes, los cuales están limitados por las falencias típicas de esos métodos. Al lograr aproximaciones cercanas al resultado final, en este caso la deformación de la snake se restringe en general a perturbaciones menores de refinamiento, reduciendo sustancialmente la complejidad computacional.

El modelo fue aplicado a la segmentación de estructuras complejas, a partir de fantasmas simulados y en imágenes reales. La evaluación cuantitativa del método ha mostrado una muy buena performance superando el 90%. Las representaciones finales que resultan de la aplicación de modelos deformables producen mallas de alta calidad y gran detalle.

REFERENCIAS

- [1] Pham D, Xu C, Prince J. A Survey of current methods in medical image segmentation, *Annual Review of Biomedical Engineering* 2000; 2: 315-37.
- [2] Castleman K, *Digital Image Processing*, NJ: Prentice Hall; 1996.
- [3] Adams R, Bischof L. Seeded Region Growing, *IEEE Trans. Pattern Analysis and Machine Intelligence* 1994; 16(6): 641-7.
- [4] Fan J, Yau D, Elmagarmid A, Aref W. Automatic image segmentation by integrating color-edge extraction and seeded region growing, *IEEE Trans Image Processing* 2001; 10(10): 1454-66.
- [5] Freixenet J, Muñoz X, Raba D, Martí J, Cufi X. Yet another survey on image segmentation: region and boundary information integration, *ECCV 2002, LNCS 2352, Springer-Verlag Berlin*; 408-422.
- [6] Yu Z, Zhu Y, Yang J, Zhu Y. A hybrid region-boundary model for cerebral cortical segmentation in MRI, *Computerized Medical Imaging and Graphics* 2006; 30: 197-208.
- [7] Lorensen W, Cline H. Marching Cubes a high resolution 3D surface reconstruction algorithm, *Computer Graphics* 1987; 21(4): 163-9.
- [8] Strauss E, Jimenez W, Giraldo G, Silva R, Oliveira A. A semi-automatic surface reconstruction framework based on T-surfaces and isosurface extraction methods, *XV Brazilian Symposium on Computer Graphics and Image Processing (SIBGRAPI'02) 2002*; p. 24.
- [9] Chen T, Metaxas D. A hybrid framework for 3D medical image segmentation, *Medical Image Analysis* 2005; 9: 547-65.
- [10] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models, *International Journal of Computer Vision* 1988; 1: 321-31.
- [11] Cohen L. On Active Contour Models and Balloons, *CVGIP: Image Understanding* 1991; 53(2): 211-8.
- [12] Lin Z, Jin J, Talbot H. Unseeded region growing for 3D image segmentation, *ACM International Conference Proceeding Series* 2000; 9: 31-7.
- [13] Olabarriaga S, Smeulders A. Interaction in the segmentation of medical images: A survey, *Medical Image Analysis* 2001; 5: 127-42.
- [14] Xu C, Pham D, Rettmann M, Yu D, Prince J. Reconstruction of the Human Cerebral Cortex from Magnetic Resonance Images, *IEEE Trans Medical Imaging* 1999; 18(6): 467-80.
- [15] Taubin G. A signal processing approach to fair surface design, *Computer Graphics Proceedings* 1995; 351-8.
- [16] McInerney T, Terzopoulos D. Topology Adaptive Deformable Surfaces for Medical Image Volume Segmentation, *IEEE Trans Medical Imaging* 1999; 18(10): 840-50.
- [17] Collins D, Zijdenbos A, Kollokian V, Sled J, Kabani N, Holmes C, Evans A. Design and construction of a realistic digital brain phantom, *IEEE Trans Medical Imaging* 1998; 17(3): 463-8.
- [18] Pichon E, Tannenbaum A, Kikinis R. A statistically based surface evolution method for medical image segmentation: presentation and validation, *MICCAI 2003*; 2: 711-20.