

2. ESTADO DEL ARTE

Las imágenes médicas juegan un papel muy importante en el diagnóstico y tratamiento de enfermedades, ya que permiten la exploración del interior del cuerpo humano de una forma no invasiva. El avance tecnológico producido en los últimos años ha transformado considerablemente las características de la adquisición y tratamiento de imágenes médicas [1]. La aparición de dispositivos de captura sofisticados, tales como equipos TAC o resonancia magnética (MRI), han marcado un cambio revolucionario sobre las prácticas de diagnóstico, al permitir la reconstrucción de cortes internos del cuerpo con alta precisión [2]. Por otro lado, las mejoras en la tecnología de la computación gráfica y la reducción de costes de los equipos personales han permitido el desarrollo de diversos tipos de aplicaciones que antes estaban restringidas a grandes equipamientos, debido a la demanda computacional de los algoritmos involucrados [3]. De esta manera, es factible actualmente la implementación de facilidades de visualización y análisis de imágenes tridimensionales generadas a partir de CT o MRI, brindando herramientas de tipo no-invasivo para asistencia de los profesionales en diferentes procedimientos médicos.

Con el incremento en tamaño y número de imágenes médicas, se ha hecho necesario el uso del computador para facilitar el procesamiento y análisis de las mismas. En particular, los algoritmos para el delineamiento de estructuras anatómicas y otras regiones son un componente clave para asistir y automatizar ciertas tareas radiológicas. Este tipo de procedimientos, conocidos como segmentación de imágenes, permiten la descomposición de una imagen en las diferentes regiones de interés, según cada aplicación particular [4].

Se puede definir la segmentación como el conjunto de métodos y algoritmos que permiten la partición de una imagen en regiones constituyentes no solapadas, las cuales son homogéneas con respecto a alguna característica (intensidad, textura). Podemos definir una imagen I según (1), donde S_k es cada conjunto o clase de píxel/vóxel, conectados entre sí. Normalmente se suele asumir el número de clases K . La determinación del número de clases K en la clasificación de píxeles puede ser un problema complicado, por lo que

generalmente se asume conocida, basado en conocimientos previos de la anatomía que se está tomando en consideración.

$$I = \bigcup_{k=1}^K S_k \quad S_k \cap S_j = 0 \quad k \neq j \quad (1)$$

En el entorno médico, estas imágenes serían imágenes de resonancia magnética (MRI), tomografía computerizada (CT), ultrasonidos (US), tomografía por emisión de fotón único (SPECT), etc.

Las segmentaciones que permiten que las regiones o clases se superpongan son llamadas segmentaciones suaves. Estas segmentaciones son importantes en el tratamiento de imágenes médicas debido a los efectos del volumen parcial, donde múltiples tejidos contribuyen a un sólo píxel o vóxel. La segmentación dura obliga a tomar una decisión en cuanto si el píxel está fuera o dentro del objeto.

Dependiendo de cómo se realice la interacción con la máquina podemos clasificar las segmentaciones en automáticas, semiautomáticas o manuales. La relación entre la interacción manual y el rendimiento es una consideración importante en cualquier aplicación de segmentación. La interacción manual puede proveer alta precisión para cualquier tipo de imagen pero requiere de una persona con conocimientos de la anatomía a segmentar. No obstante, para estudios en grandes poblaciones, esto puede ser muy laborioso y un gran consumo de tiempo. La segmentación semiautomática requiere por parte del usuario de alguna interacción para especificar ciertos parámetros de partida que pueden afectar significativamente al rendimiento. Por último, la segmentación automática es una de las tareas más difíciles del procesamiento de imágenes. Emplea métodos avanzados muy dependientes de la imagen que se desee segmentar

Por otro lado, no se puede hablar de segmentación en general, los métodos de segmentación varían ampliamente dependiendo de la aplicación específica, el tipo de imagen y de objeto a segmentar y otros factores como el ruido (relación señal/ruido ó contraste/ruido), la forma de los objetos a segmentar, la escasez de conocimiento previo, análisis de volúmenes parciales y movimientos de la imagen. Por lo tanto, la selección de un método apropiado para un problema de segmentación puede ser muy difícil [5].

Actualmente, se encuentran sistemas que aún utilizan una delimitación manual de los objetos por parte del usuario, en base a la determinación de puntos correspondientes a la frontera de componentes. Esta práctica constituye una tarea tediosa y poco repetible, además de ser propensa a errores, por lo que es deseable que en general la intervención del usuario sea mínima y restringida a aquellas situaciones en que puede ser provista en una forma simple y robusta [6]. El desarrollo de métodos automáticos de segmentación tiene el potencial de reducir sustancialmente el tiempo consumido por algunos procedimientos médicos, que así podrían llevarse a cabo con mayor efectividad y menor riesgo, por ejemplo, en planificación quirúrgica, en tratamientos complejos como los de radioterapia [7], etc.

A continuación se analizan algunos tipos de algoritmos desde el enfoque de la segmentación de imágenes de tomografía computerizada para aplicaciones de reconstrucción de modelos tridimensionales, valorando los resultados obtenidos, así como la eficiencia y eficacia de los mismos para estas aplicaciones.

2.1 Umbralización

La umbralización (*thresholding*) es un método que segmenta imágenes creando una partición binaria de las intensidades de las imágenes. Una umbralización trata de determinar o definir un valor de intensidad llamado umbral (*threshold*), que separa clases deseadas. La segmentación se logra definiendo uno o varios umbrales (técnicas *multithresholding*) y agrupando en una clase a todos los píxeles con mayor intensidad que el umbral (ver Figura 1).

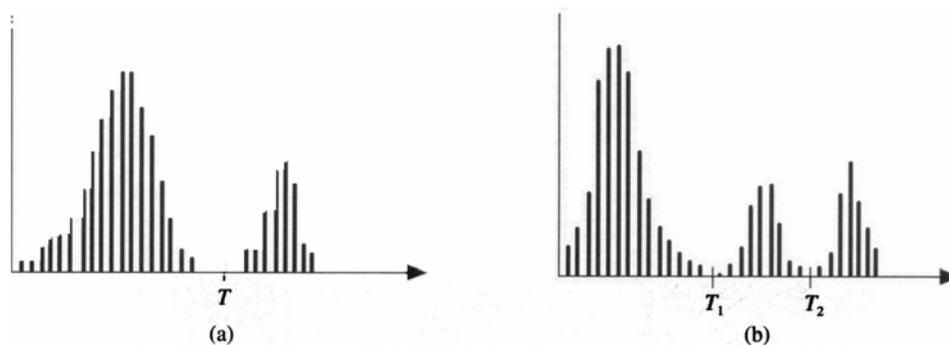


Fig. 1 Histogramas de nivel de gris que se pueden dividir en:
(a) un umbral sencillo, y (b) umbrales múltiples

Aunque enfoques basados en las intensidades de vóxels pueden ser aplicados exitosamente en la identificación de estructuras que tienen intensidades contrastantes u otras características diferenciables (como huesos, por ejemplo) [8], la mayoría de los tejidos no pueden diferenciarse de forma precisa sólo por sus propiedades de tonalidad, haciendo necesaria la aplicación de otro tipo de opciones de segmentación.

Otra limitación es que en su forma más simple (un umbral) sólo se generan dos clases y por lo tanto no se puede aplicar a imágenes multicanal. Además, la umbralización no suele tener en cuenta características espaciales de la imagen. Esto provoca que sea sensible al ruido e inhomogeneidades de intensidad, las cuales pueden presentarse en imágenes de resonancia magnética. Todo esto hace que la segmentación por umbrales sea el paso inicial de una secuencia de operaciones de procesamiento de imágenes para la segmentación.

2.2 Detección de contornos

Los métodos de detección de bordes o contornos intentan encontrar la frontera o zona de transición entre diferentes regiones con diferentes valores de intensidad o color. La idea básica es aplicar alguno de los operadores gradiente y convolucionarlos con la imagen [8]. Los posibles bordes o zonas de rápida transición entre regiones vendrán dados por valores de magnitud del gradiente elevados. Una de las mayores complejidades de este tipo de algoritmo es, una vez detectados los bordes, unirlos para conformar contornos cerrados en la región.

Este tipo de métodos resulta apropiado para imágenes de características bien definidas, con amplio contraste, aunque también pueden producir resultados no satisfactorios debido a su sensibilidad al ruido. Esto es decisivo en el caso de imágenes provenientes de reconstrucción tomográfica, en las cuales los diferentes tejidos suelen poseer intensidades no uniformes y los bordes no siempre resultan claramente definidos a partir de las intensidades de los vóxels [9].



Fig. 2 Detección de bordes con diferentes filtros

2.3 Crecimiento de Regiones

Los algoritmos de segmentación orientados a regiones constituyen un poderoso enfoque de segmentación de imágenes, orientados a la búsqueda de regiones uniformes dentro de la imagen, basándose en la idea de conectividad y similitud de los píxels o vóxeles [10, 11]. En la literatura podemos encontrar diferentes tipos de algoritmos de crecimiento de regiones. La mayoría de ellos se aplican sobre imágenes en escala de grises.

El esquema *Region Growing* previo a reconstrucciones 3D considera como entrada una imagen tridimensional de dimensiones arbitrarias $n_x \times n_y \times n_z$. Dentro de ella, cada región de interés comienza a formarse a partir de uno o más vóxeles considerados semillas (*seed point*) y evoluciona por incorporación de aquellos vecinos a los ya integrados que satisfacen la condición de aceptación establecida. El proceso finaliza cuando no hay más elementos que cumplan la condición, obteniendo como salida una matriz de iguales dimensiones que la imagen original, en la cual aparecen rotuladas las posiciones correspondientes a los vóxeles incluidos en una región. Los algoritmos de *Region Growing* varían dependiendo del criterio utilizado para decidir si un píxel debería ser incluido en la región o no, tipo de conectividad entre los vecinos y la estrategia utilizada para visitar los píxels cercanos.

Uno de los aspectos críticos en los algoritmos de crecimiento de regiones es la determinación del punto de partida para la segmentación [12]. Por un lado, los métodos completamente automáticos pueden resultar imprácticos debido a que la complejidad y variabilidad de las imágenes tiende a limitar el alcance de su aplicabilidad. Por otro lado, la ubicación de puntos semilla sobre zonas ruidosas o bordes de región puede provocar una segmentación errónea de la imagen. Por tanto, los aspectos más esenciales de los algoritmos de segmentación por crecimiento de regiones son la elección del punto de partida, el criterio de inclusión de vecinos y la condición de salida o fin del algoritmo. Este tipo de método de segmentación adopta diversas formas: algoritmos *sin-semilla* donde las semillas son seleccionadas automáticamente [13], algoritmos que optimizan la sensibilidad a la elección del punto de inicio [14], algoritmos donde el crecimiento se basa en umbrales de intensidad e información adicional espacial [15], [16]. El método propuesto en [13], a pesar de ser muy novedoso, presenta ciertas limitaciones debido a bajas relaciones señal-ruido (SNR) o contraste-ruido (CNR).

Por otro lado, existen algoritmos de segmentación basados en crecimiento de regiones con conocimiento adicional, los cuales incorporan cierto conocimiento de la imagen a fin de guiar el proceso de segmentación. La idea es proveer al proceso de información acerca de algunas propiedades de la región en cuestión como medidas de volumen, modelos de formas, etc. El algoritmo desarrollado en [15] para segmentar estructuras a partir de imágenes de cabeza de resonancia magnética, considera el volumen de la región que se desee segmentar como criterio adicional para la inclusión de voxéls. Otro ejemplo es el presentado en [16], en el que se usa un algoritmo de segmentación de crecimiento de regiones para segmentar la espinal dorsal a partir de imágenes de TAC, basándose en los niveles de gris y en las distancias espaciales desde el punto semilla a los diferentes píxels para generar mapas de probabilidad. También existen algoritmos de crecimiento de regiones en el que la inclusión de un píxel tiene en cuenta que un determinado porcentaje de los vóxeles vecinos cumplan cierto criterio de homogeneidad.

Otro aspecto crítico a tener en muy cuenta en los algoritmos de segmentación por crecimiento de regiones es la posible falta de homogeneidad en la intensidad de los vóxeles, como suele ocurrir en imágenes médicas como por ejemplo imágenes de resonancia magnética (MRI). No obstante existen soluciones que corrigen estadísticamente esta no-homogeneidad en la intensidad antes de

aplicar una segmentación basada en umbrales y conectividad entre vóxels [17].

Ya en [18] se introduce el concepto de crecimiento multipaso, pero muestra dos claros inconvenientes: un coste computacional elevadísimo ya que el parámetro de tolerancia se aumenta desde un mínimo a un valor máximo para cada semilla, realizándose por tanto el proceso de crecimiento para cada valor de paso de la tolerancia; y que el criterio para determinar qué paso da la mejor región se define exclusivamente para un tipo de imagen muy específica (mamografías en escala de grises). Hay otros algoritmos adaptativos de crecimiento de regiones [19], [20] pero vuelven a ser diseñados de forma específica para la imagen en cuestión.

Otra posible clasificación dentro de los algoritmos de segmentación es la que distingue algoritmos que usan un paso de crecimiento fijo y los que crecen con paso variable. En un proceso típico de crecimiento de regiones, la condición de inclusión es siempre la misma, es decir, la región crece con una determinada condición.

Con la técnica multipaso propuesta en [21], la condición de inclusión cambia automáticamente hasta encontrar su valor óptimo. Este algoritmo introduce como novedad un criterio basado en contraste para detener la condición de crecimiento, aplicable a imágenes de diferente naturaleza y con una condición de inclusión adaptativa y automática.