

METODOLOGÍA

“El método es necesario para la investigación de la verdad”.

René Descartes.

Describimos en este capítulo los fundamentos científicos del proyecto realizado, así como las diferentes técnicas de procesado de imagen que hemos escogido, analizado y desarrollado para alcanzar los objetivos que nos marcamos en el primer capítulo de la presente memoria.

En primer lugar, en la introducción al capítulo, realizamos una revisión de los distintos artículos y técnicas que han fundamentado nuestro trabajo posterior. En la primera sección detallamos los pasos seguidos en el diseño del algoritmo de segmentación de imágenes tridimensionales, dando cuenta además de la importancia de la selección adecuada de diferentes parámetros y premisas que podrían condicionar en última instancia el éxito del proyecto. En la segunda sección describimos el desarrollo realizado para caracterizar imágenes de modo que se optimice la posterior recuperación de las mismas.

5.1. Introducción

El diseño de algoritmos de segmentación y caracterización de imágenes médicas en 3D precisa de un amplio estudio previo de las distintas soluciones que se encuentran en la literatura, además de las bases de ambas operaciones, detalladas en esta memoria en los capítulos 3 y 4.

Las imágenes en tres dimensiones requieren de una capacidad computacional muy superior a la de las imágenes en dos dimensiones, por lo que el desarrollo de las líneas de investigación que trabajan con imágenes tridimensionales es reciente y escaso.

Destacan los artículos recientemente publicados por T. Grenier et al., en los que se propone un método de segmentación por crecimiento de regiones con adaptación de modelos de forma [25][26]. Esta solución utiliza un método no lineal, en el que la actualización de los parámetros del crecimiento de regiones se lleva a cabo utilizando la información estadística otorgada por el modelo de forma adaptativo, que obtiene información de cada uno de los vóxeles que conforman la frontera de la región segmentada y la no segmentada.

Por otro lado, y haciendo uso de la técnica de segmentación conocida como *Level Set*, A. Bosnjak, G. Montilla et. al. utilizan este método para segmentar imágenes médicas en un proceso de cirugía dirigida, particularmente similar al proyecto VirSSPA que nos ocupa. Este artículo es especialmente interesante y didáctico, ya que en primer lugar establece una comparación entre tres métodos de segmentación tridimensional distintos [27]: crecimiento de regiones, *Cubic Spline* manual, y *Level Set*. Previamente utiliza un filtrado difusivo anisotrópico para preprocesar la imagen.

No obstante lo anterior, y dadas las características específicas de nuestra solución, necesitábamos un método transparente al usuario facultativo y de uso cómodo y sencillo y que, además, añadiera pasarelas de interacción para adaptar el resultado a las necesidades del personal médico.

Es por ello que decidimos adaptar un algoritmo de segmentación por crecimiento de regiones 2D [28][29] al caso tridimensional, como núcleo del proceso de segmentación, al que posteriormente se añadiría un robusto paso de preprocesado y una plataforma de adaptación de los resultados a las necesidades del facultativo. El algoritmo de segmentación seleccionado es el desarrollado por B. Acha, C. Serrano e I. Fondón, para segmentar imágenes de quemaduras a color haciendo uso de un parámetro de distancias de color adaptativo y de una condición de parada basada en el contraste.

Por último, y para la caracterización de imágenes médicas en tres dimensiones, y basándonos en algunos conceptos de la solución desarrollada por C. Zhang y T. Chen [37], desarrollamos una solución muy simple como primer paso para posteriores desarrollos (ver Capítulo 7).

5.2. Diseño de Algoritmos de Segmentación de Imágenes Médicas en tres dimensiones para Planificación Quirúrgica

5.2.1. Introducción

La segmentación es uno de los aspectos críticos de cualquier proceso de tratamiento digital de imágenes médicas, puesto que permite extraer eficientes criterios de análisis y estudio de patologías y, por otro lado, potentes herramientas de simulación y planificación quirúrgica. Además, los últimos avances en las técnicas de adquisición de imágenes médicas dotan a la segmentación en tres dimensiones de un especial interés para el facultativo, que podrá alcanzar altas cotas de fiabilidad en la simulación virtual del proceso quirúrgico.

Se ha comprobado que, en el proceso de planificación quirúrgica, el grueso del tiempo de ejecución se invierte en segmentar el volumen de estudio. *VirSSPA* utiliza una segmentación o bien basada en umbrales o bien basada en selección de semillas y crecimiento de regiones [1]. Pero este algoritmo adolece de algunas limitaciones, dado que el tiempo de cómputo es muy elevado, los resultados obtenidos se alejan en ocasiones de lo esperado y el médico ha de fijar experimentalmente tanto los umbrales como las sucesivas semillas en las distintas alternativas de la herramienta de planificación.

Para dar respuesta a lo anteriormente descrito, y tras estudiar minuciosamente las soluciones que la literatura nos proporciona, proponemos un método de segmentación tridimensional basado en crecimiento de regiones por tolerancia adaptativa y optimización de contraste, precedido de un paso fundamental de preprocesado, sin el que el algoritmo difícilmente podría sustentarse. Es por esto que, tras describir sucintamente los distintos pasos del procesado de las imágenes médicas, explicaremos por qué es necesario preprocesar las imágenes médicas. Posteriormente, fundamentaremos matemáticamente el algoritmo de segmentación escogido y desarrollaremos el significado físico y matemático de los distintos parámetros que intervienen en proceso. Por último, explicaremos cómo queremos que el facultativo interactúe con la aplicación, de modo que él pueda ser en última instancia el que decida si el resultado de la segmentación es correcto o si, por el contrario, desearía afinar los resultados. Podemos observar el diagrama de flujo en la figura 5.1.

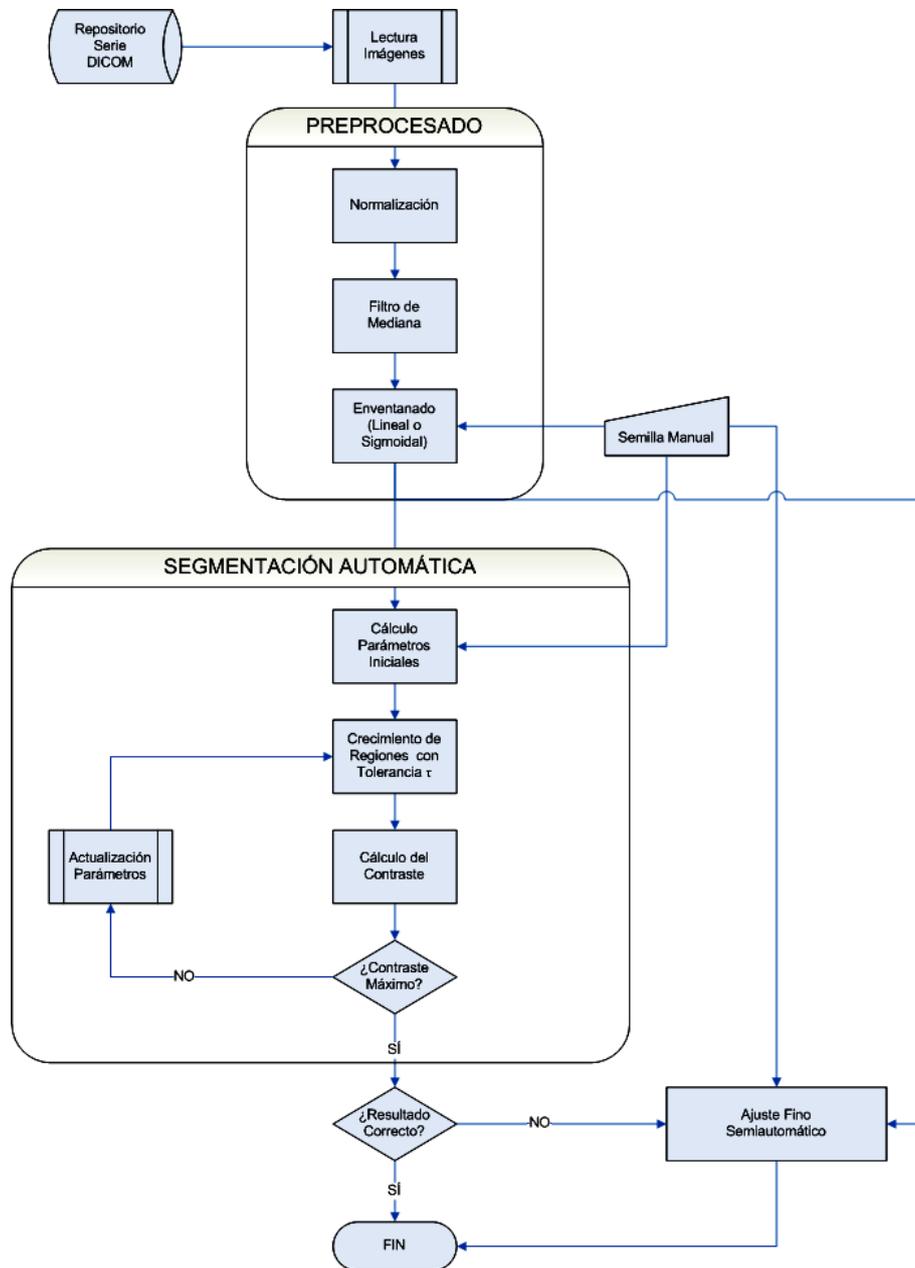


Figura 5.1: Diagrama de la estructura del algoritmo. Tras la lectura de los ficheros DICOM, ubicados en el repositorio, la imagen 3D es sometida a un preprocesado fundamental para obtener resultados adecuados. El proceso de segmentación permite además refinar los resultados si el facultativo considera que no son los adecuados.

5.2.2. Necesidad de un paso de preprocesado

Tal y como describimos en la sección 2.2.2.1, los dispositivos de adquisición influyen en la distribución final de los niveles de intensidad de la imagen que es necesario procesar. Tanto es así que parámetros tales como el número de cabezales del tomógrafo, el nivel de intensidad de la radiación emitida, las emisiones electromagnéticas a las que pueda verse expuesto el mismo, pueden determinar de forma crucial los resultados del proceso de segmentación. Además, también influye de forma directa el formato de codificación de imagen del dispositivo, la profundidad de bit por píxel de que éste dispone, puesto que esto afecta al fondo de escala de la representación de niveles de intensidad de la imagen, si tenemos en cuenta que, finalmente, todas las imágenes dispondrán de 16 bits de profundidad de píxel para la representación de los niveles de intensidad en los archivos de la norma DICOM.

Por tanto, es necesario eliminar de la forma más eficiente posible la influencia de las técnicas de adquisición, las interferencias electromagnéticas y el formato de codificación de las imágenes. Para ello, se propuso un doble esquema de trabajo. Un primer esquema basado en normalización de la imagen, filtro de mediana y un posterior inventariado lineal de la imagen centrado en la región de interés de la segmentación. El segundo esquema mantenía la normalización y el filtrado de mediana, pero sustituía el inventariado lineal por una transformación sigmoideal (no lineal, por tanto) para centrar el procesado en la región de interés (ROI).

5.2.2.1. Normalización

La normalización consigue adaptar el rango dinámico de grises entre crestas y valles del histograma de la imagen a un rango deseado para facilitar el procesado en las siguientes etapas. Así pues, se normaliza la imagen otorgando el valor de gris cero al menor valor de gris de la imagen original y, análogamente, el valor de gris uno al máximo valor de gris de la imagen original, ponderando los demás de forma lineal. La ecuación que define el proceso de normalización de la imagen tridimensional es:

$$I_N(x, y, z) = \frac{I_0(x, y, z) - \text{mín}(I_0(x, y, z))}{\text{máx}(I_0(x, y, z)) - \text{mín}(I_0(x, y, z))} \quad (5.1)$$

donde $I_N(x, y, z)$ es la imagen tras el proceso de normalización, $I_0(x, y, z)$ es la imagen original, y las funciones máx y mín son los operadores mayor y menor nivel de intensidad, respectivamente.

5.2.2.2. Filtrado de Mediana

El filtro de Mediana es el encargado de eliminar el ruido de las imágenes. Entendemos por ruido en imágenes digitales cualquier valor de un píxel de una imagen que no se corresponde exactamente con la realidad. Cuando se adquiere una imagen digital, ésta está contaminada por ruido. El ruido se debe, la mayoría de las veces al equipo electrónico utilizado en la captación de las imágenes (ruido de cuantificación de la imagen, efecto de niebla en la imagen, etc.) y al ruido añadido en los tramos de transmisión (posibles interferencias o errores al transmitir los bits de información).

Vamos a distinguir dos tipos de ruido:

- **Ruido gaussiano:** se caracteriza por tener un espectro de energía constante para todas las frecuencias. Cuando se presenta este problema, el valor exacto de cualquier píxel es diferente cada vez que se captura la misma imagen. Este efecto, suma o resta un determinado valor al nivel de gris real y es independiente de los valores que toma la imagen. El ruido gaussiano tiene un efecto general en toda la imagen, es decir, la intensidad de cada píxel de la imagen se ve alterada en cierta medida con respecto a la intensidad en la imagen original.
- **Ruido impulsivo:** se caracteriza por la aparición de píxeles con valores arbitrarios normalmente detectables porque se diferencian mucho de sus vecinos más próximos. Por el contrario, se observa que el ruido impulsivo tiene un efecto más extremo sobre un subconjunto del total de píxeles de la imagen. Un tanto por ciento de los píxeles de la imagen toman arbitrariamente el valor extremo 0 ó 1.

Los filtros de suavizado lineales o filtros paso bajo tienden a difuminar los bordes a causa de que las altas frecuencias de una imagen son atenuadas. La visión humana es muy sensible a esta información de alta frecuencia. La preservación y el posible realce de este detalle es muy importante al filtrar. Cuando el objetivo es más la reducción del ruido que el difuminado, el empleo de los **filtros de mediana** representan una posibilidad alternativa.

En el filtrado de mediana, como observamos en la figura 5.2, el nivel de gris de cada píxel se reemplaza por la mediana de los niveles de gris en un entorno de este píxel, en lugar de por la media. Recordar que la mediana M de un conjunto de valores es tal que la mitad de los valores del conjunto son menores que M y la mitad de los valores mayores que M , es decir, en un conjunto ordenado de mayor a menor o viceversa, sería el valor de la posición central.

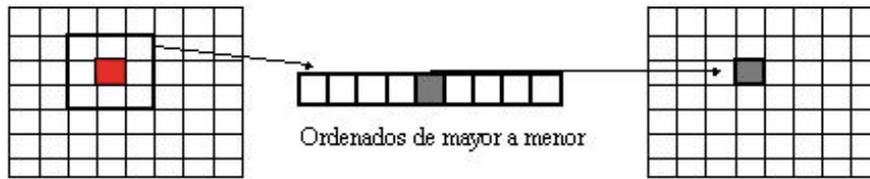


Figura 5.2: En el filtrado de Mediana, el valor de un píxel se sustituye por la mediana de los píxeles de un vecindario escogido *ad hoc*.

El filtro de la mediana no puede ser calculado con una máscara de convolución, ya que es un filtro no lineal. Como se selecciona el valor de centro, el filtrado de mediana consiste en forzar que puntos con intensidades muy distintas se asemejen más a sus vecinos, por lo que observamos que el filtro de mediana es muy efectivo para eliminar píxeles cuyo valor es muy diferente del resto de sus vecinos, tal y como sucede en imágenes afectadas por ruido.

5.2.2.3. Enventanado Lineal y Expansión Automática de Histograma

Por otro lado, no todos los rangos de nivel de gris que aparecen en las imágenes CT nos interesan de igual modo, puesto que, tras la normalización, podremos identificar una zona correspondiente al fondo, el aire y elementos externos indeseados (camilla, sábana,...), y otra zona de interés correspondiente al cuerpo del paciente. Así pues, habremos de realizar una expansión automática del histograma de las imágenes CT que elimine los elementos externos y permita observar mejor los detalles de la región de interés.

La expansión automática de histograma de cada imagen CT se lleva a cabo siguiendo los siguientes pasos, y se ilustra en la figura 5.3:

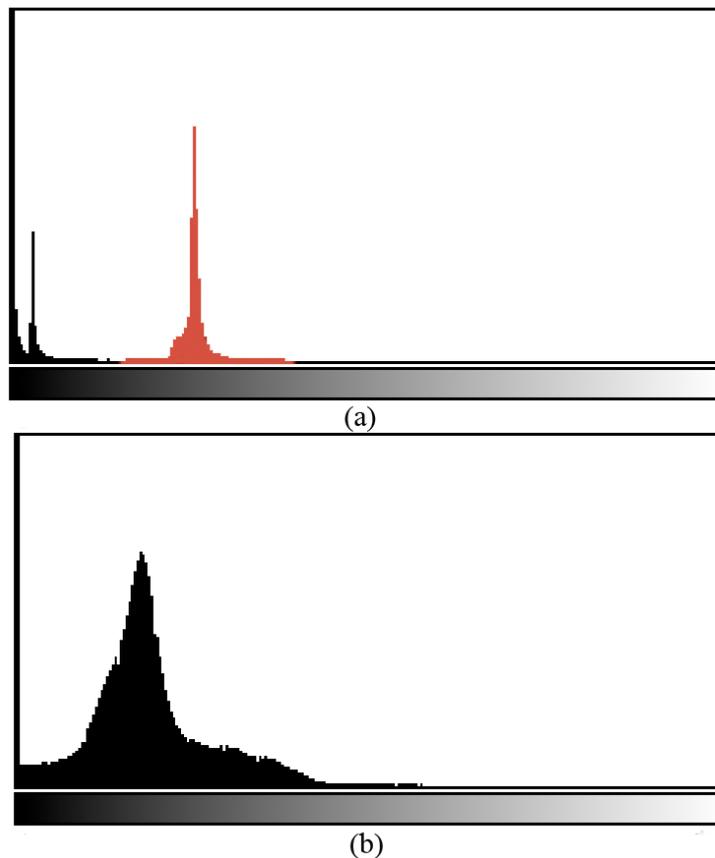


Figura 5.3: Enventanado Lineal y Expansión del Histograma. (a) En el histograma de la imagen normalizada localizamos la ROI. (b) Expandimos el histograma de la ROI al nivel inferior y superior de representación de los niveles de intensidad de la imagen.

1. Cálculo del histograma de la imagen normalizada.
2. Descarte del primer máximo ubicado en cero, correspondiente a la zona externa al campo de visión.
3. Localización del siguiente máximo, correspondiente al fondo de aire.
4. A partir del segundo máximo, es necesario avanzar en el histograma hasta que se produzca una diferencia significativa y creciente positiva en los valores del histograma. A partir de ese nivel, comienza la zona interés.
5. Expansión del histograma resultante, ubicando en cero el mínimo nivel de la región de interés y ponderando los demás niveles de forma lineal.

Matemáticamente,

$$I_E(x, y, z) = \frac{I_N(x, y, z) - \text{mín}(I_R(x, y, z))}{\text{máx}(I_N(x, y, z)) - \text{mín}(I_R(x, y, z))} \quad (5.2)$$

donde $I_E(x, y, z)$ es la imagen tras el proceso de expansión, $I_N(x, y, z)$ es la imagen normalizada, $I_R(x, y, z)$ es la región de interés y las funciones máx y mín son los operadores mayor y menor nivel de intensidad, respectivamente.

5.2.2.4. Transformación Sigmoidal

La transformación sigmoidal es una transformación orientada a punto, es decir, que afecta al nivel de intensidad de cada vóxel independientemente del nivel de intensidad de sus vecinos. La transformación sigmoidal aumenta el contraste de la imagen, aumentando a su vez la capacidad de distinción entre claros y oscuros, ya que éstos se encuentran más distanciados entre sí en el histograma. Este filtro mapea un rango específico de niveles de intensidad a un nuevo rango de intensidad realizando una transición suave y continua en los extremos del intervalo. Los filtros sigmoidales suelen ser utilizados para centrar la atención en un determinado rango de valores y atenuar los niveles de intensidad que están fuera de este rango.

Existen diversas transformaciones sigmoidales, y todas ellas se basan en diversas combinaciones de funciones sinusoidales e hiperbólicas. La expresión de la transformación sigmoidal escogida es:

$$s(x) = (\text{máx} - \text{mín}) \cdot \frac{1}{1 + e^{\left(\frac{x-\beta}{\alpha}\right)}} + \text{mín} \quad (5.3)$$

donde x es el nivel de intensidad del vóxel de entrada, $s(x)$ es el nivel de intensidad tras la transformación, α es el ancho de la ventana sigmoidal, β es el centro de la ventana sigmoidal y máx y mín son, respectivamente, el nivel superior e inferior del rango de representación a la salida de la transformación.

Pero para que el filtrado sigmoidal favorezca la segmentación del tejido que interesa al facultativo, es necesario que los parámetros de la transformación sigmoidal dependan del nivel de intensidad de la semilla dispuesta por el facultativo a tal efecto. Es por eso que los parámetros del filtro sigmoidal se definen, a su vez, como:

$$\alpha = p_w \cdot x_{seed} \quad (5.4)$$

$$\beta = p_c \cdot x_{seed} \quad (5.5)$$

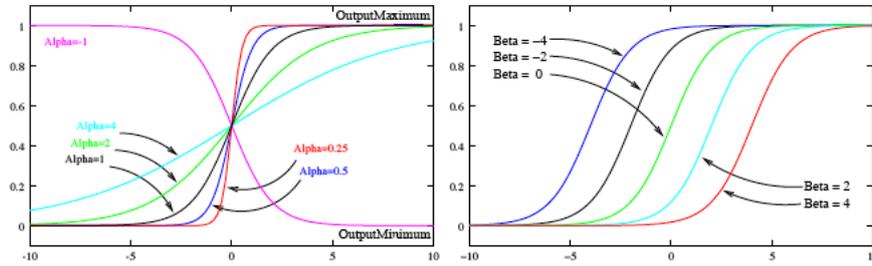


Figura 5.4: Efectos de varios parámetros en el filtrado sigmoidal. El parámetro α define el ancho de la ventana sigmoidal. El parámetro β define el centro de la ventana sigmoidal.

donde x_{seed} es el nivel de intensidad de la semilla, y p_w y p_c son los coeficientes correctores del ancho y el centro de la ventana sigmoidal, respectivamente.

5.2.3. Crecimiento de regiones tridimensional basado en tolerancia adaptativa y contraste óptimo

Las técnicas de crecimiento de regiones presentan dos aspectos críticos: la selección de semilla y la elección de la condición de crecimiento o inclusión en la región (*merging condition*).

El primero de ellos viene resuelto por el paso de parámetros que nos proporciona el facultativo. El médico dispone manualmente la semilla que inicia el crecimiento y, además, indica con qué tipo de tejido se corresponde, a saber, óseo, muscular, graso, órgano o vascular. El nivel de intensidad de la semilla se utiliza, por una parte, para determinar los parámetros de la transformación sigmoidal, tal y como hemos explicado anteriormente, y por otra parte, para establecer los parámetros que inicial el crecimiento de regiones. El tipo de tejido, en cambio, determina únicamente los coeficientes correctores del ancho y el centro de la ventana sigmoidal.

La condición para que un nuevo vóxel se una a la región es que su valor de gris sea similar al de los vóxeles ya incluidos. Esta similitud se traduce en que se cumpla la siguiente condición:

$$\bar{F} - \tau \leq F_{ijk} \leq \bar{F} + \tau \quad (5.6)$$

donde \bar{F} es el nivel de intensidad medio de los vóxeles incluidos en la región, τ es el paso de tolerancia, que irá aumentando de forma iterativa hasta

obtener la región segmentada óptima (más adelante veremos el criterio de parada) y F_{ijk} es el valor de gris del vóxel de coordenadas (i, j) situado en el corte axial k .

El factor de tolerancia τ sigue la expresión:

$$\tau = \kappa \sigma \quad (5.7)$$

donde σ es la desviación típica de los niveles de intensidad de la región segmentada y κ es el factor de confianza o cobertura, que determina el peso que le concedemos a la desviación típica a la hora de establecer el intervalo de inclusión.

Para iniciar el crecimiento, es necesario establecer, como observamos en el diagrama de flujo de la figura 5.1, los parámetros iniciales, de manera que pueda efectuarse una primera iteración del algoritmo de crecimiento de regiones. Así pues, el nivel de intensidad medio, \bar{F} se define como el nivel de intensidad medio del vecindario tridimensional de radio 2 del vóxel semilla v_s , esto es,

$$\bar{F} = \frac{1}{125} \sum_{v_{ijk} \in N_2(v_s)} F_{ijk} \quad (5.8)$$

Por su parte, κ toma inicialmente un valor optimizado empíricamente y cuyo estudio se adjunta en el capítulo posterior a éste. Por último, y de forma análoga al nivel medio de intensidad, la desviación típica inicial se calcula como:

$$\sigma = \sqrt{\frac{1}{125} \sum_{v_{ijk} \in N_2(v_s)} (F_{ijk} - \bar{F})^2} \quad (5.9)$$

Para relajar la condición en cada iteración y aumentar la tolerancia de inclusión en la región, aumentamos κ en un valor también optimizado empíricamente, denominado paso del factor de confianza $\Delta\kappa$, de modo que en la iteración $(n + 1)$ -ésima, y mientras no tenga lugar la condición de parada, se producen las siguientes actualizaciones:

$$\kappa_{n+1} = \kappa_n + \Delta\kappa \quad (5.10)$$

$$\bar{F} = \frac{1}{N_R} \sum_{v_{ijk} \in R} F_{ijk} \quad (5.11)$$

$$\sigma = \sqrt{\frac{1}{N_R} \sum_{v_{ijk} \in R} (F_{ijk} - \bar{F})^2} \quad (5.12)$$

Una vez que la región ha crecido con una determinada tolerancia τ , el siguiente paso es verificar si la región obtenida es óptima. Si no es óptima, el crecimiento de regiones se repetirá, pero con una condición más relajada, es decir, con un parámetro de tolerancia τ mayor que el anterior.

El criterio óptimo para la adaptación automática de la tolerancia τ , es decir, obtener al final del proceso de crecimiento la mejor región, consiste en maximizar un parámetro de contraste. Este parámetro de contraste se calcula de la siguiente forma:

$$c = \frac{|\bar{b}_i - \bar{b}_e|}{\bar{b}_i + \bar{b}_e} \quad (5.13)$$

donde \bar{b}_i y \bar{b}_e representan el nivel de intensidad medio de los vóxeles pertenecientes al borde interior y exterior de la región crecida, respectivamente, que a su vez se definen como:

$$b_i = \left\{ v_{ijk} \right\} \left| v_{ijk} \in R \cap N\{v_{ijk}\} \notin R, \quad \forall (i, j, k) \quad (5.14)$$

$$b_e = \left\{ v_{ijk} \right\} \left| v_{ijk} \notin R \cap N\{v_{ijk}\} \in R, \quad \forall (i, j, k) \quad (5.15)$$

donde v_{ijk} es un vóxel cualquiera, R es la región de crecimiento y $N\{\cdot\}$ es el operador vecindario tridimensional de radio 1.

Aunque la anterior es la definición más estricta, a efectos prácticos, el valor medio de los vóxeles pertenecientes al borde interior será calculado como el nivel de intensidad medio de la región crecida. En cambio, para el cálculo del nivel de intensidad medio del borde exterior, realizamos la siguiente operación morfológica:

$$I \times \left[M \vee (M \oplus B) \right] = I \times \left[M \vee \left\{ z \mid (\hat{B})_z \cap M \neq \emptyset \right\} \right] \quad (5.16)$$

donde I es la imagen tras el proceso de segmentación, M es la imagen de máscaras, en la que los vóxeles valen 1 si el vóxel correspondiente en la imagen I pertenece a la región segmentada y 0 en caso contrario, y B es el ele-

mento estructural de radio unidad con el que efectuamos la dilatación.

Esto es, efectuamos la multiplicación vóxel a vóxel de la imagen tras la segmentación y un *or* exclusivo entre la máscara tras la segmentación y la dilatación de la máscara segmentada con un elemento estructural B de radio 1. La dilatación de I con el elemento estructural B es el conjunto formado por todas las localizaciones del origen del elemento estructural donde el elemento estructural trasladado y reflejado solapa al menos con una porción de I . Después hallamos el valor medio de los vóxeles que forman el borde exterior en la imagen original.

5.2.4. Ajuste final de los resultados

El algoritmo de segmentación por crecimiento de regiones, tolerancia adaptativa y optimización de contraste explicado en la sección anterior impone, por definición, un hándicap al facultativo. Al ser un proceso automático, cuando se cumple la condición de contraste máximo, el algoritmo efectúa las salidas correspondientes y genera las imágenes finales sin que el médico pueda comprobar previamente si el resultado final es de su agrado o no. Es por esto que hemos decidido implementar, de forma paralela al anterior, un algoritmo semiautomático que, basándose en los principios del procesado de imagen expuestos anteriormente, permita que el médico interactúe en la segmentación de las imágenes y afine a su gusto los resultados.

En la figura 5.5 observamos el diagrama de flujo del algoritmo de ajuste semiautomático.

El algoritmo toma como punto de partida la imagen preprocesada, con las mismas técnicas expuestas en el apartado anterior. A continuación, y tras la disposición de la semilla por parte del facultativo, se procede a calcular los parámetros que inician el crecimiento de regiones por factor de confianza adaptativo. Una vez finalizado el crecimiento, el médico observa los resultados y decide si ha obtenido resultados adecuados o si, por el contrario, sería necesario volver a efectuar otra segmentación. En tal caso, existen dos opciones:

- Si la imagen queda infrasegmentada, el facultativo escogerá la opción **Segmentar Más**, esto es, en la siguiente iteración habremos de aumentar el factor de confianza.
- Si la imagen queda sobresegmentada, el facultativo escogerá la opción **Segmentar Menos**, esto es, en la siguiente iteración habremos de disminuir el factor de confianza.

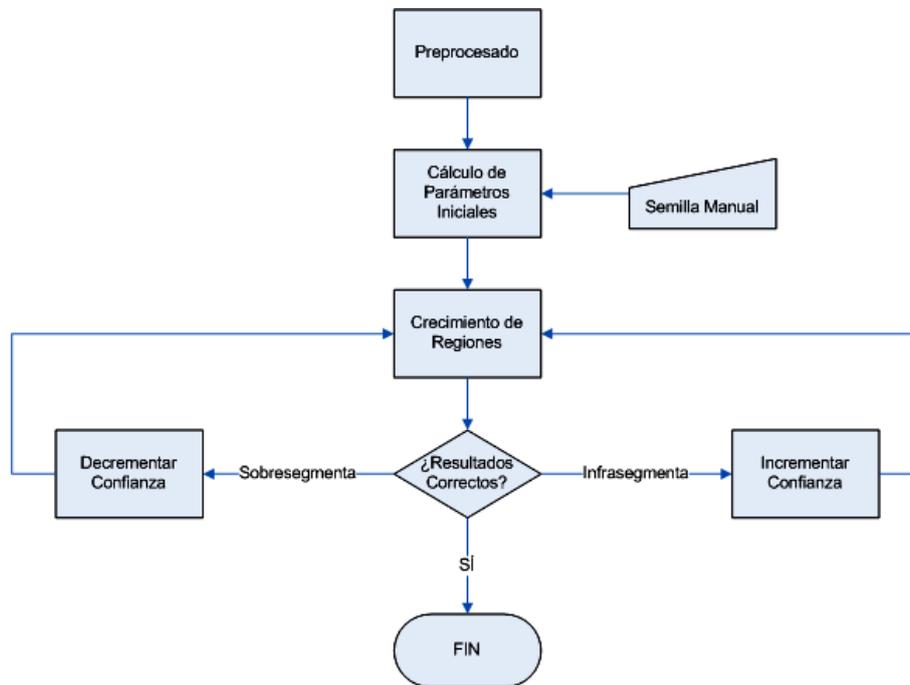


Figura 5.5: Diagrama de flujo del algoritmo de ajuste. Tras efectuarse el preprocesado indicado, se procede a realizar una segmentación por crecimiento de regiones con parámetros iniciales otorgados por la semilla inicial. Si los resultados son los esperados por el médico, el proceso finaliza. Si el médico observa que el programa sobresegmenta la imagen, debe reducirse el factor de confianza y volver a aplicar el crecimiento de regiones. Si en cambio observa que infrasegmenta, ha de aumentarse el factor de confianza y volver a crecer.

Para optimizar la idoneidad de los resultados, es necesario además añadir una condición. Si tras una infrasegmentación se sucede una sobresegmentación, o viceversa, el paso del coeficiente de confianza se verá reducido a la mitad, de modo que vayamos afinando en la búsqueda del factor de confianza que obtiene los mejores resultados.

5.2.5. Postprocesado

La rugosidad inherente de algunos tipos de tejidos requiere de un paso de postprocesado para, fundamentalmente, eliminar la sensación de falsa desconexión entre los diferentes vóxeles que conforman el tejido segmentado. Es por esto que, para tejidos tales como la grasa o el músculo, hemos decidido aplicar un cierre volumétrico que utiliza como elemento estructural una esfera de radio r , cuyo valor ha sido hallado experimentalmente (el estudio correspondiente puede ser consultado en el siguiente capítulo).

El **cierre morfológico** de la imagen segmentada I por el elemento estructural esférico B no es más que la dilatación de I por B seguida posteriormente de una erosión del resultado anterior por el elemento estructural B . Matemáticamente:

$$I \bullet B = (I \oplus B) \ominus B \quad (5.17)$$

La interpretación geométrica es bastante sencilla. El cierre de I por B es la unión de todas las traslaciones de B que no solapan con I . Como en el caso de la apertura, el cierre también suaviza los contornos de las figuras. En cambio, suelda las roturas estrechas y rellena los entrantes y los huecos más pequeños que el elemento estructural.

5.3. Caracterización de Imágenes Médicas 3D para Planificación Quirúrgica

5.3.1. Introducción

Son muchas las propiedades de la herramienta de planificación quirúrgica VirSSPA que pueden ser aprovechadas para la integración de un sistema de recuperación de imágenes médicas como una más de sus múltiples funcionalidades.

Una vez mejorado el algoritmo de segmentación, podemos extraer características de una manera mucho más sofisticada y eficiente, y por tanto ajustar la búsqueda y afinar la idoneidad de los resultados obtenidos, utilizando por tanto el conocimiento adquirido durante el estudio de los distintos casos para acometer la planificación de una nueva operación.

Tras el estudio del Estado del Arte sobre caracterización y recuperación de imágenes médicas en tres dimensiones pueden extraerse algunas conclusiones:

1. Dado el nivel de precisión y exactitud que la herramienta VirSSPA proporciona y exige, la recuperación de imágenes debe estar fundamentalmente basada en contenido, esto es, en parámetros de forma.
2. Una herramienta de planificación quirúrgica que afronte el problema con la mayor flexibilidad y versatilidad posibles deberá ser capaz de integrar en su sistema de recuperación de información diversas modalidades de imagen con sus correspondientes protocolos de adquisición.
3. Para poder recuperar correctamente información referente a imágenes por contenido es necesario realizar previamente un paso de normalización de forma, más conocido como registro de imágenes.
4. Dada la complejidad que aporta la tridimensionalidad a cualquier sistema de procesado de imágenes, la intervención del facultativo será prácticamente imprescindible, aunque uno de los objetivos de nuestro trabajo es minimizar al máximo su intervención.

Tomando como base las premisas anteriores, describiremos en primer lugar el procedimiento seguido para extraer características significativas de las imágenes, de modo que posteriormente puedan utilizarse para realizar una búsqueda. Posteriormente expondremos los principios matemáticos por los que se rigen tanto las características escogidas como el espacio paramétrico y la métrica que define la idoneidad de la búsqueda. Por último, expondremos

brevemente la forma escogida para mostrar los resultados finales. Hemos optado por llevar a cabo una metodología secuencial, de modo que cada nueva aproximación sea más compleja y eficiente que la anterior, hasta llegar a un nivel óptimo en los resultados obtenidos.

5.3.2. Extracción de características

La extracción de características debe ser realizada en dos fases:

1. Una primera, en el transcurso del proceso de simulación, en la que el facultativo solicita información relativa al caso que está tratando. En esta primera fase, se extraen las características que se consideren necesarias, o las que precise el facultativo, para que sean utilizadas en una búsqueda simultánea al proceso de simulación. Esta fase es opcional, y viene dada por la petición del médico.
2. Una segunda fase, que tiene lugar al final del proceso de simulación del caso, en que se extraen una serie de características comunes a todos los casos, de modo que se cree una entrada asociada a dicho caso en la base de datos sobre la que se efectuarán posteriores búsquedas.

Algunas características, tales como las semánticas, pueden ser extraídas directamente de la información perteneciente a las cabeceras de los ficheros DICOM. Sin embargo, la inmensa mayoría de las características que los facultativos necesitan para realizar una búsqueda eficiente han de ser extraídas después de, en primer lugar, la segmentación de la región de interés y, posteriormente, después del registro de las volúmenes segmentados. Es importantísimo que las características de forma extraídas se correspondan con la caracterización de volúmenes alineados a un volumen de referencia del que conocemos su sistema de coordenadas, la métrica de distancias y la magnitud de la misma.

5.3.3. Primera aproximación: análisis de forma de estructuras óseas

5.3.3.1. Introducción

En primer lugar, y como una primera aproximación y toma de contacto, decidimos caracterizar diversas estructuras óseas por ser ésta quizás una de las aplicaciones con más proyección en la recuperación de casos clínicos, habida cuenta de la multitud de artículos y estudios existentes en la literatura a este respecto.

5.3.3.2. Metodología

Pretendemos caracterizar diversas estructuras óseas mediante la extracción de las siguientes características: calibre medio, longitud y curvatura. Para ello utilizaremos varias estructuras óseas obtenidas tras un proceso previo de segmentación. En esta primera aproximación hemos caracterizado tibias, peronés y fémures.

Previamente, para una extracción eficaz de características, es necesario registrar las imágenes de manera que los ejes principales coincidan con los del sistema de representación canónico con respecto al cual vamos a realizar las medidas. En primer lugar se construye una matriz cuadrada de orden 3 con los momentos de orden 2 del modelo tridimensional:

$$S = \begin{bmatrix} M_{200} & M_{110} & M_{101} \\ M_{110} & M_{020} & M_{011} \\ M_{101} & M_{011} & M_{002} \end{bmatrix} \quad (5.18)$$

Los ejes principales se corresponden con los autovectores de la matriz S , análisis conocido como Análisis en Componentes Principales (PCA). El autovector correspondiente al mayor autovalor es el primer eje principal. El autovector correspondiente al segundo autovalor es el segundo eje principal. Análogamente, el autovector correspondiente con el tercer autovalor es el tercer eje principal. Para imponer un criterio de unicidad en el resultado, los momentos de tercer orden M_{300} y M_{030} han de ser positivos después de la transformación.

Una vez conocidos los ejes principales de la imagen original, es necesario someter a la imagen a una transformación rígida. Las transformaciones rígidas o mapeos rígidos se definen como transformaciones geométricas que mantienen todas las distancias entre los diferentes puntos de cada imagen. Estas transformaciones también mantienen la rectitud de las líneas, la planitud de las superficies y los ángulos entre líneas rectas. Los problemas de registro que sólo involucran transformaciones rígidas se conocen como problemas de registro rígido. Las transformaciones rígidas, en general, constan de una traslación y una rotación.

Sea el vóxel $\mathbf{v}(x, y, z)$ perteneciente a la imagen original y el vóxel $\mathbf{u}(x, y, z)$ el elemento de imagen transformado correspondiente a \mathbf{v} . Se define la transformación rígida T de la siguiente forma:

$$\mathbf{u} = T\{\mathbf{v}\} \quad (5.19)$$

$$\mathbf{u} = \mathbf{R} \mathbf{v} + \mathbf{t} \quad (5.20)$$

donde \mathbf{t} es el vector **traslación** y \mathbf{R} es la matriz **rotación**.

El vector traslación se define a su vez como $\mathbf{t}^T = [t_x, t_y, t_z]$, es decir, se encarga de trasladar cada coordenada de cada vóxel una cantidad fija e igual para todos ellos. La matriz de rotación \mathbf{R} es una matriz **ortogonal**, esto es, se cumple

$$\mathbf{R}^T \mathbf{R} = \mathbf{I} \quad (5.21)$$

y por tanto

$$\mathbf{R}^{-1} = \mathbf{R}^T \quad (5.22)$$

Esta clase de matrices produce tanto rotaciones como reflexiones. Es por esto que debemos asegurarnos de que $\det(\mathbf{R}) = 1$, de modo que la transformación pueda ser únicamente una rotación y no una reflexión (que modificaría la naturaleza de nuestra imagen).

A su vez, la matriz de rotación \mathbf{R} se define como

$$\mathbf{R} = \mathbf{R}_x \mathbf{R}_y \mathbf{R}_z \quad (5.23)$$

$$\mathbf{R} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \theta_x & -\sin \theta_x \\ 0 & \sin \theta_x & \cos \theta_x \end{bmatrix} \begin{bmatrix} \cos \theta_y & 0 & \sin \theta_y \\ 0 & 1 & 0 \\ -\sin \theta_y & 0 & \cos \theta_y \end{bmatrix} \begin{bmatrix} \cos \theta_z & -\sin \theta_z & 0 \\ \sin \theta_z & \cos \theta_z & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (5.24)$$

donde las matrices \mathbf{R}_k hacen rotar el eje k un ángulo θ_k .

De un modo sintético, la transformación rígida T podría expresarse de la siguiente forma:

$$\begin{bmatrix} u_x \\ u_y \\ u_z \\ 1 \end{bmatrix} = \left[\begin{array}{ccc|c} & & & t \\ R & & & \\ \hline 0 & 0 & 0 & 1 \end{array} \right] \begin{bmatrix} v_x \\ v_y \\ v_z \\ 1 \end{bmatrix} \quad (5.25)$$

Una vez registradas las imágenes, podemos extraer las características independientemente de cómo estuvieran dispuestas originalmente las imágenes tridimensionales. El procedimiento seguido para caracterizar las estructuras óseas es el siguiente:

1. Calculamos el centro de masas de aproximadamente el 25% de los N cortes axiales que conforman la imagen tridimensional original.
2. Calculamos la distancia que va del centro de masas del primer corte axial en el que está ubicada la estructura ósea al centro de masas del último corte axial en el que está ubicada la estructura ósea. Denominamos a esta longitud L_R .
3. Calculamos la suma total de distancias parciales entre los centros de masas de los cortes axiales en los que hemos calculado los centroides. A esta longitud la denominamos L_T , medida real de longitud del hueso.
4. En cada uno de los cortes axiales seleccionados, hallamos el radio mínimo $r_{\text{mín}_i}$ y el radio máximo $r_{\text{máx}_i}$ de la superficie de estructura ósea con respecto al centro de masas calculado.
5. Definimos el calibre medio del hueso analizado como

$$r = \frac{1}{N} \sum_{i=1}^N \frac{r_{\text{máx}_i} + r_{\text{mín}_i}}{2} \quad (5.26)$$

6. Definimos el coeficiente aproximado de curvatura como

$$c = L_R/L_T \quad (5.27)$$

7. Definimos la excentricidad del calibre del hueso como

$$e = \frac{1}{N} \sum_{i=1}^N \sqrt{1 - \left(\frac{r_{\text{mín}_i}}{r_{\text{máx}_i}} \right)^2} \quad (5.28)$$