

ALGORITMO DE GENERACIÓN DE MALLAS DE SUPERFICIE A PARTIR DEL CRECIMIENTO DE REGIONES EN IMÁGENES 3D

Mariana del Fresno* y Marcelo Vénere*,†

* PLADEMA-ISISTAN,
Universidad Nacional del Centro,
Pinto 399 (B7001BBO), Tandil, Argentina
e-mail: mdelfres@exa.unicen.edu.ar
web page: <http://www.pladema.gov.ar>

† también Comisión Nacional de Energía Atómica
e-mail: venerem@exa.unicen.edu.ar

Palabras clave: Geometría Computacional, Imágenes Médicas, Segmentación.

Resumen. *En el campo del reconocimiento de objetos y visión computacional, uno de los procesos esenciales consiste en la segmentación de la imagen en los objetos significativos que la componen. En este trabajo se presenta un procedimiento completo de segmentación de imágenes tridimensionales y generación de superficies basado en el método de crecimiento de regiones. El proceso es semiautomático, ya que comienza con una inicialización interactiva simple por parte de un usuario experto, a partir de la cual se desencadena el crecimiento automático de las regiones. El resultado de la segmentación es utilizado para generar el modelo de superficies correspondiente a las regiones detectadas. Este proceso consiste en 3 etapas: la construcción de una triangulación inicial, el procesamiento de la malla para determinar y resolver posibles situaciones conflictivas y la aplicación de un filtro de suavizado que permite lograr superficies de mejor calidad visual. Este enfoque logra superficies compactas y libres de huecos, superando algunas deficiencias de los métodos convencionales. Los resultados obtenidos son altamente satisfactorios, aún ante la presencia de ruido y variaciones de intensidad en la imagen.*

1 INTRODUCCIÓN

Una de las operaciones más importantes dentro del procesamiento de imágenes es la segmentación. Su objetivo es particionar una imagen en sus objetos constituyentes o regiones de interés, de acuerdo a un criterio prefijado¹. Este proceso constituye generalmente una de las principales etapas dentro del análisis de imágenes y su resultado usualmente dictamina el eventual éxito de los procesos subsecuentes, tales como reconocimiento de patrones o visión computacional, por ejemplo. Por esta razón, la investigación en el área ha sido intensiva y se han propuesto numerosos enfoques de segmentación^{2,3,4}.

Los métodos de segmentación usualmente se agrupan en cuatro enfoques principales: esquemas de umbralado de intensidades, métodos basados en bordes, métodos orientados a regiones y además esquemas híbridos que resultan de combinaciones de estos enfoques⁵.

Las técnicas basadas en umbrales se basan en la partición de los elementos de la imagen en función de sus tonalidades. En ciertos casos, el análisis de la distribución de intensidades de la imagen permite encontrar de manera óptima los valores característicos que establecen la separación de los objetos del interés, analizando el histograma de intensidades de la imagen. Sin embargo, pueden surgir complicaciones cuando estos valores no pueden determinarse fácilmente y los resultados no siempre son aceptables debido a que este tipo de métodos sólo considera información sobre intensidad, sin tener en cuenta otras propiedades de la imagen.

Los métodos basados en bordes buscan la detección de transiciones de tonalidades que idealmente se asocian a los límites entre diferentes componentes. Si bien se han planteado numerosas variantes, hay dos alternativas principales dentro de esta clase de métodos y son el uso de la primera o segunda derivada, a través del empleo de máscaras de filtrado¹. La naturaleza derivativa de este enfoque lo hace extremadamente sensible a la presencia de ruido en la imagen y además los bordes detectados no siempre resultan continuos, dificultando la determinación de las regiones dentro de los límites hallados.

Contrariamente a los métodos anteriores, los enfoques basados en regiones permiten considerar tanto la similitud de intensidades como la conectividad de los elementos, razón por la cual constituyen una de las alternativas más simples y robustas. En un esquema de crecimiento de regiones, los objetos de interés dentro de la imagen se constituyen a partir de ciertos puntos iniciales (conocidos como semillas), y evolucionan mediante la incorporación sucesiva de los puntos adyacentes y similares a los ya incluidos en cada región. El proceso de crecimiento continúa de esta manera hasta no se encuentran más puntos para integrar a la región, ya que posiblemente corresponden a otra diferente^{1,6}.

Diferentes métodos de segmentación aplican alguno de los criterios anteriores, pero lamentablemente suelen fallar en su propósito. Con el fin de lograr mejorar los resultados de la segmentación, se han planteado esquemas híbridos que tratan de combinar los aspectos favorables de las distintas técnicas propuestas. Así, una tendencia reciente consiste en la aplicación de un esquema integrado de segmentación que considere información sobre regiones y bordes, basado en la naturaleza complementaria de ambos tipos de información. Existen numerosas variantes en esta línea de integración, dependiendo de distintos aspectos, como el momento en que se realiza la integración y la manera en que ésta se realiza⁷.

En este trabajo se presenta un procedimiento de segmentación y generación de mallas de

superficie de las regiones detectadas. El algoritmo de segmentación se basa esencialmente en el método de crecimiento de regiones pero integra información sobre bordes en la definición del criterio de incorporación de voxels para controlar la evolución de la región. El algoritmo se aplica directamente sobre la imagen 3D, evitando de este modo los problemas típicos de correspondencia entre cortes contiguos en la etapa de integración para la generación de la malla de superficie. El enfoque es simple, robusto y se basa en la información aportada por el usuario experto sobre la composición de la imagen a través de la especificación de las semillas, aunque además permite la incorporación de otro tipo de conocimiento previo sobre las propiedades de las regiones. El método resulta un algoritmo semiautomático, ya que luego de la especificación de los puntos iniciales, la determinación de las regiones y la generación del modelo de superficies se pueden efectuar automáticamente. El algoritmo de segmentación se presenta en la sección 2. La sección 3 explica el proceso utilizado para la generación del modelo de superficies. La sección 4 presenta una discusión sobre los resultados obtenidos y en la sección 5 se discuten las conclusiones del trabajo.

2 UN MÉTODO DE CRECIMIENTO DE REGIONES

El objetivo del crecimiento de regiones es determinar conjuntos conectados de voxels en la imagen de entrada, según un criterio preestablecido, generalmente basado en propiedades locales⁶. El crecimiento de cada región se inicia a partir de la especificación de uno o más voxels iniciales, denominados semillas. Luego, se analizan los vecinos inmediatos de cada uno de ellos a fin de determinar si satisfacen el criterio de pertenencia a la región. Este proceso automático de crecimiento se repite, considerando en cada etapa los vecinos de los puntos incorporados que aún no han sido visitados, hasta que no existen más puntos que cumplan el criterio o hasta que se presente alguna condición de corte general.

El crecimiento de regiones se inicia a partir de una etapa interactiva de selección de semillas por parte del usuario experto, a partir de la cual se incorpora información valiosa sobre las características relevantes de cada región. Esto le permite al algoritmo determinar en forma automática el conjunto de componentes con propiedades similares dentro del volumen, aunque también es posible la intervención del usuario para especificar o corregir los parámetros que controlan el comportamiento del proceso de segmentación.

El algoritmo desarrollado se ha aplicado por lo general sobre imágenes provenientes de tomografías computadas (CT) o imágenes de resonancia magnética (MRI). En estos casos, la imagen 3D se forma a partir de los cortes individuales producidos por el dispositivo de captura y cada voxel de la imagen se asocia con una propiedad en esa posición relativa sobre el objeto real. En diversos trabajos, la segmentación se aplica a los cortes individuales de la imagen y luego se integran los resultados parciales para conformar el volumen total segmentado. En nuestro caso, el proceso de crecimiento se lleva a cabo directamente sobre la estructura 3D, evitando de este modo los problemas de puesta en correspondencia de los esquemas mencionados. Esto resulta conveniente sobre todo si se requiere la segmentación de objetos complejos, como ciertas estructuras anatómicas provenientes de imágenes médicas, ya que en ese caso algunos voxels de una región podrían encontrarse aislados dentro de un mismo corte pero, sin embargo, conectarse a través de cortes adyacentes en la estructura 3D

(por ejemplo, voxels correspondientes a las circunvoluciones del cerebro en una MRI).

2.1 Definición de semillas

El punto de partida del algoritmo de segmentación consiste en la determinación de las semillas de cada región. Se han propuesto diferentes alternativas para esta etapa, incluyendo opciones de determinación automática a partir del análisis del histograma de la imagen o como resultado de una segmentación previa con otras técnicas⁸. Sin embargo, la complejidad y variabilidad de ciertas estructuras complejas, como ocurre frecuentemente en imágenes médicas, tiende a limitar el alcance de aplicabilidad de los métodos completamente automáticos. Por otra parte, la ubicación de puntos iniciales sobre zonas ruidosas o correspondientes a bordes puede provocar una segmentación errónea de la imagen, la cual en todo caso requerirá una corrección posterior.

En el entorno de visualización de imágenes provisto, el usuario puede especificar los puntos semilla por medio de la exploración interactiva de la imagen, sabiendo que tales puntos ciertamente pertenecen a la región buscada. Con el fin de asistir al usuario en este proceso, se brinda información adicional acerca de la posición, tonalidad y gradiente en cada punto en que el usuario se detenga durante la navegación a través del volumen (Figura 1). Esta información puede servir de orientación para determinar la conveniencia de la selección. Además, se permite la especificación de una o varias semillas, lo cual puede ser apropiado en el caso de estructuras con alta variación de intensidades o que no corresponden a una única pieza, como por ejemplo en el caso de la segmentación del cráneo en una tomografía. Una vez especificadas las semillas para cada región de interés, se registra su posición x,y,z dentro del volumen de datos y su valor de intensidad, el cual se utiliza en la evaluación del criterio de similitud de los voxels visitados durante el proceso de crecimiento.

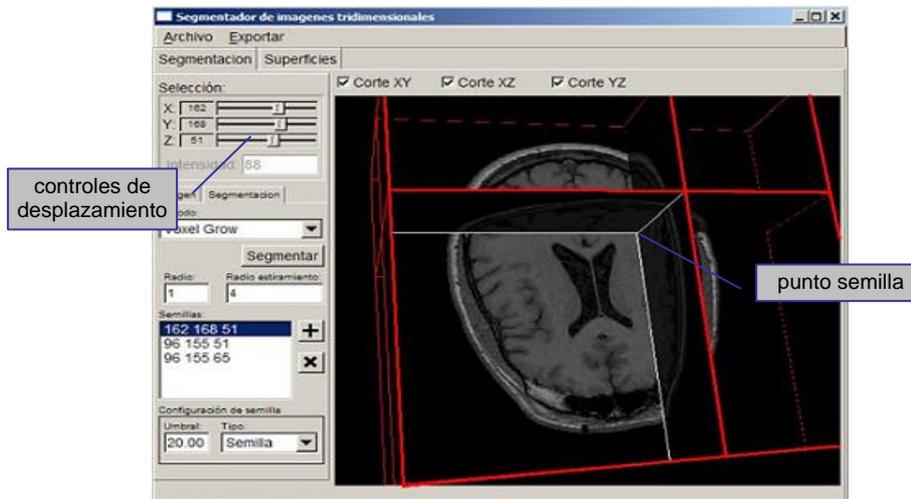


Figura 1: Interfase para exploración de la imagen y especificación de semillas

2.2 Criterio de crecimiento

A partir de los puntos iniciales definidos para cada región, el algoritmo de segmentación debe permitir que éstas crezcan por incorporación de otros voxels con propiedades similares. Entre las posibilidades analizadas, los mejores resultados se obtuvieron al considerar la información local sobre los valores de intensidad, para verificar la homogeneidad del punto analizado, y además tener en cuenta el valor del gradiente en tal punto, como medida de la variación de intensidades alrededor del mismo¹. Este criterio integrado permite incorporar un voxel a la región correspondiente si se cumplen las siguientes condiciones:

- a) el entorno del voxel es similar al promedio de las semillas especificadas, de acuerdo al nivel de tolerancia definido para la región, y
- b) se trata de un punto que no pertenece a un borde

El mapa de gradientes de la imagen incorpora información adicional dentro del criterio de evaluación y asegura la detención del llenado en zonas de transición entre componentes. Si se trata de un punto de borde significa que la región ha alcanzado su límite y el punto debe ser descartado. En cuanto a la tolerancia utilizada para la comparación de intensidades, esta se debe considerar debido a la frecuente variabilidad de intensidades dentro de una misma componente y a la presencia de ruido en la imagen. Una posibilidad es que el usuario experto provea este valor; sin embargo, el concepto de homogeneidad de una región no es fácilmente traducible a un valor numérico, por lo que definir tal valor no es tarea simple y frecuentemente suele desencadenar en un proceso de prueba y error. A tal fin, el algoritmo elabora una estimación del valor de tolerancia a utilizar para cada región, a partir del desvío de las tonalidades en torno a las semillas definidas. Este valor posteriormente puede ser ajustado si es conveniente. A causa de los aspectos mencionados en cuanto a las características de las imágenes de entrada, se ha incluido otra consideración referida a la proporción de puntos en el entorno exigida para el cumplimiento del criterio a). Experimentalmente, se comprobó que 0.8 es un valor porcentual apropiado. Una proporción superior brinda un criterio más estricto para lograr la inclusión del voxel central y a medida que dicho valor se disminuye, se relaja la exigencia sobre la cantidad de voxels similares hasta llegar al criterio simple de comparación sólo contra el voxel central.

Según lo expresado, se calcula inicialmente la intensidad característica de cada región como el promedio de intensidades de las semillas especificadas en ella:

$$I(R_i) = \underset{s \in R_i}{\text{promedio}}[f(s)] \quad (1)$$

donde los valores $f(s)$ corresponden a las intensidades de las semillas s definidas para la región R_i . Luego, la expansión de la región se efectúa sobre aquellos voxels v que satisfacen el criterio de similitud establecido. Para esto, se evalúa la diferencia $d(v')$ entre la intensidad de cada uno de los puntos v' pertenecientes al entorno $ent(v)$ del voxel analizado (incluyendo este punto), con respecto a $I(R_i)$, obteniendo:

$$d(v') = |f(v') - I(R_i)| \quad (2)$$

Además, se calcula el valor $grad(v)$ asociado a la magnitud del vector gradiente en v , y se verifica que la proporción de voxels dentro del entorno con $d(v')$ inferior a la tolerancia admitida sea igual o superior al porcentaje establecido y además que $grad(v)$ también esté por debajo del umbral fijado para poder considerar la inclusión de v a la región. En caso de satisfacer ambas condiciones, se calcula la diferencia promedio en v :

$$d(v) = \underset{v' \in ent(v)}{\text{promedio}}[d(v')] \quad (3)$$

para establecer finalmente un factor de calidad $\rho(v)$ asociado a v , el cual se define como:

$$\rho(v) = \alpha d(v) + (1 - \alpha) grad(v) \quad (4)$$

En esta expresión, el valor de α controla los pesos relativos del contraste de intensidades y de la magnitud del gradiente en v . Este valor puede ajustarse experimentalmente y puede variar con respecto a las distintas imágenes y aplicaciones particulares.

Mediante este criterio integrado se logra impedir, o al menos disminuir enormemente, las situaciones problemáticas típicas de los procesos de segmentación: por un lado, la sobre-segmentación de la región por escape del crecimiento a través de conductos delgados hacia regiones de intensidad similar y por otro, la situación inversa de exclusión de puntos que poseen ruido o un alto contraste de intensidades. En otros trabajos se plantean criterios similares, pero en la mayoría de los casos la comparación de intensidades se realiza con respecto al promedio de la región por lo que en tal caso es necesario recalcular dicho valor en cada iteración y requiere la actualización de valores previamente calculados⁹. En la Figura 2 se muestra el resultado del algoritmo de crecimiento de cerebro sobre uno de los 69 cortes de una tomografía de cabeza. En el primer caso, que corresponde a la utilización de un criterio simple de comparación de voxels individuales, se puede apreciar claramente la situación de desborde de la región sobre estructuras vecinas (Figura 2a). La segunda imagen presenta el resultado de la aplicación del criterio integrado de evaluación del entorno y consideración del valor del gradiente (Figura 2b).

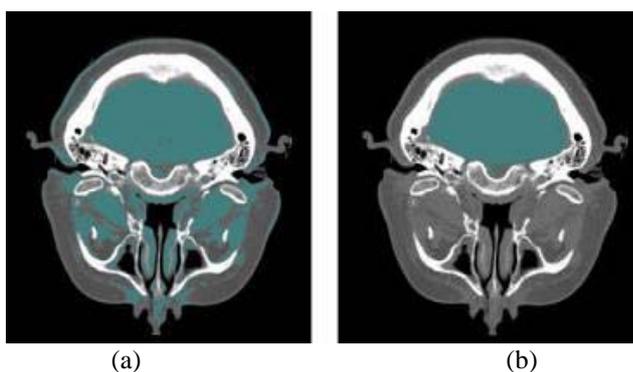


Figura 2: Aplicación del algoritmo de segmentación: problema de sobre-segmentación (a), control de desbordes por aplicación de un criterio integrado de evaluación de entorno (b)

2.3 Algoritmo de crecimiento

En principio, el crecimiento de cada región se basa en una estrategia de búsqueda en amplitud (BFS= *Breadth First Search*), considerando la exploración progresiva de los sucesivos niveles de puntos a partir de las voxels semilla. Los voxels visitados que satisfacen el criterio de pertenencia se mantienen en una lista auxiliar hasta el momento de ser procesados y eventualmente integrados a la región. Inicialmente se incorporan las semillas y a partir de ellas, el análisis se va extendiendo a sus vecinos inmediatos.

El esquema de segmentación permite la incorporación de información a priori sobre las características de la región segmentada. Esto permite aumentar las capacidades del algoritmo, condicionando la detención o reorientación del proceso de crecimiento, según corresponda. Las posibilidades en este punto son variadas y se pueden considerar algunos aspectos como medidas de volumen, modelos de formas, curvatura, etc., aunque no suele resultar simple en el caso de componentes complejas.

Considerando el factor $\rho(v)$ definido en (4), la estructura que contiene los voxels visitados se puede implementar como una cola de prioridad ordenada según este valor, mediante un *heap*¹⁰. Por su definición, esta estructura consiste en un árbol binario en el cual cada nodo padre tiene asociado un factor mejor o igual al de sus hijos. Esta propiedad asegura que el mejor candidato se encuentra siempre en la raíz del árbol. Por esta razón, si en cada iteración del algoritmo de crecimiento se extrae el primer elemento del *heap*, se estará escogiendo el voxel más similar a la región que está siendo segmentada. Un inconveniente de esta estrategia es que, para mantener la condición del *heap*, ante cada operación sobre la lista se debe verificar su ordenamiento y re-estructurarla en caso de ser necesario. Sin embargo, el costo computacional asociado no supera al de otros esquemas de ordenamiento de listas y su utilización permite guiar el proceso de crecimiento en todo momento a través de los “mejores” voxels. De esta manera, si se produce alguna condición general de corte (como puede ocurrir al alcanzar el volumen máximo) se habrán incorporado los voxels con menor contraste respecto de las semillas que caracterizan a la región. A continuación se presenta el pseudocódigo del algoritmo de crecimiento:

```

Insertar semillas en la lista  $L$ ,
Estimar el valor de tolerancia y la intensidad característica de  $R$ 
mientras  $L$  no esté vacía y no se cumple condición de corte
   $v$  = extraer primer elemento de  $L$ ,
  incorporar  $v$  a  $R$  y marcarlo como visitado,
  para cada vecino  $v'$  de  $v$ 
    si  $v'$  no ha sido visitado
      si  $v'$  satisface el criterio de aceptación
        insertar  $v'$  en  $L$  según su factor de calidad,
      sino
        insertar  $v'$  en la lista  $F$  de puntos frontera

```

Como se puede apreciar, inicialmente se incluyen las semillas en el *heap* L y a partir de ellas se estima el valor de tolerancia para el contraste de intensidades de la región. Luego, se inicia el proceso iterativo de crecimiento en el cual se extrae en cada paso el primer elemento de L , se lo rotula como perteneciente a la región para evitar su re-evaluación y se considera la extensión sobre cada uno de sus vecinos inmediatos. Este esquema asegura que cada voxel es evaluado una única vez, aunque sí es posible que sea considerado varias veces en el análisis del entorno de sus vecinos. Los puntos en los cuales se detiene el crecimiento se incorporan a otra lista F , correspondiente a la frontera de la región. Esta información es utilizada por el algoritmo de generación de mallas de superficie, evitando un recorrido adicional sobre la imagen para la detección de la frontera de la región. A modo de ejemplo, en la Figura 3 se muestran sucesivas etapas de crecimiento sobre un corte axial de una MRI y una visualización por *volume rendering* del resultado obtenido.

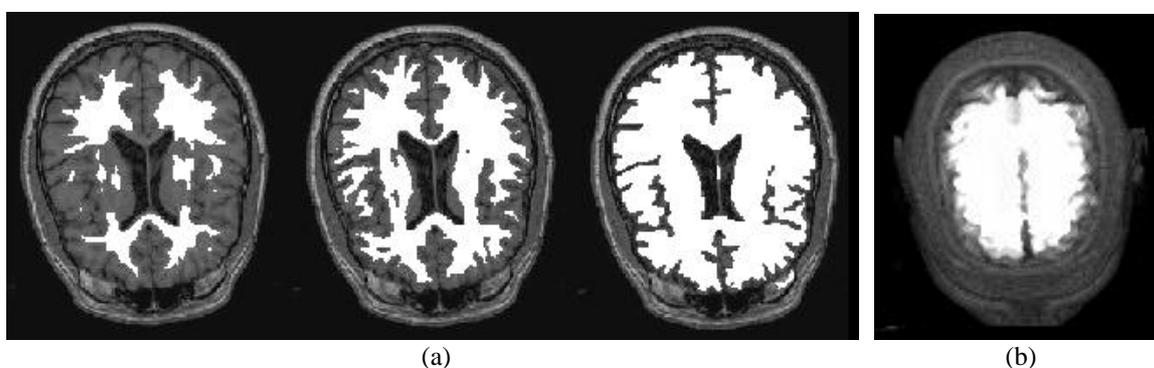


Figura 3: evolución del crecimiento de regiones sobre el cerebro en una MRI (a) y visualización del resultado sobre un corte virtual en el plano axial de la imagen digital 3D (b)

Una variación del algoritmo descrito consiste en actualizar la intensidad característica de la región a partir de los voxels que sucesivamente se incorporan a la región y recalcular además el valor del desvío utilizado como tolerancia del contraste de la región. Este enfoque adaptativo, sin embargo, implica un incremento en la complejidad computacional del algoritmo, más aún si esta actualización se propaga a los elementos ya incorporados en L .

En cualquier caso, la salida del algoritmo consiste de una estructura de iguales dimensiones que la imagen original, en la cual se rotulan las componentes asociadas a las distintas regiones detectadas. Esta información se tiene en cuenta además durante la etapa de visualización del volumen segmentado y en la generación de la geometría de las superficies detectadas.

2.4 Postprocesamiento de las regiones segmentadas

Luego que una región ha sido segmentada, puede ser deseable post-procesarla con el fin de extender su frontera actual o depurar el resultado, mediante la eliminación de voxels erróneamente incorporados o la inclusión de puntos aislados por efecto del ruido.

Con este fin, el esquema de segmentación provee una etapa de extensión adicional de las componentes detectadas a partir de la frontera obtenida (lista F), mediante una estrategia de

crecimiento similar, pero restringida a cierta cantidad de niveles de profundidad. Esta opción es especialmente apropiada cuando se ha considerado un entorno amplio ya que, dependiendo de la dimensión del mismo, puede suceder que el llenado no alcance plenamente los límites reales del objeto procesado. En este caso se debe considerar un entorno menor que el utilizado durante el llenado inicial y una cantidad de niveles al menos coincidente con la dimensión empleada en el crecimiento original, ya que se supone que la frontera de la región pudo crecer inicialmente hasta esa distancia del borde real.

3 MODELO DE SUPERFICIES

El resultado del proceso de segmentación puede ser evaluado mediante algoritmos de *volume rendering*¹¹, como en ejemplo de la Figura 3.b. Sin embargo, en cierto tipo de aplicaciones resulta útil efectuar la generación de un modelo de superficies de las regiones segmentadas para efectuar visualizaciones interactivas o realizar mediciones a partir de él.

El algoritmo de generación de mallas propuesto en este trabajo utiliza directamente el resultado de la etapa de segmentación, sin intervención adicional del usuario. El proceso consta de 3 etapas: inicialmente se construye una triangulación a partir de las caras correspondientes a los voxels en la frontera entre regiones, luego se detecta la posible presencia de situaciones conflictivas y finalmente se aplica un proceso de suavizado con el fin de mejorar el aspecto visual del modelo.

3.1 Construcción de la triangulación inicial

El enfoque utilizado para la generación del modelo de superficie considera la información sobre los voxels en el límite de las componentes segmentadas en la etapa de crecimiento de regiones. A partir de las caras frontera se genera una triangulación inicial, dividiendo cada una de ellas en dos triángulos, a partir del trazado de una diagonal. Cada esquina de un voxel frontera constituye un vértice de la malla regular construida sobre la imagen y cada triángulo se puede describir por la tripla de vértices que lo determinan. En este punto, se debe tener en cuenta que, si se mira cada triángulo desde un punto interior a la región, sus vértices deben especificarse en sentido anti-horario para asegurar la generación de superficies cerradas y coherentes.

3.2 Detección y tratamiento de conflictos

En el proceso de generación de la malla de superficie se pueden presentar algunas disposiciones de voxels que luego provocan situaciones conflictivas durante la etapa de suavizado, como se puede observar en la Figura 4.a. Se pudo comprobar que los casos problemáticos ocurren cuando los voxels que conforman la frontera resultan unidos sólo por una arista o por un vértice en común. A modo de ejemplo, en la Figura 5 se muestra una de las disposiciones para cada caso, pero existen 12 posibles combinaciones de voxels conectados por una única arista, mientras que son 8 las disposiciones correspondientes a dos voxels con un sólo vértice en común. El tratamiento de estas situaciones involucra la detección de las aristas o vértices conflictivos durante la etapa de generación de la triangulación inicial,

determinando cuál de los posibles casos de conflicto se produce. En este caso, se genera una copia de cada vértice involucrado en un conflicto y se le asigna un nuevo número de vértice. Luego, como convención, se considera el vértice original para los triángulos correspondientes al voxel de la izquierda y el vértice copia para los triángulos asociados al voxel a la derecha. Esta estrategia de re-enumeración de vértices permite que el algoritmo de suavizado los considere como puntos diferentes (si bien conservan la misma posición) y los triángulos puedan ser “despegados”, logrando una superficie suave (Figura 4.b).

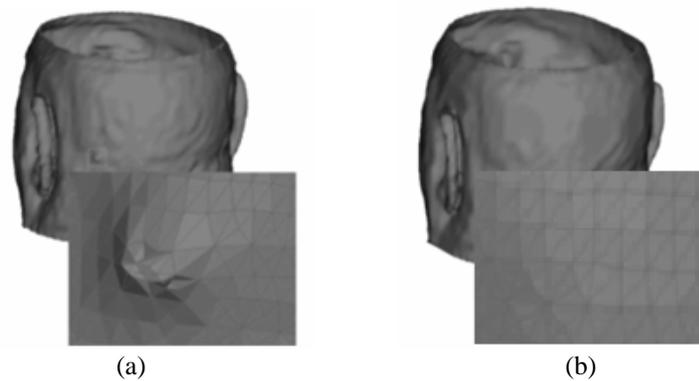


Figura 4: Presencia de conflicto en la generación de mallas: superficie sin tratamiento de situaciones conflictivas (a), malla generada luego del tratamiento de aristas y vértices conflictivos (b)

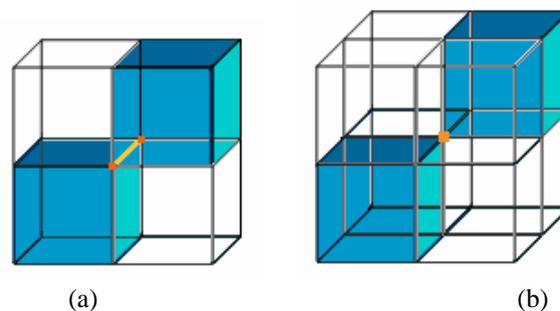


Figura 5: Una de las posibles disposiciones de voxels para diferentes casos conflictivos: aristas (a), vértices (b)

3.3 Post-procesamiento de la malla

La malla de triángulos generada describe las superficies de cada región segmentada, aunque, por su construcción, la visualización de la imagen resultante ofrece un aspecto escalonado (Figura 6.a). A partir de esta triangulación inicial, se lleva a cabo una etapa de suavizado de la superficie, por medio de un filtro pasa-bajos, que realiza un análisis de frecuencias sobre los vértices que componen la malla de polígonos. Este proceso permite obtener una distribución más homogénea de los vértices, disminuyendo así la presencia de irregularidades, sin perder detalles de importancia (Figura 6.b).

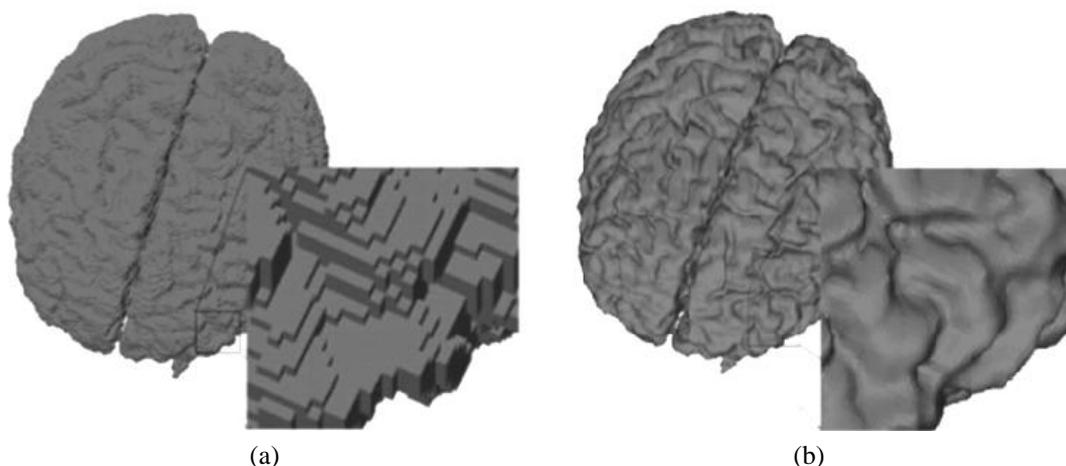


Figura 6: Descripción poligonal de superficies: triangulación inicial (a), superficie suavizada (b)

4 RESULTADOS

El algoritmo de segmentación y generación de superficies presentado en este trabajo ha sido aplicado sobre imágenes digitales 3D, asociadas a tomografías computadas y resonancias magnéticas, principalmente. La estrategia de crecimiento de regiones permite obtener resultados altamente satisfactorios, donde las componentes detectadas se aproximan a los límites reales de los objetos sin generar desbordes hacia otras estructuras, como puede apreciarse en las imágenes presentadas en la Figura 7.

En la Tabla 1 se especifican algunos de los casos analizados, indicando el tiempo aproximado insumido por los algoritmos de segmentación y generación de mallas, así como la cantidad de triángulos que componen la malla de superficie y la cantidad de vértices que han debido ser re-enumerados por el proceso de detección de conflictos, en cada caso. Las pruebas se efectuaron sobre un equipo con la siguiente configuración de hardware: procesador AMD Athlon 1.04 GHz, 512 MB RAM, placa de video GeForce FX 5200.

| Imagen | Dimensiones | Estructuras segmentada | Tiempo (ms) segmentación | Tiempo (ms) generac.mesh | #triángulos generados | # vértices despegados |
|--------|-----------------|------------------------|--------------------------|--------------------------|-----------------------|-----------------------|
| CT | 256 x 256x 125 | piel | 67598 | 36583 | 258412 | 8 |
| CT | 256 x 256x 125 | cerebro | 21341 | 29210 | 169618 | 91 |
| CT | 256 x 256x 125 | cráneo | 26708 | 45557 | 351298 | 1528 |
| MRI | 256 x 256 x 85 | cerebro | 19268 | 43682 | 518556 | 1654 |
| MRI | 256 x 256 x 124 | cerebro - tumor | 94350 | 67225 | 420923 | 1829 |

Tabla 1. Imágenes usadas en la evaluación del método y resultados obtenidos

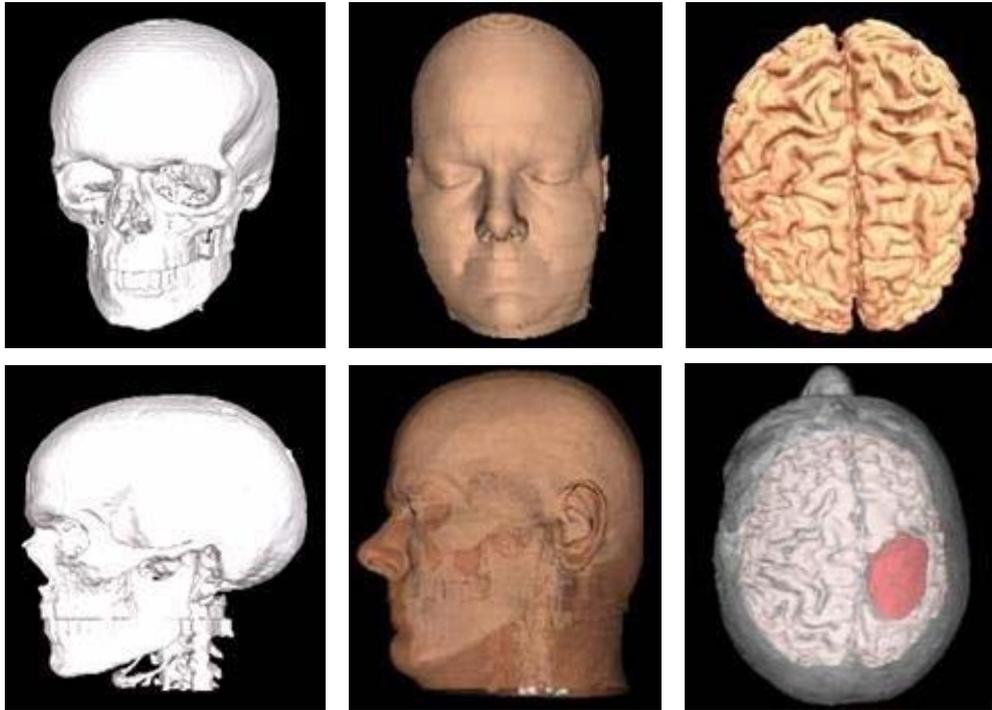


Figura 8. Visualización de segmentaciones obtenidas a partir de las imágenes de la Tabla 1

5 CONCLUSIONES

En este trabajo se describió un método semiautomático de segmentación y generación de mallas de superficie. El esquema, basado en el método de crecimiento de regiones, reduce la intervención del usuario experto prácticamente a la tarea de especificación de semillas en una interfase interactiva, para luego abocarse a la detección de componentes homogéneas a partir de la información provista por ellas. El criterio de similitud empleado considera la integración de regiones y discontinuidades, logrando tomar ventaja de la naturaleza complementaria de tales informaciones. El criterio de evaluación se considera sobre un entorno alrededor de cada punto, lo que permite atacar dos problemas importantes: la exclusión de puntos con ruido y el desborde del llenado hacia otras regiones contiguas, por conductos delgados. A partir del contraste de intensidad del entorno con respecto a las semillas especificadas para la región y al valor de gradiente en el punto analizado, se especifica un factor de calidad. Este valor es utilizado como criterio de ordenamiento de la lista en la cual el algoritmo va incorporando los voxels visitados. De esta manera, las regiones crecen siempre sobre los voxels más homogéneos, lo que resulta importante en caso de cumplirse alguna condición de corte general que implique la detención del algoritmo.

La segmentación se complementa con un procedimiento de generación de las superficies detectadas, el cual incluye un enfoque para el tratamiento de situaciones conflictivas y un post-procesamiento de suavizado sobre la malla de polígonos obtenida. Este enfoque permite

utilizar directamente el resultado del algoritmo de segmentación, evitando los problemas originados por los métodos tradicionales basados en detección de iso-superficies.

El método propuesto es simple, eficiente y robusto frente a la presencia de ruido y a la variación de intensidades en las imágenes. El mismo ha sido aplicado a imágenes digitales tridimensionales, generalmente provenientes de tomografías y MRI, obteniendo resultados altamente satisfactorios.

6 REFERENCIAS

- [1] K. Castleman, *Digital Image Processing*, Prentice Hall, (1996).
- [2] R. Haralick, L. Shapiro, *Computer and Robot Vision*, Addison-Wesley Publishing Company, (1992).
- [3] D. Pham, C. Xu, J. Prince, *A survey of current methods in medical image segmentation*, Annual Review of Biomedical Engineering, Vol.2, (2000).
- [4] H. Cheng, X. Jiang, Y. Sun, J. Wang, *Color Image Segmentation: advances and prospects*, Pattern Recognition, 34: 2259-2281, (2001).
- [5] Z. Lin, J. Jin, H. Talbot, *Unseeded region growing for 3D image segmentation*, Visualization 2000, Pan-Sydney Workshop on Visual Information Processing (2000).
- [6] R. Adams, L. Bischof, *Seeded Region Growing*, IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.16, No.6 (1994).
- [7] J. Freixenet, X. Muñoz, D. Raba, J. Martí, X. Cufí, *Yet another survey on image segmentation: region and boundary information integration*, ECCV 2000, LNCS 2352, pp. 408-422 (2002).
- [8] J. Fan, D. Yau, A. Elmagarmid, W. Aref, *Automatic image segmentation by integrating color-edge extraction and seeded region growing*, IEEE Trans. on Image Processing, Vol.10, No.10 (2001).
- [9] Y. Xiaohan, J. Yla-Jaaski, O. Huttunen, T. Vehkomaki, O. Sipild, T. Katila, *Image segmentation combining region growing and edge detection*, IAPR International Conference on Pattern Recognition, vol.C: 481-484, Netherlands (1992).
- [10] A. Aho, J. Hopcroft, J. Ullman, *Data structures and algorithms*, Addison-Wesley. Reading (1987).
- [11] J. Foley, A. Van Dam, S. Feiner, J. Hughes, *Introduction to Computer Graphics*, Addison-Wesley (1996).