

Proyecto Fin de Carrera  
Ingeniería de Telecomunicación  
Escuela Técnica Superior de Ingenieros



---

**SEGMENTACIÓN DE MÚSCULOS  
BASADA EN EL USO DE HISTOGRAMAS  
Y MINIMIZACIÓN DE UNA FUNCIÓN  
DE ENERGÍA MEDIANTE EL  
ALGORITMO DE MAX-FLOW**

---

Lola Anula Gómez

Tutor: José Antonio Pérez Carrasco

*Sevilla, Septiembre de 2015*

**UNIVERSIDAD DE SEVILLA**

## Agradecimientos

En este punto, me gustaría dar las gracias a todas las personas que han contribuido directa o indirectamente en este trabajo.

En el plano personal, no puedo dejar de agradecer a mis padres, Mari y Mariano, todo lo que han hecho para que pueda llegar hasta este punto. Su apoyo incondicional, sus ánimos, su cariño, su paciencia y comprensión en todos los momentos difíciles, sus esfuerzos y demás detalles que han sido fundamentales para mí. Mis hermanos, M<sup>a</sup> José y Jerónimo, que en la distancia han sabido guiarme, cuidarme y animarme. Son y serán siempre mi ejemplo a seguir.

A todos mis amigos de siempre, Carolina, Rosa, Juan...y a todos los demás que siempre estáis ahí y hacéis mi vida mucho más bonita.

Y sirviendo de puente entre el plano personal y el profesional, debo mencionar a mis compañeros de carrera, por la experiencia compartida, los buenos momentos y el apoyo recibido.

Gracias a José Pérez Carrasco, tutor del proyecto, por la confianza depositada en mí para la realización del presente proyecto. También agradecerle las horas de atención dedicadas y toda la ayuda prestada.

Gracias a todos.

## Resumen

En este trabajo se describe el desarrollo de una aplicación para la segmentación automática de tejido musculoso estriado en tomografía computarizada. Esta tarea es complicada debido a que la intensidad y valores Hounsfield de los músculos suelen solapar con los tejidos circundantes (órganos, huesos). Esta superposición se debe principalmente a la presencia de tejido liso en numerosos órganos. Por otra parte, la segmentación de tejido musculoso es una tarea que requiere tiempo debido a la esencia 3D de los músculos. Por lo general, esta segmentación se implementa de forma manual o automático de algún tipo de músculo en concreto. En este trabajo, el algoritmo propuesto es general, automático, sencillo y rápido. El proceso de desarrollo se basa en cuatro etapas fundamentales, una etapa de preprocesamiento, con el fin de no tener en cuenta valores Hounsfield que no se corresponden con el músculo; una etapa de cálculo de la distancia a histograma; una etapa de segmentación utilizando un algoritmo Max-Flow y una etapa final de post-procesamiento para mejorar el resultado de la segmentación. El método de validación compara la superficie estimada con respecto a la forma muscular trazada manualmente por un experto. El error obtenido entre ambas superficies es siempre inferior al 0.1. Además, se han calculado diferentes coeficientes como DICE, jaccard, sensibilidad, sensibilidad y valor predictivo (VPP) para evaluar el rendimiento de nuestra aplicación. En zonas donde no se encuentran músculo liso se obtuvieron los valores DICE y jaccard superiores al 0,9 y 0.82 respectivamente.

**Palabras claves:** Segmentación, músculos, max-flow, tomografía computarizada.

# Índice

<b>Índice de Figura .....</b>	<b>vi</b>
<b>Índice de Tablas .....</b>	<b>vii</b>
<b>Introducción .....</b>	<b>1</b>
1.1    Introducción al Problema .....	1
1.2    Descripción del Trabajo .....	2
1.2.1    Objetivos .....	4
1.2.2    Sumario .....	4
<b>Músculos .....</b>	<b>6</b>
2.1    Introducción .....	6
2.2    Tejido muscular .....	7
<b>La Imagen Médica Digital .....</b>	<b>8</b>
3.1    Introducción .....	8
3.2    Tomografía Computarizada.....	9
<b>Técnicas de filtrado y Segmentación .....</b>	<b>12</b>
4.1    Introducción .....	12
4.2    Técnica de Segmentación.....	12
4.3    Segmentación de músculos.....	14
4.3.1    Introducción .....	14
4.3.2    Antecedentes .....	15
4.3.2    Algoritmo de Max-Flow .....	16
4.4    Técnicas de Filtrado.....	20

<b>Diseño e Implementación de la Metodología para la Segmentación de Músculos .....</b>	<b>22</b>
5.1 Descripción de las Imágenes .....	22
5.2 Pre-Procesamiento de las Imágenes .....	23
5.3 Distancia al histograma modelo .....	23
5.4 Proceso de Segmentación: Algoritmo Max-Flow .....	26
5.5 Etapa Post-Procesamiento .....	28
<b>Resultados.....</b>	<b>29</b>
6.1 Introducción .....	29
6.2 Análisis de los resultados .....	33
<b>Conclusiones y Perspectivas .....</b>	<b>36</b>
<b>Referencias.....</b>	<b>37</b>

# Índice de Figura

<b>Figura 1.</b> Diferentes densidades de los tejidos.....	2
<b>Figura 2.</b> Imágenes TC etiquetadas .....	3
<b>Figura 3.</b> Tipos de músculos. ....	6
<b>Figura 5.</b> Unidades Hounsfield típicas para distintos tejidos en estudios de TC .....	11
<b>Figura 6.</b> Proceso Global de la Segmentación de Imágenes. ....	13
<b>Figura 7.</b> Ejemplo de etiquetado de una imagen. ....	17
<b>Figura 8.</b> Ejemplo de un grafo dirigido capacitado. ....	19
<b>Figura 9.</b> 1) Imagen original. 2) Histograma.....	23
<b>Figura 11.</b> Imágenes calculadas de una rebanada CT. ....	25
<b>Figura 12.</b> Resultado de la etapa de Post-Procesamiento .....	28
<b>Figura 14.</b> Resultado de la segmentación de varias imágenes con presencia de músculo liso.. ....	35
<b>Figura 15.</b> Corte pelvis mujer: a) Imagen 568 TC. b) Imagen máscara. c) Imagen segmentada. ....	35

# Índice de Tablas

<b>Tabla 1.</b> Valores Hounsfield habituales para cada tipo de tejido humano escaneado con CT.....	15
<b>Tabla 2.</b> Valores Dice y Jaccard.....	30
<b>Tabla 3.</b> Valores Sensibilidad y Especificidad. ....	32
<b>Tabla 4.</b> Valores PPV. ....	33

# Capítulo 1

## Introducción

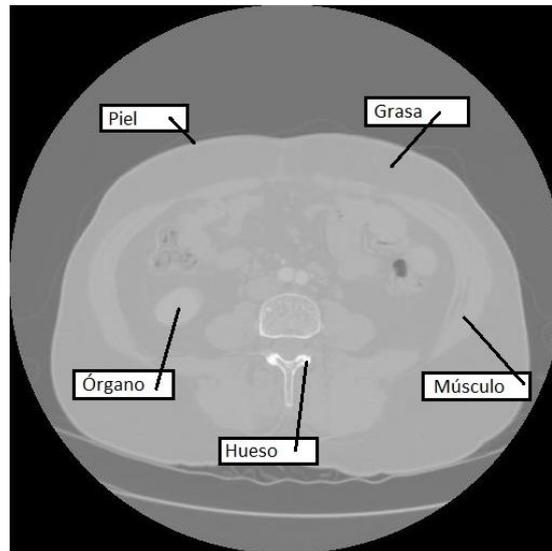
### 1.1 Introducción al Problema

La visión por computadora y el análisis de imágenes constituyen herramientas importantes que pueden ser usadas en numerosas áreas [1]. En el procesamiento de imágenes médicas, la segmentación es una herramienta importante para el análisis de estructuras anatómicas y tipos de tejido, así como para obtener la distribución espacial de las regiones funcionales, proporcionando una visión más detallada de la anatomía del cuerpo humano. Además de ser una técnica muy importante para el diagnóstico de varias enfermedades.

Las técnicas de segmentación de imágenes se basan en la organización o agrupamiento de un conjunto de formas, donde las principales características usadas en esta organización son la proximidad, similitud y continuidad. El proceso de segmentación divide una imagen en regiones (también llamadas clases o subconjuntos) que son homogéneas con respecto a una o más características [2]. La segmentación de imágenes está enmarcada en los problemas de visión por computadora, como una herramienta para el reconocimiento de objetos, basada en técnicas de extracción de formas, las cuales verifican tres propiedades básicas: ser suficientemente generales para poder describir un amplio rango de formas, permitir al mismo tiempo la extracción del objeto de la escena que lo contiene, y por último, facilitar la comparación con formas similares. Esta técnica de procesamiento de imágenes genera una imagen binaria, donde los puntos que pertenecen al objeto se representan con un uno, mientras que los que no pertenecen al mismo se representan con un cero.

La segmentación de ciertos tejidos musculosos es difícil debido a la presencia de músculo liso en algunos órganos o estructuras (como corazón, vejiga, útero, intestino, etc.). Además, los distintos tipos de músculos presentan grandes diferencias en densidades y, por tanto, diferentes valores Hounsfield. Esto implica la superposición de estos valores con los correspondientes a otro

tipo de tejidos tales como huesos (esponjoso), grasa y algunos órganos. En la Fig. 1 se muestran las diferentes densidades de los diferentes tejidos.



*Figura 1. Diferentes densidades de los tejidos.*

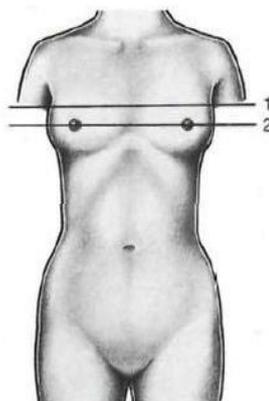
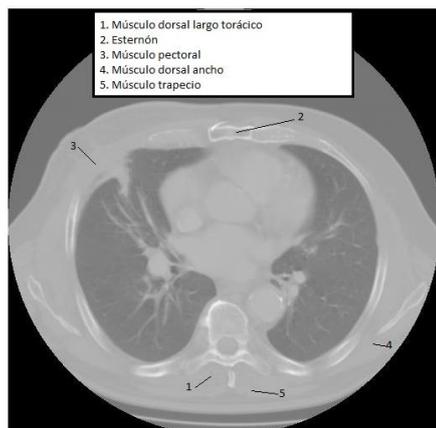
Una segunda dificultad en la segmentación de tejido musculoso es su esencia 3D. Por lo tanto, se requieren algoritmos rápidos y automáticos a fin de obtener la segmentación con reducidos tiempos de computación, con el fin de ayudar realmente a los radiólogos en el diagnóstico y tratamiento de enfermedades y en la planificación quirúrgica.

La segmentación de tejido musculoso ha sido abordada por numerosos autores [14, 15, 16] Por lo general, esta segmentación se implementa de forma manual o con algoritmos que usan técnicas simples tales como umbralización y que por tanto proporciona malos resultados. Además, la técnica de segmentación suelen ser muy específica de un tipo de músculo en concreto. Esta falta de generalización es un problema, ya que los radiólogos prefieren no considerar diferentes métodos de segmentación según sean las regiones a analizar. Por lo tanto, interesa un método general y adecuado que sea capaz de segmentar un amplio número de tejidos musculosos sin considerar su número ni su localización

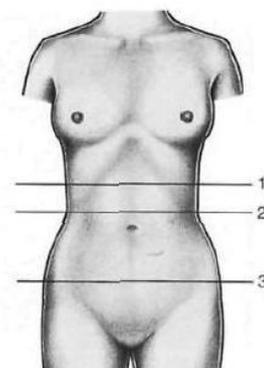
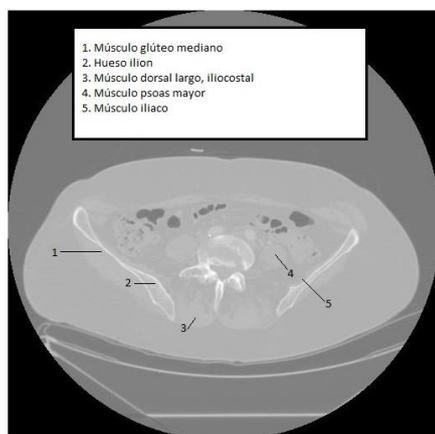
## 1.2 Descripción del Trabajo

En el presente trabajo se propone el desarrollo de un enfoque para la segmentación de músculos en imágenes adquiridas mediante un equipo de tomografía computarizada (CT) (Fig. 2), almacenadas en el formato DICOM (*Digital Imaging and Communications in Medicine*). Dicho enfoque está basado en el uso de histogramas y minimización de una función de energía. En primer lugar, se calcula la distancia de un histograma local a un histograma referencia del músculo para toda la imagen.

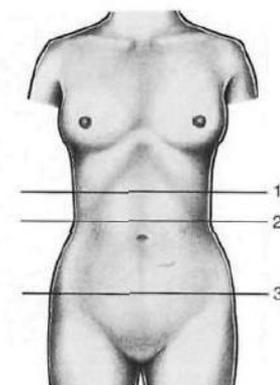
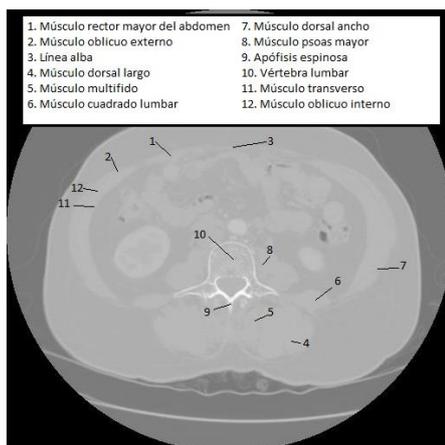
De modo, que la distancia será próxima a cero en las zonas de tejido musculoso, y será alta en las zonas de tejido no musculoso.



*Corte horizontal del tórax. Imagen obtenida mediante TC. Nivel 1 aproximadamente.*



*Corte horizontal de la cavidad abdominal. Imagen obtenida mediante TC. Nivel 3 aprox.*



*Corte horizontal de la cavidad abdominal. Imagen obtenida mediante TC. Nivel 2 aprox.*

*Figura 2. Imágenes TC etiquetadas*

El proceso de segmentación utiliza el algoritmo de Max-Flow Continuo, donde la segmentación de imágenes puede plantearse como un problema de minimización de una energía. De

modo, que la segmentación buscada proporcionará el mínimo absoluto de una energía. Todo ello, con la finalidad de generar una imagen binaria donde los puntos que pertenecen al área de interés se representan con uno (1), y los demás píxeles se fijan en cero (0).

El objetivo final es la posterior reconstrucción 3D de la estructura muscular y así mejorar la visualización y diagnóstico médico, facilitando la detección de patologías.

## 1.2.1 Objetivos

### Objetivo General

Desarrollar una herramienta computacional para la segmentación de tejido musculoso en tomografía computarizada.

### Objetivos Específicos

- Desarrollar un algoritmo basado en distancia al histograma modelo para obtener la entrada al algoritmo de segmentación
- Desarrollar un algoritmo de segmentación basado en la técnica de Max-Flow Continuo.
- Realizar validación de resultados.

## 1.2.2 Sumario

En el capítulo 2 se describe la anatomía de los músculos y el tejido muscular. Se describen las diferentes clases de tejidos.

En el capítulo 3 se define el concepto de imagen médica y se detalla la técnica de la tomografía computarizada.

El capítulo 4 muestra las técnicas de filtrado y segmentación seleccionadas en este trabajo. Se realiza un bosquejo general de los principales procesos realizados.

En el capítulo 5 se describe la metodología utilizada para la segmentación de tejido muscular. Esta metodología se caracteriza por la aplicación de una técnica de segmentación de imágenes, basada en el uso de histogramas y minimización de una función de energía, para posteriormente comparar sus resultados. Estas etapas se describen a continuación:

- etapa de preprocesamiento, al fin de eliminar información irrelevante.
- cálculo de la distancia a un histograma modelo.
- segmentación utilizando el algoritmo de Max-Flow continuo rápido.

- etapa final de post-procesamiento para mejorar el resultado de la segmentación.

Adicionalmente, en el capítulo 4 se sintetizan algunos antecedentes de trabajos en el área.

En el Capítulo 6 se muestran los resultados de la aplicación de la metodología descrita en base de datos de tomografía computarizada y su respectiva validación.

# Capítulo 2

## Músculos

### 2.1 Introducción

Un músculo es un tejido blando que genera movimiento al contraerse o extendiéndose al relajarse. En el cuerpo humano (y en todos los vertebrados) los músculos están unidos al esqueleto por medio de los tendones formando el sistema muscular. El sistema muscular permite que el esqueleto se mueva, se mantenga firme y estable y también da forma al cuerpo. En los vertebrados los músculos son controlados por el sistema nervioso, aunque algunos músculos (tales como el cardíaco) pueden funcionar de forma autónoma. Aproximadamente el 40 % del cuerpo humano está formado por músculos, es decir, que por cada kilogramo de peso total, 400 g corresponden a tejido muscular.

La principal función de los músculos es contraerse y alargarse, para así poder generar movimiento y realizar funciones vitales. Se distinguen tres grupos de músculos, según su disposición: músculo esquelético, músculo liso y músculo cardíaco

El cuerpo humano contiene aproximadamente 650 músculos.

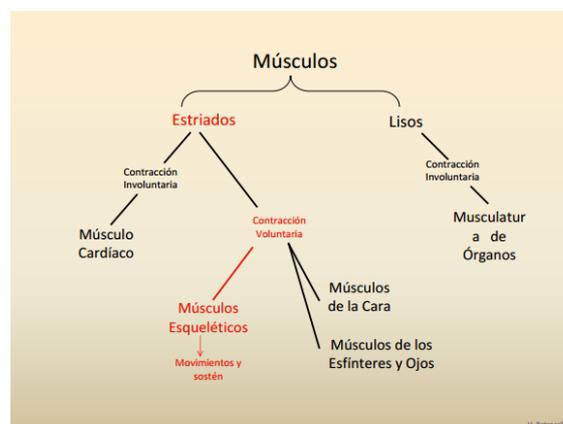


Figura 3. Tipos de músculos.

## 2.2 Tejido muscular

Hay tres tipos de tejidos musculares [3] clasificados con base en factores estructurales y funcionales. En el aspecto funcional, el músculo puede ser músculo voluntario o músculo involuntario. En lo estructural, puede mostrar bandas transversales regulares a todo lo largo de las fibras (músculo estriado) o no (músculo liso o no estriado). Con base en esto los tres tipos de músculo son:

- **Músculo estriado o esquelético:** son un tipo de músculos estriados unidos al esqueleto. Son usados para facilitar el movimiento y mantener la unión hueso-articulación a través de su contracción. Son, generalmente, de contracción voluntaria (a través de inervación nerviosa), aunque pueden contraerse involuntariamente. El cuerpo humano está formado aproximadamente de un 90% de este tipo de músculo y un 10% de músculo cardíaco y visceral.

El tejido muscular estriado está formado por fibras musculares de forma cilíndrica, con extremos que mantienen el mismo grosor en toda su extensión, y más largas que las del tejido muscular liso.

- **Músculo cardíaco:** Es de naturaleza estriada modificada y de control involuntario. Está presente solo y únicamente en el corazón, de ahí que se llame "cardíaco". Se puede decir, que el músculo cardíaco es el único estriado que tiene movimiento involuntario.
- **Músculo liso involuntario:** Se encuentra en las paredes de las vísceras huecas y en la mayor parte de los vasos sanguíneos y no están bajo el control de la voluntad. Sus células son fusiformes y no presentan estriaciones, ni un sistema de túbulos. Son células mononucleadas con el núcleo en la posición central. Este músculo tiene una similitud con el músculo estriado o esquelético. La diferencia es que no posee línea Z como lo posee el músculo estriado, sino que posee bolas densas que reemplazan a estas líneas Z. El músculo liso forma capas dentro de los órganos huecos.

El objetivo de este trabajo es la segmentación de músculos y, como ya hemos mencionado, éstos están presentes en numerosos órganos, por lo que resulta complicado extraer, por ejemplo de un corte del tórax, los músculos estriados que sujetan las costillas sin extraer el corazón. Con lo cual, estaríamos segmentando un órgano sin ser éste nuestro objetivo.

# Capítulo 3

## La Imagen Médica Digital

### 3.1 Introducción

Hoy en día, la imagen médica en su modalidad digital, se utiliza de manera cotidiana. Se llama imagen médica al conjunto de técnicas y procesos usados para crear imágenes del cuerpo humano, o partes de él, con propósitos clínicos (procedimientos médicos que buscan revelar, diagnosticar o examinar enfermedades) o para la ciencia médica (incluyendo el estudio de la anatomía normal y función) [4] En el contexto clínico, la imagen médica se equipara generalmente a la radiología y al profesional de la medicina responsable de interpretar (y a veces de adquirir) las imágenes, que es el radiólogo.

La imagen digital 2D se presenta mediante una función discreta de dos variables,  $f(x,y)$ , que expresa una matriz bidimensional cuyos elementos  $(x, y)$ , llamados píxeles, tienen asociado un nivel de gris o intensidad luminosa. Cuanto mayor sea el número de píxeles, mayor será la resolución espacial de la imagen y mejor calidad de la misma.

El formato digital representa una mejora de las limitaciones de la imagen convencional proporcionando la posibilidad de transmitir una imagen a cualquier lugar a través de la red. La imagen médica analógica tiene el problema añadido del deterioro irreparable, además del problema de almacenamiento en los hospitales, así como la posibilidad de que se extravíen.

De modo, que para poder transmitir una imagen por la red, la telemedicina requiere que las imágenes y los protocolos de comunicación estén unificados. DICOM (Digital Image Communications in Medicine) es el estándar desarrollado por un comité creado en 1983 conjuntamente entre las asociaciones ACR (American College of Radiology) y NEMA (National Electrical Manufacturers Association). Este protocolo de comunicaciones no sólo establece coherencia entre los distintos dispositivos dentro de un sistema de imagen médica, sino que también define los datos, funciones y requisitos de calidad mínimos que debe presentar dicho sistema. Cada imagen DICOM debe incorporar información relativa al paciente como datos personales, fecha del

estudio, médico que le ha informado, etc. Está pensado para el manejo, almacenamiento, impresión y transmisión de imágenes médicas.

## 3.2 Tomografía Computarizada

La TC (Tomografía computarizada) es hoy en día, una parte esencial del diagnóstico radiológico. Esta modalidad de imagen médica ha ido perfeccionándose a través de los años, llegando a completar o sustituir a la clásica imagen de rayos X en muchas áreas.

La Tomografía Computarizada utiliza un equipo de rayos X y tecnología computarizada para obtener imágenes de cortes axiales del cuerpo y permite reconstruir las imágenes en cortes transversales, horizontales y oblicuas. La TC utiliza los rayos X emitidos en haces para obtener cortes por planos (tomografía), los cuales son procesados con un programa de computador, y que permiten obtener imágenes tanto de tejidos blandos como de tejidos óseos, lo cual marca la gran diferencia con los rayos X convencionales.

En los rayos X (RX) estándar, se dirige un rayo de energía a la parte del cuerpo que se está estudiando. Una placa situada detrás de la zona del cuerpo captura las variaciones del rayo de energía después de que éste pasa a través de la piel, el hueso, el músculo y otros tejidos. Así pues, en una radiografía convencional se presenta la distribución de la modulación de la intensidad de la radiación, y esta ofrece siempre una imagen de superposición. Cada elemento de la imagen muestra la suma de todas las contribuciones a la atenuación a lo largo de la línea fuente-detector. De modo, que en el caso de que existan estructuras con un alto coeficiente de atenuación, estas no permitirán que las que se encuentran detrás de ellas en la dirección del haz de rayos, aparezca en la imagen. El contraste en las radiografías convencionales está dominado por las estructuras con alta atenuación, tales como huesos, o por diferencias de grosor en el objeto. Mientras que las de baja atenuación, por lo general, tejidos blandos, aparecen ocultas en la mayoría de los casos prácticos. En la tomografía computarizada, al realizarse proyecciones en 360 grados, se podrían ver esas estructuras que en el caso de la radiografía quedarían enmascaradas [5].

Para comprender la tomografía computarizada hay que imaginar el cuerpo humano formado por un número finito de elementos discretos. Este tipo de imagen se considera formada por vóxeles (elementos de volumen), ya que cada pixel de los que vemos en la imagen transversal, aunque esta sea plana, se corresponde con un elemento de volumen que tiene un determinado espesor.

En términos generales, el principio de la tomografía computarizada [6] consiste en medir la distribución espacial de la intensidad de la radiación X que atraviesa un objeto, desde diferentes direcciones. Para poder obtener la imagen, es necesario radiar al menos con un barrido de 180°. El tubo de rayos X gira solidariamente con el detector, radiando el objeto desde diferentes direcciones.

La información se recoge en el detector en forma de mapa de atenuaciones. La repetición de este proceso sobre secciones adyacentes, genera un conjunto de imágenes bidimensionales.

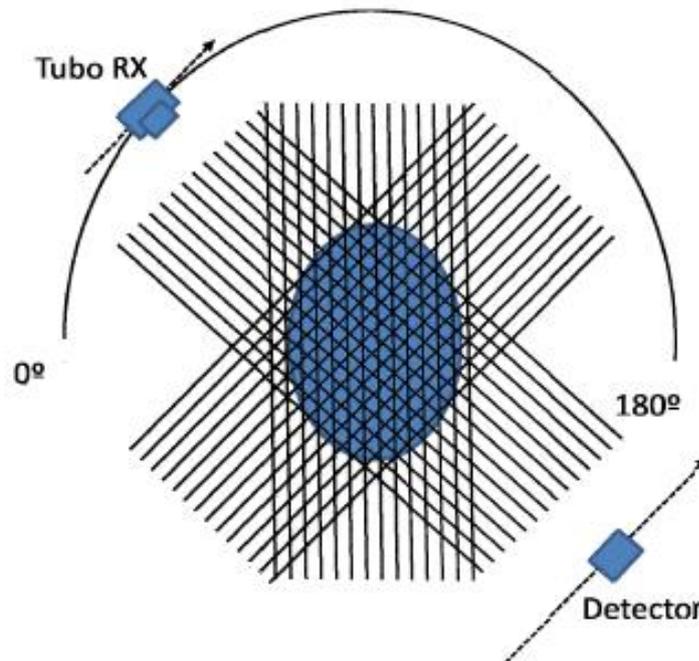


Figura 4. Esquema para la adquisición de datos en la imagen TC (escáner de primera generación)

Una vez adquirida la información en forma de mapas de atenuaciones, hay que resolver un sistema de ecuaciones para conocer los valores de los distintos coeficientes de atenuación en cada vóxel. Dichos coeficientes se corresponden con los valores de cada punto de la imagen final. Este sistema es complejo y existen procedimientos diferentes para hacerlo [7].

Los valores que se obtienen para un determinado coeficiente de atenuación, se muestran como valores de TC relativos al coeficiente de atenuación del agua. Estos números reciben el nombre de números de TC y se expresan en unidades HU (Unidades Hounsfield). En esta escala, el agua o cualquier tejido con coeficiente de atenuación equivalente, toma el valor cero por definición.

Se define el valor para un determinado material T como:

$$(\text{Valor de TC})_T = 1000 \cdot (\mu_T - \mu_{\text{agua}}) / \mu_{\text{agua}}$$

Aproximando  $\mu_{\text{agua}}$  a cero, el aire se corresponde con un valor de TC de -1000 HU. Para huesos y calcificaciones fuertes los valores suben hasta 2000. No obstante, los metales pueden alcanzar valores mayores. Esta escala no tiene límite superior. Para escáneres médicos, los valores que se dan normalmente están entre -1024 y 3071 HU.

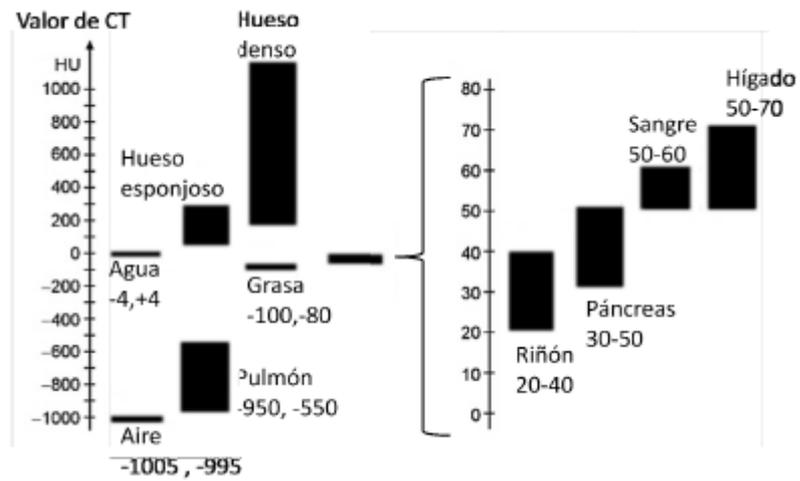


Figura 5. Unidades Hounsfield típicas para distintos tejidos en estudios de TC

# Capítulo 4

## Técnicas de filtrado y Segmentación

### 4.1 Introducción

La detección de estructuras con características determinadas dentro de una imagen constituye un aspecto fundamental para la automatización de diversos tipos de aplicaciones. Estos procedimientos, conocidos como segmentación de imágenes, permiten la descomposición de una imagen en regiones de interés, según cada aplicación particular.

Tras el proceso de segmentación, las imágenes pueden presentar ciertas imperfecciones debido a pequeños errores que puedan cometerse. Estos pueden mejorarse mediante el uso de filtros, que varían teniendo en cuenta el efecto que producen en las imágenes, como modificación de brillo, contraste, reducción de ruido, suavizado y realce de contornos. También pueden agruparse en categorías considerando el mecanismo utilizado para la modificación de la imagen. Algunos de ellos son los filtros morfológicos [8], que se basa en operaciones no lineales entre un conjunto de píxeles de la imagen y un elemento estructura, que puede ser un rectángulo, círculo o elipsoide, según el caso lo requiera.

### 4.2 Técnica de Segmentación

El objetivo de la segmentación es obtener una partición de la imagen en regiones coherentes como paso previo al análisis de su contenido. La segmentación de imágenes se puede definir como la descomposición de la imagen en regiones homogéneas, que compartan ciertas características y se puede realizar de distintas formas:

**Manual:** El usuario realiza la segmentación él mismo con la ayuda de una herramienta informática.

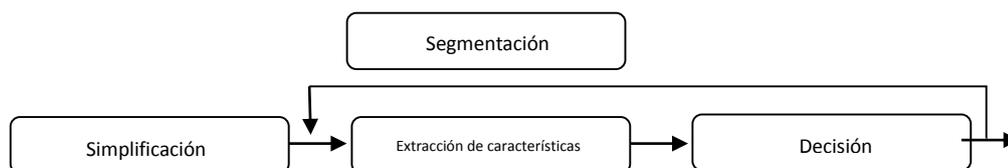
**Automática:** La aplicación realiza todo el proceso de forma automática. Este método es el utilizado en el presente trabajo.

**Semi-automática o interactiva:** La aplicación realiza el proceso, pero el usuario interviene en determinados momentos sobre el mismo para definir parámetros o corregir resultados.

El proceso de segmentación de una imagen puede ser abordado desde diferentes puntos de vista. Cada una de las estrategias posibles tiene sus ventajas e inconvenientes. Por lo tanto, la estrategia a elegir depende de las características de la imagen que queremos segmentar y de cuál es la información que queremos extraer de dicha segmentación. Las estrategias básicas de segmentación más representativas pueden ser clasificadas en cinco categorías [9].

- Las técnicas basadas en detección de puntos y líneas.
- Técnicas basadas en detección de bordes: consiste en intentar encontrar un borde entre las regiones mediante medidas de discontinuidad [11, 12].
- Técnica basada en umbrales [10]:
- Técnica basada en regiones, que asume la idea de que aquellos píxeles cuyos valores estén dentro de un cierto intervalo pertenecen a la misma clase [13, 14], como las técnicas de crecimiento, fusión o división.
- Técnicas basadas en modelos [15], que tratan de enlazar los bordes locales cuando ellos están sobre una curva bien especificada (rectas, rectángulos, circunferencias, elipses u otro tipo de curvas en una imagen que se puedan expresar por un número reducido de parámetros)

En cuanto al procedimiento, un esquema general para la segmentación se puede considerar como la concatenación de tres pasos principales, representados en la Fig. 6.



*Figura 6. Proceso Global de la Segmentación de Imágenes.*

**La simplificación.** La mayoría de las veces, los datos originales en una imagen contiene información que es irrelevante para una aplicación dada. En tales casos, los datos se deben simplificar, eliminando toda aquella información irrelevante. La simplificación controla la cantidad y naturaleza de la información que es preservada. Además los datos simplificados deben contener áreas fáciles de segmentar. Por ejemplo, la simplificación puede reducir la complejidad de texturas, eliminando ruido o eliminar objetos muy pequeños para un tamaño dado.

La simplificación no debe modificar la información de los contornos que es relevante para la aplicación.

**Extracción de características.** La segmentación se realiza sobre características específicas de los datos. La selección del espacio de características conduce al tipo de homogeneidad que se espera en la partición final. En algunas aplicaciones, los datos originales proveen directamente el espacio de características necesario para la segmentación. Por ejemplo, para la segmentación a color, el valor del pixel puede corresponderse directamente a la característica de interés. Sin embargo, en otros casos, las características de interés deben ser estimadas a partir de los datos originales.

Las características típicas se enumeran debajo del bloque de la extracción de características de la Fig.1. El listado incluye actividad, frecuencia, textura, distorsión, histograma, DFD, espacios que caracterizan algunas nociones semánticas, movimiento o profundidad.

**Decisión.** Finalmente para obtener una partición de los datos, el espacio de características debe ser analizado. El paso de Decisión decide sobre la posición de los contornos que forman la partición en el espacio de decisión. Los contornos separan áreas de datos que contienen elementos con las mismas características en el espacio de características seleccionado. Por ejemplo en la segmentación espacial, la decisión puede producir la forma exacta de una región.

## 4.3 Segmentación de músculos

### 4.3.1 Introducción

Todos los tejidos corporales no óseos, como los músculos, la grasa, el tejido fibroso, los vasos sanguíneos o cualquier otro tejido conjuntivo del cuerpo se denominan tejidos blandos. Desde un punto de vista técnico, los niveles de gris de una imagen TC que contenga distintos tipos de estos tejidos no son lo suficientemente divergentes como para que el proceso de segmentación de los mismos pueda utilizar esta característica, el nivel de intensidad de la imagen, como único parámetro válido.

El paso de preprocesado incluido en el algoritmo, aun aumentando notablemente el rango dinámico de las regiones de interés dentro de la imagen, y por tanto optimizando su resolución y la divergencia entre los diferentes niveles de gris de los diferentes tejidos, no consigue que el tratamiento de tejidos blandos pueda tener en cuenta únicamente el nivel de gris de los vóxeles.

Será necesario atender a otros parámetros y, en general, será necesaria también la intervención de algoritmos más complejos, que marcará, de nuevo, una serie de parámetros iniciales que nos permitan determinar la región definitiva.

Diversas metodologías han sido propuestas para la segmentación de músculos y para la extracción de parámetros que describan la estructura muscular, las cuales buscan mejorar las técnicas de diagnósticos. Estas metodologías no se encuentran estandarizadas y por lo general son muy especializadas en un tipo de músculo en concreto, por lo que se requiere una metodología general, sencilla, rápida y que reduzca el margen de error [10, 15, 16].

### 4.3.2 Antecedentes

Al considerar la segmentación de músculos, no hay muchos trabajos publicados. Entre los trabajos hallados se encuentran artículos muy especializados en algún tipo de músculo: detección de músculos pectorales en mamografías, detección de músculos masticatorios en CT, etc. y suelen usar o algoritmos basados en umbrales globales [10] o algoritmos basados en modelos [15] (muy específicos del músculo a segmentar).

Como ejemplo de algoritmos basados en umbrales, se puede consultar la referencia [10]. En este trabajo se analiza de forma eficiente la composición del tejido muscular en imágenes de tomografías computarizadas en espiral. La distribución, asociada a los valores Hounsfield, de la densidad muscular, especialmente cuando se incluye el volumen de músculo entero, proporciona información notable sobre la condición muscular. De modo que, diferentes escenarios fisiológicos y patológicos se pueden representar mediante la técnica de caracterización muscular basada en los valores de HU, definiendo los intervalos apropiados y asociando a dichos intervalos diferentes colores. En la tabla 1 se muestran los valores Hounsfield habituales para cada tipo de tejido utilizado por este tipo de algoritmos.

Anatomical tissues	Threshold sets for computer tomography (HU)	
	Min	Max
Bone	226	3,071
Compact bone	662	1,988
Spongial bone	148	661
Muscle	-5	135
Fat Tissue	-205	-10
Skin Tissue	-30	60
Tooth	1,200	3,071

*Tabla 1. Valores Hounsfield habituales para cada tipo de tejido humano escaneado con CT*

Como ejemplo de algoritmos basados en modelos, se puede consultar la referencia [15]. El propósito de este estudio es desarrollar un esquema para segmentar la región del músculo recto

abdominal en imágenes TC. Se propone un nuevo método de reconocimiento muscular basado en el modelo de la forma. El método incluye tres etapas para el proceso de segmentación. El primero es para generar un modelo de forma que represente al músculo recto abdominal. La segunda es reconocer puntos característicos anatómicos correspondientes al origen y la inserción del músculo, y la tercera es para segmentar los músculos rectos del abdomen utilizando el modelo de la forma.

También se pueden encontrar trabajos basados en Level Sets, como por ejemplo la implementación publicada en [16]. El trabajo consiste en un método de segmentación semiautomático de imágenes CT de los músculos cuádriceps. El método utilizado hace uso de Templates como inicialización al enfoque de segmentación basado en Level Sets. Las plantillas son cuantitativamente seleccionadas de un conjunto de imágenes en función a las características de la población de pacientes a saber, el sexo y el tipo de cuerpo. Para una imagen dada, se selecciona una plantilla basada en la mínima divergencia de Kullback-Leibler entre los histogramas de la imagen y el conjunto de plantillas.

### 4.3.2 Algoritmo de Max-Flow

Como se puede observar, esta falta de generalidad es un problema a la hora de segmentar varios tipos de tejido musculosos diferentes, pues habría que diferenciar distintos métodos de segmentación de acuerdo con las regiones que queramos analizar. Por lo tanto, sería deseable disponer de un método más general y más adecuado para poder segmentar un número más amplio de estructuras musculosas.

Con el sistema que aquí presentamos pretendemos obtener esta generalidad, obteniendo total transparencia a la hora de analizar distintas regiones por un mismo método. Hemos planteado la segmentación de imágenes como un problema de minimización de una función de energía. Las técnicas de minimización basadas en cortes de grafos permiten obtener el mínimo de una función de energía en tiempo real mediante algoritmos de tipo min-cut/max-flow.

En [18] se hace una comparación experimental de la eficiencia de los algoritmos de min-cut/max-flow para aplicaciones de visión por computación.

#### Segmentación de imágenes por minimización de energía

Consideramos una imagen  $I$ , es decir, un conjunto de píxeles  $P$  y un valor  $I_p$  para cada  $p \in P$ . Como la imagen es en niveles de grises,  $I_p \in R$  representa la intensidad de gris de la imagen en el pixel  $p$ .

El objetivo de la segmentación de una imagen es determinar las partes u objetos de interés de la misma y por lo tanto, una buena segmentación asignará la misma etiqueta a los píxeles de un mismo objeto. La segmentación de una imagen puede interpretarse como un etiquetado, es decir, la asignación de una etiqueta a cada píxel. En nuestro caso es necesario identificar músculo de no músculo, por lo que tendríamos entonces dos etiquetas y hablamos de segmentación binaria.

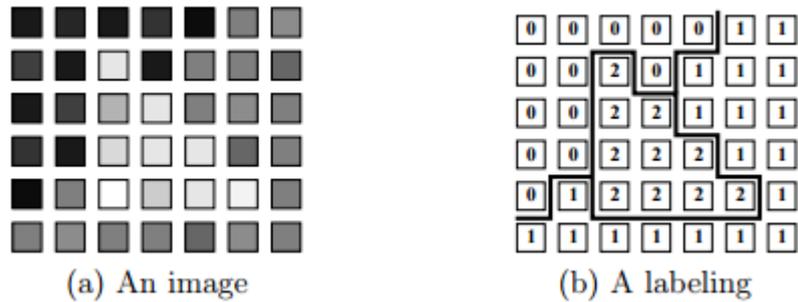


Figura 7. Ejemplo de etiquetado de una imagen. Una imagen en (a) es un conjunto de píxeles  $P$  con intensidades observadas  $I_p$  para cada  $p \in P$ . Un etiquetado  $L$  se muestra en (b) asigna alguna etiqueta  $L_p \in \{0, 1, 2\}$  a cada píxel  $p \in P$ . Tal etiquetas representan el índice de los diferentes objetos segmentados. Las líneas gruesas en (b) muestran discontinuidades de etiquetado entre píxeles vecinos.

## Etiquetado y energía

Más formalmente, un etiquetado es una aplicación  $f: P \rightarrow \Gamma$  entre dos conjuntos finitos  $P$  y  $\Gamma$ , cuyos elementos se denominan sitios y etiquetas respectivamente.

En el contexto de la segmentación de imágenes, el conjunto  $P$  es el conjunto de píxeles de la imagen y el conjunto  $\Gamma$  está formado por las etiquetas que se asignarán a las diferentes partes de la imagen. La segmentación de la imagen será un etiquetado que minimice una función real del conjunto de etiquetados  $E$ , denominada (función de) energía.

Dada una imagen de la que se desea una segmentación binaria, nos enfrentamos a un doble problema [18]:

1. Definir una energía  $E$  adecuada de modo que la segmentación buscada  $f$  sea mínimo absoluto de la energía, es decir,  $E(f) \leq E(g)$  para cualquier otro etiquetado  $g$ .
2. Definida la energía, encontrar un mínimo absoluto.

Cuando el conjunto de etiquetas está formado por dos elementos, éstos suelen denotarse por 0 y 1

## Energía y segmentación

Debido principalmente a la falta de algoritmos eficientes que permitan optimizar energías de orden mayor que dos, es una práctica común suponer que las energías a minimizar son de orden dos [18], es decir, de la forma

$$E(f) = \sum_{p \in P} V_p(f_p) + \sum_{\{p,q\} \in N} V_{pq}(f_p, f_q) \quad (4.1)$$

donde  $f$  es un etiquetado del conjunto de píxeles  $P$ ,  $V_p$  y  $V_{pq}$  son los potenciales de orden uno y dos respectivamente y  $N$  es un conjunto de todos los pares de píxeles vecinos. Los potenciales de orden uno,  $V_p$ , están basados en los datos observados y miden la preferencia de etiqueta de cada píxel individualmente. Pueden reflejar como la intensidad de un píxel  $p$  encaja en un modelo de intensidad conocido, por ejemplo, el histograma. Los potenciales de orden dos,  $V_{pq}$ , miden el coste de asignar etiquetas a dos píxeles vecinos. Se usan para imponer suavizado espacial, es decir, la energía no debe penalizar los etiquetados en los que píxeles vecinos del borde de los objetos tomen diferentes etiquetas, y si debe hacerlo si los píxeles vecinos corresponden a los objetos o al fondo. De tal forma, que esta energía penalizará asignar distintas etiquetas a píxeles con intensidades similares y próximos entre sí.

Un caso interesante de la energía se tiene cuando los términos  $V_{pq}$  de orden dos vienen dados por el siguiente modelo de Potts:

$$V_{pq}(l_1, l_2) = \begin{cases} \beta_{pq} & \text{si } l_1 \neq l_2 \\ 0 & \text{si } l_1 = l_2 \end{cases} \quad (4.2)$$

El coeficiente  $\beta_{pq} \geq 0$  penaliza una discontinuidad entre dos píxeles vecinos. Normalmente es alto para píxeles con intensidades similares y próximo a cero cuando las intensidades son muy diferentes. También puede ser una función decreciente con la distancia entre píxeles. Estos coeficientes pueden estar basados en el gradiente local de la intensidad, aspectos geométricos como la longitud o el área, la dirección del gradiente u otros criterios.

## El problema min-cut/max-flow

Un grafo ponderado dirigido  $G(V, E)$  consiste en un conjunto de nodos  $V$  y un conjunto de aristas  $E$  dirigida que los conectan. Por lo general, los nodos corresponden a píxeles, voxels, u otras características. Un gráfico normalmente contiene algunos nodos especiales adicionales que se llaman terminales. En el marco de la visión, terminales corresponden al conjunto de etiquetas que se pueden asignar a los píxeles. Nos concentraremos en el caso de las gráficas con dos terminales.

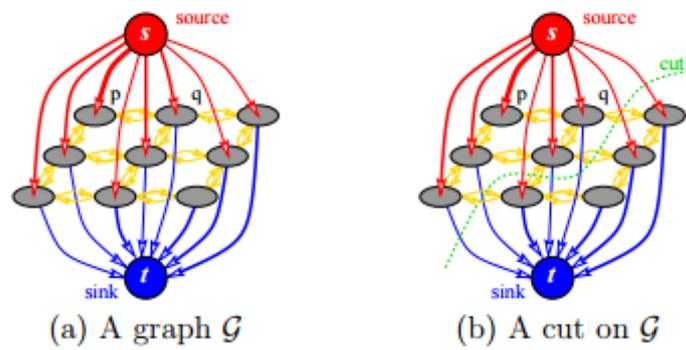


Figura 8. Ejemplo de un grafo dirigido capacitado.

Sea  $G$  un grafo dirigido completo en el que el conjunto de vértices  $V$  contiene dos vértices especiales,  $s$  y  $t$ , denominados fuente y sumidero respectivamente. Consideramos una función capacidad  $c$ , que asigna a cada arista dirigida  $(p, q)$  un número no negativo  $c(p, q)$ .  $(p, q)$  son, por tanto, píxeles vecinos.

Un corte en el grafo  $G$  es una bipartición  $C = (S, T)$  del conjunto de vértices tal que  $s \in S$  y  $t \in T$ . Es decir,  $V = S \cup T$ ,  $S \cap T = \emptyset$ ,  $s \in S$  y  $t \in T$ . El coste  $|C|$  de un corte  $C = (S, T)$  es la suma de las capacidades de las aristas con vértices origen en  $S$  y vértice final en  $T$ , es decir,

$$|C| = c(S, T) = \sum_{p \in S, q \in T} c(p, q) \quad (4.3)$$

El problema de mínimo corte en un grafo dotado de una función de capacidad consiste en encontrar el corte con mínimo coste.

Un flujo en el grafo  $G$  con función de capacidad  $c$  es una aplicación  $f$  con las siguientes condiciones:

- Restricción de capacidades:  $f(x; y) \leq c(x; y)$  para todo  $(x; y) \in V \times V$ .
- Conservación de flujo:  $f(p, V) = f(V, p)$  para todo  $p \in V \rightarrow \{s, t\}$ , donde  $f(V_1, V_2) = \sum_{p \in S, q \in T} f(p, q)$  es el flujo que sale de  $V_1$  y llega a  $V_2$ .

El valor de un flujo  $f$  es el flujo que sale de  $s$ . Este valor coincide con el flujo que llega a  $t$ . el problema de máximo flujo en un grafo dotado de una función de capacidad consiste en encontrar un flujo con máximo valor de flujo.

Intuitivamente, interpretando las aristas del grafo como tuberías y la capacidad de una arista como el caudal máximo de fluido que puede circular por la correspondiente tubería, puede hablarse

de flujo de fluido de fuente a sumidero y de máximo flujo, es decir, de caudal máximo de fluido que puede circular de la fuente al sumidero respetando las restricciones que marcan las capacidades.

Un resultado fundamental en teoría de grafos es el Teorema de Ford y Fulkerson [19] que establece que el corte de un grafo con coste mínimo se corresponde con el flujo de máximo valor, es decir, el flujo máximo de  $s$  a  $t$  satura un conjunto de aristas en el grafo que divide el conjunto de vértices en dos conjuntos disjuntos correspondientes al corte con coste mínimo. De hecho, el mínimo coste es igual al máximo valor de flujo. Así, los problemas de mínimo corte y máximo flujo son equivalentes.

Existen algoritmos, conocidos como algoritmos de tipo min-cut/max-flow y el que nosotros utilizaremos, que permiten obtener el máximo flujo, y por lo tanto el mínimo corte.

## 4.4 Técnicas de Filtrado

El filtrado convierte una escena dada en otra. Su propósito es realzar la información deseada (objeto) y suprimir la información no deseada (ruido, *background*, otro objeto) en la escena de salida [20].

En nuestro trabajo, con el fin de mejorar los resultados, utilizaremos filtros morfológicos, que son aquellos que se basan en operaciones matemáticas no lineales. Se recorre la matriz bidimensional de píxeles de la imagen, procesándola con un conjunto de puntos adicionales conocidos como elemento estructurante. Los elementos estructurantes pueden variar su forma y tamaño. Las formas comúnmente utilizadas para los elementos estructurantes son los rectángulos, cuadrados, círculos y elipses. Existen varios operadores que aplican el uso del elemento estructurante para filtrar morfológicamente las imágenes. A continuación se muestra la descripción de los operadores utilizados.

### Operador de erosión

El operador de erosión es también conocido como un operador morfológico para el filtrado de valores máximos en una imagen, que se encarga de analizar los píxeles que conforman una vecindad y sustituye los valores más oscuros por valores más claros, por consiguiente reduce los píxeles cercanos al negro. El resultado es una imagen más oscura, donde los detalles claros han desaparecido y se han unido zonas oscuras que antes estaban separadas por pequeñas zonas más claras. La Eq.4 representa el uso de este operador.

$$A \ominus B = \{x \in X | x + b \in A, \forall b \in B\} \quad (4.4)$$

donde  $A$  representa los píxeles de la imagen a filtrar y  $B$  el elemento estructurante.

### Operador de dilatación

Este método también es llamado filtrado de mínimos, en donde el pixel a tratar representa el pixel más oscuro de su vecindad, por lo que la intensidad total de la imagen de salida será reducida. El operador de dilatación se representa en la Eq. 4.5. La dilatación tiende a ensanchar las regiones negras en la imagen. Una de sus funciones es atenuar el ruido extremo dentro de la imagen, ya que elimina los valores más claros.

$$A \oplus B = \{x = a + b | a \in A \wedge b \in B\} \quad (4.5)$$

donde  $A$  representa los píxeles de la imagen a filtrar y  $B$  el elemento estructurante.

### Apertura

La apertura se utiliza para suavizar los contornos, y suprimir pequeñas islas de píxeles y picos dentro de la imagen. Se obtiene al aplicarle un operador de dilatación a una imagen erosionada. La siguiente Eq. 4.6 muestra la formulación matemática de este operador.

$$A \circ B = (A \ominus B) \oplus B \quad (4.6)$$

donde  $A$  representa los píxeles de la imagen a filtrar y  $B$  el elemento estructurante.

## Capítulo 5

# Diseño e Implementación de la Metodología para la Segmentación de Músculos

**Introducción** En este trabajo, hemos planteado la segmentación de imágenes como un problema de minimización de una función de energía. Este proceso es aplicado en distintos volúmenes TC de distintos pacientes. La metodología introducida requiere básicamente de cuatro etapas. Las dos primeras, previas a la segmentación, son la etapa de preprocesamiento, al fin de eliminar información irrelevante, y el cálculo de la distancia a un histograma modelo. La tercera etapa consiste en la segmentación utilizando el algoritmo de Max-Flow continuo rápido. Y por último, la etapa final de post-procesamiento para mejorar el resultado de la segmentación. Los algoritmos se han programado en lenguaje MATLAB.

La finalidad es obtener la segmentación de los músculos para cada una de las etapas y estudiar cualitativamente y cuantitativamente sus resultados.

### 5.1 Descripción de las Imágenes

Cómo se menciona en la sección 3.1, la fuente de datos se encuentra en formato DICOM.

En nuestra aplicación se han utilizado 30 imágenes extraídas de volúmenes TC provenientes de distintas secciones del cuerpo y de diferentes pacientes. Esta información es guardada con una resolución en píxeles de 512 x 512. La información de las imágenes de las bases de datos utilizadas se encuentra en escala de grises, donde los valores de los píxeles oscilan por lo general entre -2000 y 3000 (valores Hounsfield). En la Fig. 9 se ve un ejemplo de una de las imágenes de la base de datos y su histograma una vez la imagen ha sido normalizada y umbralizada.

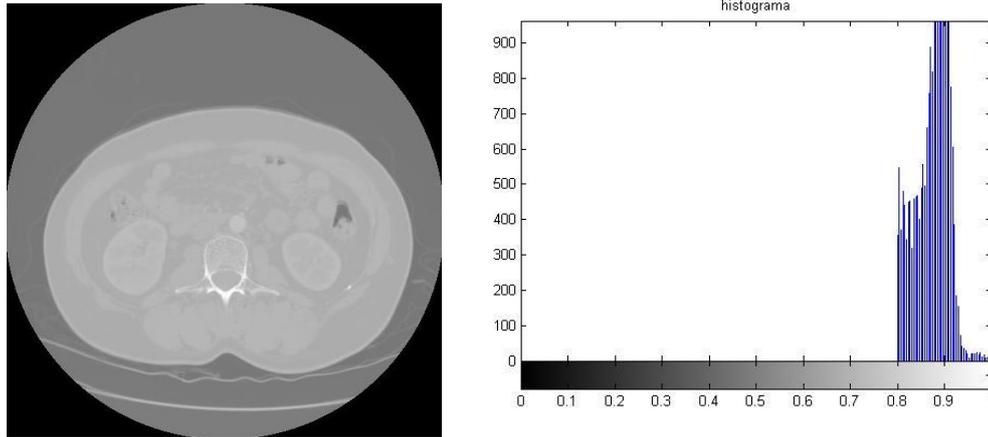


Figura 9. 1) Imagen original. 2) Histograma

## 5.2 Pre-Procesamiento de las Imágenes

La etapa de preprocesado consiste básicamente en una etapa de umbralización seguida de otra de normalización para conseguir un aumento de contraste.

La etapa de umbralización se realiza a fin de no tener en cuenta los valores que no se corresponden a los músculos y para obtener un mayor contraste. El umbral elegido en la operación de umbralización fue elegido escogiendo el valor mínimo y máximo presentes en las estructuras musculosas de las imágenes segmentadas manualmente y supervisadas por un experto.

En segundo lugar, la imagen umbralizada es normalizada y denotada como  $I_{norm}$ . Esta normalización permite una mejora de contraste de la imagen.

$$I_{norm} = \frac{I - I_{max}}{I_{max} - I_{min}}$$

Para no perder generalización, los valores mínimos y máximos, y el umbral elegido que han sido utilizados durante las operaciones de preprocesado son comunes a todos los volúmenes que se han utilizado.

## 5.3 Distancia al histograma modelo

Los volúmenes TC considerados en este enfoque se han separado en dos conjuntos, de los cuales 10 imágenes se han utilizado como conjunto de datos de entrenamiento y el resto se ha utilizado para realizar las pruebas.

El histograma modelo que requiere esta etapa ha sido calculado a partir de la segmentación manual del conjunto de imágenes de entrenamiento. Esta segmentación manual previa ha sido supervisada por un experto. Con el histograma modelo tenemos nuestra referencia de músculo. Es decir, toda parte correspondiente a músculo tendrá un histograma parecido al histograma modelo, representado en la Fig. 10.

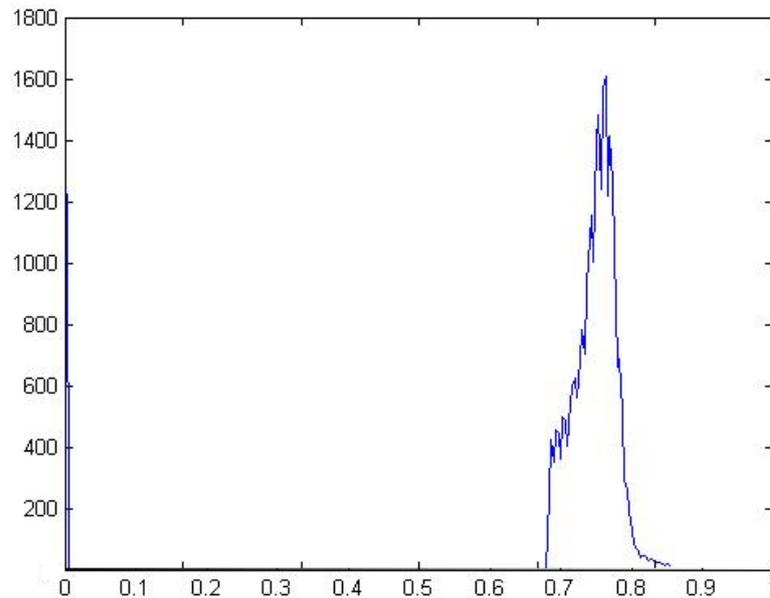


Figura 10. Histograma modelo.

Una vez obtenido nuestro histograma modelo, continuamos calculando el histograma local de cada píxel usando una vecindad  $7 \times 7$ . Se calcula la distancia de este histograma local al histograma referencia de músculo. Tras finalizar este proceso para toda la imagen podremos formar una imagen distancia al histograma modelo. A esta imagen se le llama HDI (*Histogram Distance Image*). Esta distancia será próxima a cero en las zonas con tejido musculoso, y será alta en las zonas de tejido que no se correspondan con músculos. Por último, con el fin de combinar esta información de distancia con la información de intensidad *Inorm*, creamos una imagen de costes CIT (*Cost Image Term*) que tendrá valores cercanos a 0 donde no haya músculo y cercanos a 1 donde sí lo haya.

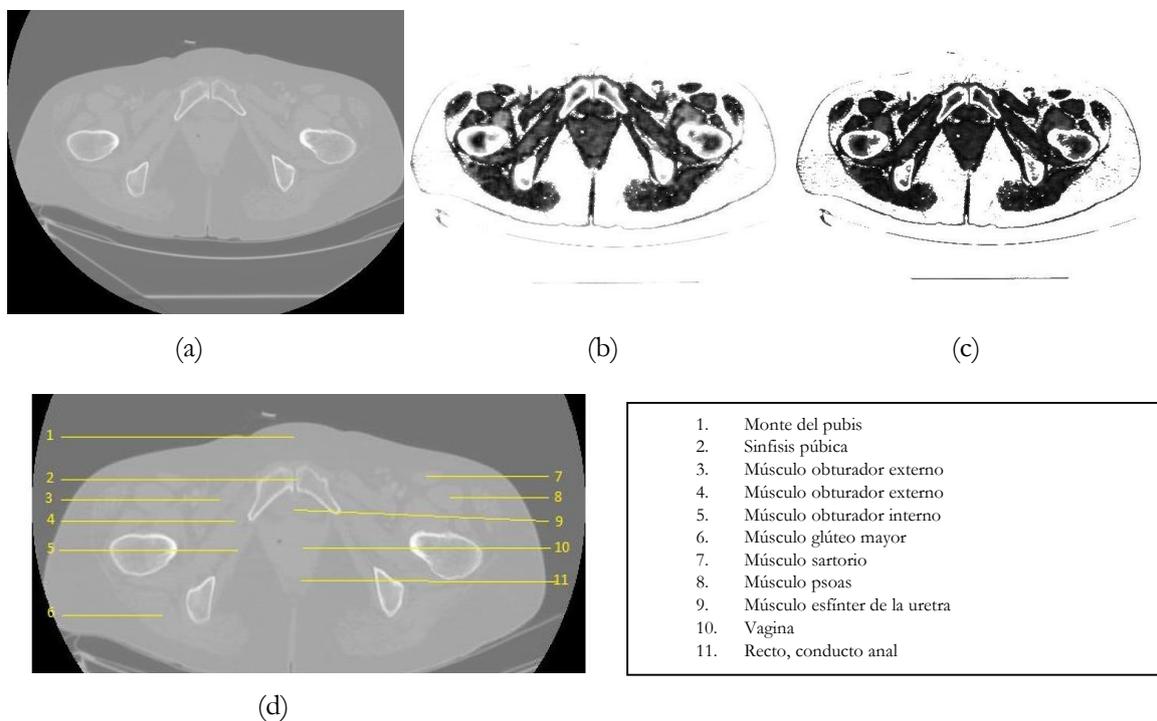
$$CIT = ((1 - Inorm) + HDI)/2 \quad (5.1)$$

La Eq. 5.1 es la función de costes a ser minimizada mediante el algoritmo max-flow continuo que se describe en el apartado siguiente. El primer término de la expresión utiliza información de intensidad. Los píxeles correspondientes al músculo tendrán valores cercanos a '1'. Por el contrario,

los píxeles que no correspondan a los músculos tendrán valores cercanos a '0'. Por lo tanto, se utiliza  $1 - I_{norm}$  en lugar de  $I_{norm}$  directamente porque queremos valores bajos en los tejidos musculosos.

Algo similar ocurre con el segundo término de la expresión de la derecha de la Eq. 1. La distancia al modelo histograma en píxeles correspondientes a los músculos debe ser cercano a 0 mientras que debería estar cerca de '1' en píxeles que pertenecen a otra clase de tejidos.

En la Fig. 11 se muestra un ejemplo del cálculo de estos dos parámetros, HDI y CIT. La Fig. 11a se corresponde con una imagen CT de un corte de la pelvis de una mujer. En ella se pueden apreciar ciertos músculos como son el músculo sartorio, los músculos obturadores (externo e interno), músculo glúteo mayor, músculo sartorio, músculo psoas y el músculo esfínter de la uretra.



*Figura 11. Imágenes calculadas de una rebanada CT. La primera imagen (a) es la imagen inicial CT. La segunda imagen (b) corresponde a la imagen distancia HDI. La tercera imagen (c) corresponde a CIT imagen que será la entrada al algoritmo max-flow continuo. Finalmente, la última imagen (d) se corresponde con un zoom de la primera (a) en la que se etiquetan los músculos presentes en ella. Se puede observar que los tejidos musculosos son más oscuros en la imagen CIT, lo que significa que la información de nivel de gris y la distancia al histograma se han combinado adecuadamente.*

## 5.4 Proceso de Segmentación: Algoritmo Max-Flow

Si nos planteamos la segmentación de imágenes como un problema de minimización de una energía, nos enfrentamos a una doble cuestión: definir una energía cuyo mínimo proporcione la segmentación buscada y, una vez definida la energía, encontrar un mínimo absoluto de la misma.

### El algoritmo min-cut/max-flow

El algoritmo que utilizaremos en el presente trabajo es el propuesto por J. Yuan et al. [21] que, como veníamos buscando, resuelve el problema de segmentación de imágenes, basado en el método continuo max-flow (CMF).

Dado una imagen en el dominio continuo  $\Omega$  (volumen 3D en nuestro caso), se supone que hay dos terminales, la fuente  $s$  y el sumidero  $t$ . Suponemos que para cada posición de la imagen  $x \in \Omega$ , existen tres flujos: el flujo fuente  $p_s(x)$  dirigido de la fuente  $s$  a  $x$ , el flujo sumidero  $p_t(x)$  dirigido de  $x$  al sumidero  $t$  y el flujo espacial  $p(x)$  que pasa por la posición  $x$ . Los tres campos de flujos están limitados por las capacidades:

$$p_s(x) \leq C_s(x), p_t(x) \leq C_t(x), |p(x)| \leq C(x) \forall x \in \Omega; \quad (5.2)$$

donde  $C_s$  es la capacidad de la fuente,  $C_t$  es la capacidad del sumidero y  $C(x)$  es la capacidad en el punto  $x$ .

Además, para  $\forall x \in \Omega$ , todos los flujos se conservan, es decir,

$$p_t - p_s + \text{div} p = 0, \forall x \in \Omega \quad (5.3)$$

Por lo tanto, el problema de máximo flujo correspondiente se formula mediante la maximización del flujo total de la fuente:

$$\max_{p_s, p_t, p} \int p_s dx \quad (5.4)$$

sujetos a las restricciones de flujo de la Eq. 5.2 y Eq. 5.3.

Como ya hemos mencionado anteriormente, una formulación max-flow continuo de este tipo es equivalente al problema de mínimo corte, Yuan et al [16] lo planteó como sigue:

$$\min_{u(x) \in [0,1]} \int (u) C_s dx + \int (1 - u) C_t dx + \int C(x) |\nabla u| dx \quad (5.5)$$

En realidad, la Eq. 5.5 representa el modelo dual de la Eq. 5.4.  $u(x)$  es la función de etiquetado e indica si el punto  $x$  pertenece a la región a segmentar.

Si el problema de minimización está bien definido, la función de coste  $C_s$  debería tomar valores bajos dentro de músculos y los altos valores fuera de ellos. Del mismo modo,  $C_t$  debe tener valores bajos fuera de los músculos y los valores altos dentro de ellos. El término más a la derecha de la Eq. 5.5 es el término de regularización y  $C(x)$  es una función de penalización.  $|\nabla u|$  es el gradiente absoluto de la función de etiquetado  $u(x)$ , indicando así el límite de la región segmentada.  $C_s$  y  $C_t$  se llaman términos regionales. En el algoritmo propuesto aquí, el término regional  $C_s$ , proporcionado como entrada al algoritmo máximo de flujo continuo, es el término  $CIT$  calculado a través de la Eq. 5.1. Así, en nuestro algoritmo, los términos  $C_s$  y  $C_t$  se calculan de la siguiente manera:

$$C_s = CIT \quad (5.6)$$

$$C_t = 1 - CIT \quad (5.7)$$

Tenga en cuenta que con la Eq. 5.7 forzamos  $C_t$  sea baja fuera de los músculos y alta dentro de ellos, como es requerido por la minimización de la Eq. 5.5.

El término más a la derecha de la Eq. 5.5 es el término de penalización. La energía no debe penalizar etiquetados en los que los pixeles vecinos del borde de los objetos tomen diferentes etiquetas, y si debe hacerlo si los pixeles vecinos corresponden a los objetos o al fondo. Esta penalización se modela por una función  $C(x)$  en función del gradiente de  $CIT$  a lo largo de la superficie, de modo que si el gradiente de  $CIT$  es alto no se penalizará. La función de penalización se calcula como sigue:

$$C(x) = \frac{bg}{1+ag|\nabla CIT(x)|} \quad (5.8)$$

donde los parámetros  $a$  y  $b$  controlan la importancia del gradiente en la función de penalización. En nuestra aplicación los valores  $ag$  y  $bg$  se han obtenido empíricamente y sus valores son 10 y 5, respectivamente. Tenga en cuenta que  $C(x)$  tendrá valores bajos si el gradiente de  $CIT(x)$  es alta. Por lo tanto, el término más a la derecha en la Eq. 5.5 no penalizará a un área si se encuentra una frontera alta.

## 5.5 Etapa Post-Procesamiento

Por último, con el fin de suavizar la imagen segmentada resultante, y para obtener una segmentación más precisa, se realiza una operación morfológica de apertura (ver sección 4.3). En este proceso el radio del elemento estructura utilizado para realizar tanto la erosión como la dilatación es 2. Para aplicar estos filtros se utiliza un elemento estructura en forma de disco. En la Fig. 12 se puede ver el resultado de aplicar la operación morfológica de apertura a una imagen segmentada.

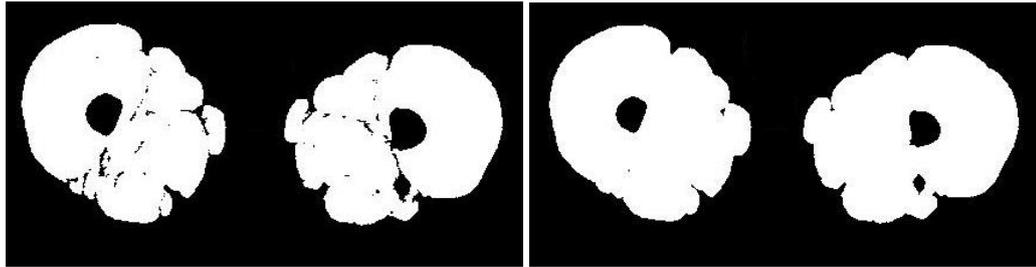


Figura 12. Resultado de la etapa de Post-Procesamiento. a) imagen segmentada. b) resultado tras operación de apertura

## Capítulo 6

### Resultados

#### 6.1 Introducción

En nuestra aplicación se han utilizado 30 imágenes extraídas de diferentes volúmenes TAC. Las imágenes corresponden a pacientes distintos y a TACs diferentes.

Para poder medir la eficiencia de la técnica de segmentación, estas imágenes han sido segmentadas manualmente y supervisadas por un experto. La segmentación manual ha sido utilizada como groundtruth y se han calculado diferentes parámetros para medir la eficiencia de la segmentación implementada.

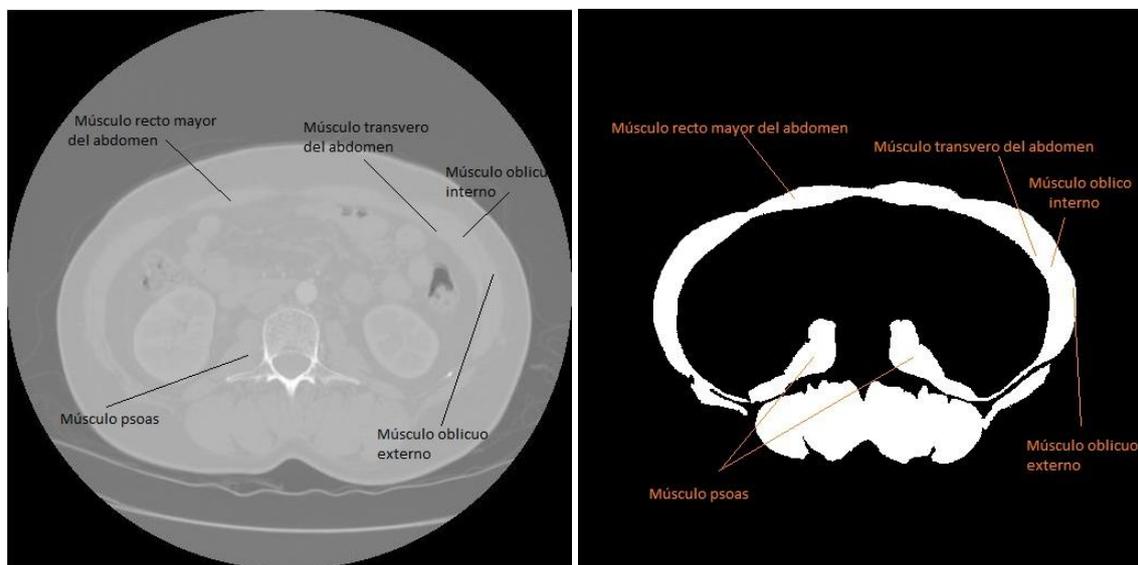


Figura 13. Ejemplo de segmentación manual: Groundtruth. Se trata de un corte horizontal de la cavidad abdominal: Imagen1) TC. Imagen2) máscara.

Estos parámetros miden la efectividad de una técnica de segmentación en base a los verdaderos positivos (píxeles que han sido marcados como músculo y realmente lo son), verdaderos negativos (píxeles marcados como no músculo y realmente no lo son), falsos positivos (píxeles

marcados como músculo que realmente no lo son) y falsos negativos (píxeles que son músculo pero que han sido marcados como negativos). Los parámetros objetivos de eficiencia son: PPV (*Positive Predicted Value*), Sensibilidad, Especificidad, Jaccard y Coeficiente Dice. En la Tabla 2 se muestran los valores Jaccard y Dice obtenidos para las 30 imágenes.

Tanto el coeficiente Dice como Jaccard son un estadístico utilizado para comparar la similitud de dos muestras. Y se definen de la siguiente manera:

$$Dice = \frac{2C}{A+B} = \frac{2|A \cap B|}{|A|+|B|} \quad Jaccard = \frac{|A \cap B|}{|A \cup B|} \quad (6.1)$$

donde  $A$  y  $B$  son el número de especies en las muestras  $A$  y  $B$ , respectivamente, y  $C$  es el número de especies compartidas por las dos muestras; Dice y Jaccard son el cociente de similitud (entre 0 y 1).

IMAGEN	DICE	JACCARD
IM 1	0.9646	0.9316
IM 2	0.9636	0.9298
IM 3	0.9615	0.9258
IM 4	0.9630	0.9287
IM 5	0.4838	0.3191
IM 6	0.5050	0.3378
IM 7	0.8980	0.8149
IM 8	0.9553	0.9145
IM 9	0.5774	0.4059
IM 10	0.7851	0.6462
IM 12	0.9192	0.8505
IM 13	0.9254	0.8611
IM 14	0.4041	0.2532
IM 15	0.7536	0.6046
IM 16	0.7599	0.6128
IM 17	0.7737	0.6309
IM 18	0.7841	0.6449
IM 19	0.5100	0.3423
IM 20	0.7760	0.6339
IM 21	0.7539	0.6050
IM 22	0.2951	0.1731
IM 23	0.8107	0.6817
IM 24	0.8124	0.6840
IM 25	0.9369	0.8813
IM 26	0.9252	0.8608
IM 27	0.7803	0.6397
IM 28	0.7353	0.5814
IM 29	0.7772	0.6356
IM 30	0.8474	0.7351
IM 31	0.9273	0.8645
<b>PROMEDIO</b>	<b>0.7755</b>	<b>0.6644</b>

Tabla 2. Valores Dice y Jaccard. Con los parámetros predeterminados:  $a=1$ ,  $b=0.2$ ,  $ag=10$   $bg=5$

En cuanto a la sensibilidad y la especificidad, ambos son dos conceptos que se utilizan en probabilidades médicas. Permiten evaluar el valor de un test. Estos dos conceptos son dependientes. La sensibilidad designa la probabilidad de obtener un test positivo en un individuo que tiene la condición buscada (individuo portador de la enfermedad). Al contrario, la especificidad designa la probabilidad de obtener un test negativo en una persona que no tiene la condición buscada (individuo sano).

La sensibilidad se define como:

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad (6.2)$$

donde  $VP$  es verdaderos positivos y  $FN$  falsos negativos.

Y la especificidad como:

$$\text{Especificidad} = \frac{VN}{VN + FP} \quad (6.3)$$

donde  $VN$ , serían los verdaderos negativos; y  $FP$ , los falsos positivos.

En nuestro caso la condición buscada sería la presencia de músculo. En la Tabla 3 se muestran los valores de Sensibilidad y Especificidad obtenidos para las 30 imágenes.

IMAGEN	SENSIBILIDAD	ESPECIFICIDAD
IM 1	0.9814	0.9912
IM 2	0.9779	0.9915
IM 3	0.9747	0.9913
IM 4	0.9831	0.9905
IM 5	0.8788	0.7906
IM 6	0.9384	0.8047
IM 7	0.9214	0.9663
IM 8	0.9755	0.9891
IM 9	0.5492	0.8986
IM 10	0.8333	0.9657
IM 12	0.9247	0.9839
IM 13	0.8984	0.9892
IM 14	0.6544	0.9287
IM 15	0.9156	0.9374
IM 16	0.8978	0.9404
IM 17	0.9274	0.9414
IM 18	0.9385	0.9417
IM 19	0.8325	0.8922
IM 20	0.9108	0.9495
IM 21	0.9128	0.9427
IM 22	0.7837	0.8848
IM 23	0.9262	0.9554
IM 24	0.9368	0.9550

<b>IM 25</b>	0.8975	0.9951
<b>IM 26</b>	0.8775	0.9948
<b>IM 27</b>	0.7371	0.9911
<b>IM 28</b>	0.6532	0.9917
<b>IM 29</b>	0.7037	0.9932
<b>IM 30</b>	0.8789	0.9752
<b>IM 31</b>	0.8818	0.9971
<b>PROMEDIOS</b>	0.8701	0,9520

Tabla 3. Valores Sensibilidad y Especificidad. Con los parámetros predeterminados:  $a=1$ ,  $b=0.2$ ,  $ag=10$   $bg=5$

Los valores predictivos (positivo y negativo) miden la eficacia real de una prueba diagnóstica. Son probabilidades del resultado, es decir, dan la probabilidad de padecer o no una enfermedad una vez conocido el resultado de la prueba diagnóstica. Se trata de valores post-test. El valor predictivo positivo mide la probabilidad de tener la enfermedad si el resultado del test ha sido positivo. En la Tabla 4 pueden observarse los valores obtenidos para las 30 imágenes analizadas

$$PPV = \frac{\text{Resultados positivos en enfermos}}{\text{Total de resultados positivos}} = \frac{VP}{FP + VP} \quad (6.4)$$

donde  $VP$  es verdaderos positivos y  $FP$  falsos positivos.

<b>IMAGEN</b>	<b>PPV</b>
<b>IM 1</b>	0.9483
<b>IM 2</b>	0.9497
<b>IM 3</b>	0.9486
<b>IM 4</b>	0.9437
<b>IM 5</b>	0.3338
<b>IM 6</b>	0.3455
<b>IM 7</b>	0.8758
<b>IM 8</b>	0.9362
<b>IM 9</b>	0.6086
<b>IM 10</b>	0.7421
<b>IM 12</b>	0.9138
<b>IM 13</b>	0.9540
<b>IM 14</b>	0.2923
<b>IM 15</b>	0.6403
<b>IM 16</b>	0.6587
<b>IM 17</b>	0.6637
<b>IM 18</b>	0.6733
<b>IM 19</b>	0.3676
<b>IM 20</b>	0.6759
<b>IM 21</b>	0.6421
<b>IM 22</b>	0.1818
<b>IM 23</b>	0.7209
<b>IM 24</b>	0.7171
<b>IM 25</b>	0.9799
<b>IM 26</b>	0.9783

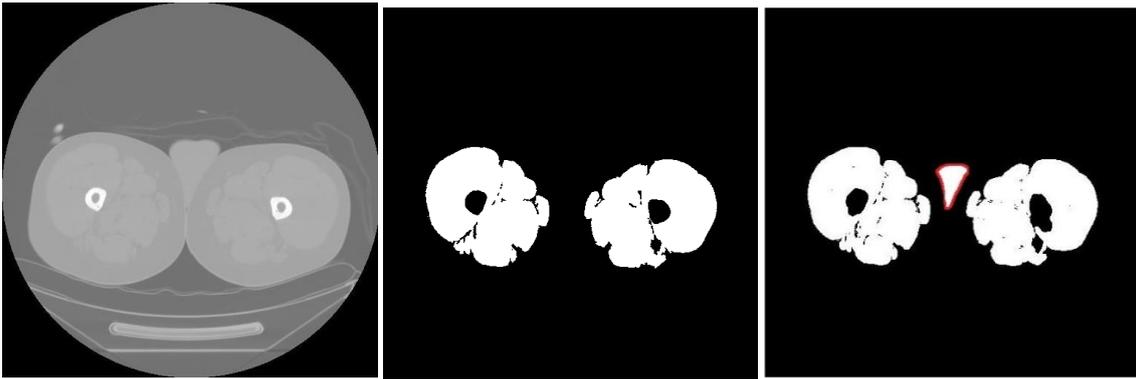
<b>IM 27</b>	0.8287
<b>IM 28</b>	0.8409
<b>IM 29</b>	0.8679
<b>IM 30</b>	0.8180
<b>IM 31</b>	0.9978
<b>PROMEDIO</b>	0,7348

*Tabla 4. Valores PPV.*

## 6.2 Análisis de los resultados

En la Tabla 2, vemos que los resultados difieren mucho unos de otros y que en algunas imágenes obtenemos valores Dice muy bajos. Esto no se debe a un error o una deficiencia de nuestro algoritmo sino, como venimos mencionando a lo largo de esta memoria, a la presencia de músculo liso en las diferentes zonas y estructuras de nuestro cuerpo. Los músculos lisos, presentes en numerosos órganos como corazón, hígado, páncreas, intestino, estomago, bazo... así como numerosas estructuras como uretra, vagina, útero... presentan un histograma muy similar o igual al de los músculos estriados, además de un nivel de intensidad similar. Por tanto, al calcular la distancia al histograma, en las zonas donde esté presente músculo liso la distancia será pequeña, al igual que en los músculos estriados. Y al calcular el factor CIT, con el mismo nivel y la misma distancia, no habrá diferencia alguna entre las zonas de músculo liso y músculo estriado, por lo que nuestro algoritmo lo segmentará como tal y, aunque estaríamos segmentando tejido muscular, también estamos segmentando parte de órganos y estructuras que no forman parte de nuestro objetivo. Algunos ejemplos de ello son los testículos, el corazón, el hígado y los intestinos, que representamos en la Fig. 14.

La Fig. 14 muestra los resultados obtenidos para cinco imágenes diferentes con presencia de músculo liso, utilizando nuestro algoritmo. La imagen de la izquierda de cada fila es la imagen TC original, la del centro es la groundtruth y la de la derecha es la imagen segmentada por nuestro algoritmo. La segmentación del músculo liso se representa en rojo. Tenga en cuenta que las segmentaciones del músculo estriado proporcionadas por nuestro algoritmo son bastante similares a las segmentadas manualmente, siendo incluso mejor en algunos puntos, mostrando así la eficacia del algoritmo aquí descrito.



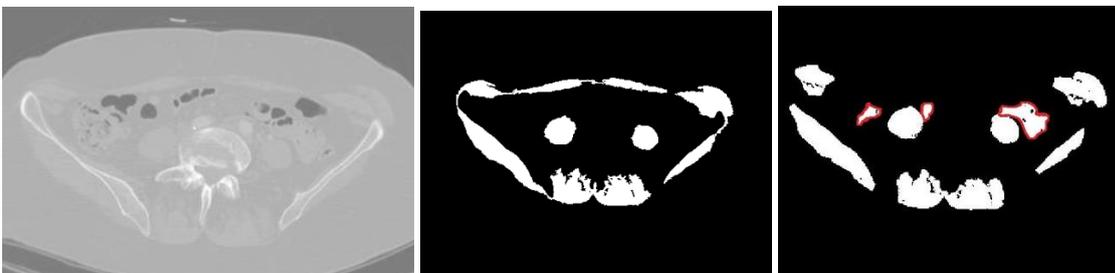
*Corte de las extremidades inferiores: Imagen 4.*



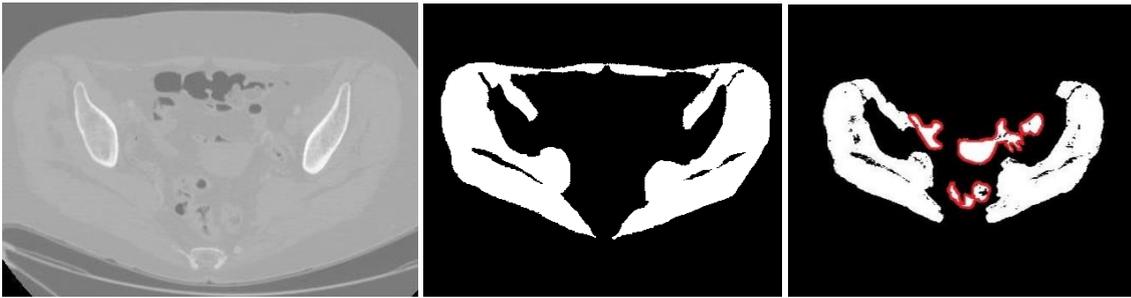
*Corte del tórax: Imagen 8.*



*Corte de la cavidad abdominal: Imagen 116.*



*Corte de la cavidad abdominal: Imagen 360.*



*Corte transversal del útero: Imagen 468.*

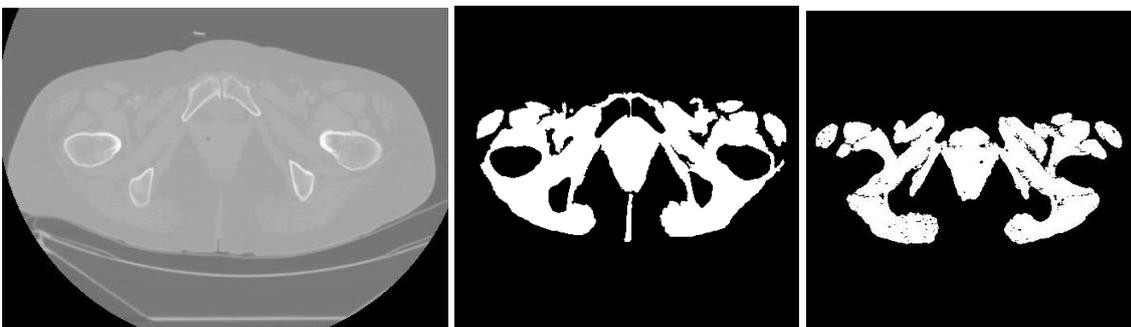
*Figura 14. Resultado de la segmentación de varias imágenes con presencia de músculo liso. a) Imagen TC b) groundtruth c) Imagen segmentada.*

En la Fig. 14, la imagen 4, que representa un corte de las extremidades inferiores, podemos observar como aparece una pequeña zona en rojo. Esta zona se corresponde con los testículos. Los testículos se encuentran envueltos por la bolsa escrotal, la cual está compuesta por diferentes capas, siendo la segunda de sus capas de músculo liso, el dartos. Por lo que nuestro algoritmo detecta la presencia de músculo y lo segmenta.

Al igual ocurre, con las siguientes imágenes que aparecen en la Fig. 14. En la imagen 8 aparece el corazón, que es un órgano musculoso, en la 116 aparece el hígado, y en las dos últimas los intestinos. Los intestinos están invadidos por fibras musculares lisas provenientes de la capa muscular de la mucosa, mientras que el hígado, formado por numerosas capas, presenta una capa de músculo liso.

De modo, que aunque en estos casos obtengamos valores Dice o Jaccard pequeños por la presencia de músculo liso, se puede apreciar que la segmentación de músculo estriado se ha realizado con éxito.

Sin embargo, como puede observarse en la Tabla 2, en zonas donde no se encuentran órganos ni estructuras que contengan músculo liso, obtenemos valores DICE y Jaccard superiores a 0,9 y 0,82 respectivamente. Como es el caso de la Fig.15 que representa la segmentación de una imagen TC de la pelvis de una mujer. Lo que demuestra que los resultados son prometedores.



*Figura 15. Corte pelvis mujer: a) Imagen 568 TC. b) Imagen máscara. c) Imagen segmentada.*

En este caso, se puede apreciar la eficacia de nuestro algoritmo.

## Capítulo 7

# Conclusiones y Perspectivas

En este trabajo se ha propuesto un algoritmo automático para la segmentación de estructuras musculosas. La segmentación de tales estructuras es una tarea complicada debido a que éstas presentan intensidades superpuestas con los tejidos circundantes, además de la presencia de tejido liso en numerosas órganos. Un nuevo algoritmo de segmentación, que combina información de nivel de gris e información estadística extraída de histogramas y basado en la optimización max-flow continuo, se ha propuesto para resolver este problema.

Este algoritmo ha sido validado con 30 imágenes de TC y aunque es un número pequeño, se ha evaluado con imágenes provenientes de distintas secciones del cuerpo y de distintos pacientes. Las imágenes fueron segmentadas manualmente, y varios coeficientes se han calculado para medir su eficacia. Los resultados obtenidos fueron prometedores, sobretodo en el caso de estructuras que no contenían músculo liso. Estos resultados tienen que ser analizados bajo el supuesto de que la segmentación exacta de los músculos es una tarea difícil, incluso para un experto debido a sus fronteras difusas. Por tanto, sería conveniente que diferentes expertos supervisaran la segmentación para una mejor validación del algoritmo. Esta sería una tarea del futuro. Del mismo modo, sería deseable una validación con un número mayor de casos.

Tenga en cuenta que la etapa de segmentación utilizando la aplicación de max-flow continuo es muy rápida (tiempo inferior a un segundo por imagen), sin embargo, el principal problema de este algoritmo radica en la computación de la distancia local de histograma para cada pixel de la imagen, requiriendo tiempos del orden de minutos, para la segmentación de una sola imagen. En implementaciones futuras sería conveniente acelerar la creación de la imagen de entrada, que combina la información de nivel de gris y la información estadística, para el tiempo de cómputo.

## Referencias

- [1] R. A. Haralick y L. Shapiro, *Computer and Robot Vision*. USA: Addison-Wesley Publishing Company, 1992, vol. I.
- [2] A. Mitiche y J. K. Aggarwal, *Image segmentation by conventional and information integrating techniques: a synopsis*, Image and Vision Computing, vol. 3, no. 2, pp. 50-60
- [3] Ross Pawlina. *Histología*. Ed. Médica Panamericana, 2006. 5ª Edición. p 305-307
- [4] COPTESIDEX Ilustre Colegio Profesional de Técnicos Radiólogos de Extremadura [En línea]. [Fecha de consulta: 09/07/2015]. Disponible en: <http://www.coptesidex.es>
- [5]. Cabrero F., *Imagen radiológica: principios físicos e instrumentación*, Elsevier, 2006. . p. 137
- [6] A Calzado, J Geleijns, *Tomografía computarizada. Evolución, principios técnicos y aplicaciones* 2010
- [7] Ye Y, Zhao S, Yu H, Wang G. *A general exact reconstruction for cone-beam CT via backprojection-filtration*. IEEE Trans. on Medical Imaging 2005; 24(9):1190-1198.
- [8] R.C. González y R.E. Woods, *Digital Image Processing*, Prentice Hall, 2ª Edición, 2002. (caps. 3 y 4)
- [9] Santiago Fernando González Benítez, *Segmentación de secuencias de imágenes estereoscópicas mediante competición de regiones para el modelado 3d de músculos artificiales*. 2005
- [10] Paolo Gargiulo, Tordur Helgason, et. al., “*Monitoring of Muscle and Bone Recovery in Spinal Cord Injury Patients Treated With Electrical Stimulation Using Three-Dimensional Imaging and Segmentation Techniques: Methodological Assessment*”, Artificial Organs, 35(3):275-281. 2011
- [11] S. M. Bhandarkar y A. Siebert, *Integrating edge and surface information for range image segmentation*, in *IEEE Southeastcon*, no. 1, 1992, pp. 106–113.

- [12] E. Saber, A. M. Tekalp y G. Bozdagi, *Fusion of color and edge information for improved segmentation and edge linking*, Image and Vision Computing, vol. 15, pp.769–780, 1997.
- [13] O. Tobias y R. Seara, *Image segmentation by histogram thresholding using fuzzy sets*, IEEE Transactions on Image Processing, vol. 11, no. 12, pp. 1457–1465, 2002.
- [14] I. Sekita, T. Kurita, N. Otsu y N. Abdelmalek, *A thresholding method using the mixture of normal density*
- [15] N. Kamiya, X. Zhou, H. Chen, C. Muramatsu, T. Hara, *Automated Segmentation of Rectus Abdominis Muscle Using Shape Model in X-ray CT Images*, 33rd Annual International Conference of the IEEE EMBS, Boston, Massachusetts USA, August 30 - September 3, 2011.
- [16] Jeffrey W. Prescott, Thomas M. Best, et al., *Anatomically Anchored Template-Based Level Set Segmentation: Application to Quadriceps Muscles in MR Images from the Osteoarthritis Initiative*, Journal of Digital Imaging, Vol 24, No 1 (February), 2011: pp 28:43
- [18] Yuri Boykov and Vladimir Kolmogorov. *An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in Vision*. In IEEE Transactions on PAMI, Vol. 26, No. 9, pp. 1124-1137, Sept. 2004
- [19] Ford, L. y Fulkerson, D. *Flows in networks*. Princeton Univ. Press (1962).
- [20] W. Pratt, *Digital Image Processing*. USA: John Wiley essing(1962).
- [21] Yuan, J., Bae, E., Tai, X.-C.: *A study on continuous maxflow and min-cut approaches*. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 2217–2224 (2010)

