

# Capítulo

# 1

## **Antecedentes de los métodos de Segmentación.**

Este capítulo tiene como propósito proporcionar los conocimientos básicos de la segmentación y principales métodos existentes en nuestro campo de aplicación.

La segmentación de imágenes es una técnica de procesamiento que se refiere a la extracción de información útil de una escena para facilitar su observación y análisis, ya que el resto del contenido de una imagen puede estar contaminado o no ser útil para el propósito buscado.

La segmentación de imágenes médicas enfrenta tres problemas principales vinculados a las imágenes:

- Las imágenes contienen gran cantidad de ruido, lo cual dificulta la clasificación de píxeles por intensidad.
- La intensidad en los tejidos y órganos, no es uniforme.
- Un píxel puede tener diferentes intensidades, producto de la mezcla de clases de tejidos.

La segmentación se logra con diferentes métodos y combinación de los mismos. La

clasificación de dichos métodos varía de una bibliografía a otra. Tomando como base [1], se distinguen tres generaciones en los métodos de segmentación para imágenes médicas, cada una añade un nivel de complejidad mayor a los algoritmos, dichas generaciones representan una referencia para la clasificación de los distintos métodos existentes en el campo de trabajo.

La primera generación está integrada por técnicas de bajo nivel, donde poco o nada de información *a priori* se incluye [1]. Además son vulnerables a los tres problemas principales que enfrenta la segmentación de imágenes médicas, mencionados anteriormente.

La segunda generación, incorpora modelos de imagen, modelos de incertidumbre y métodos de optimización, a los algoritmos. Sin embargo, los resultados de la segmentación continúan siendo dependientes de los datos.

La tercera generación, incluye conocimiento de más alto nivel en el algoritmo, durante el proceso de segmentación.

En la siguiente tabla, extraída de [1], se sintetiza la clasificación de los métodos de segmentación de imágenes médicas de acuerdo a la generación a la cual pertenecen.

Generation	Category		
	Region-based	Boundary Following	Pixel Classification
1st	<i>Region Growing</i>	<i>Edge tracing</i>	<i>Threshold</i>
2nd	<i>Deformable Models</i>	<i>Minimal Path</i>	<i>Statistical Pattern Recognition</i>
	<i>Graph Search</i>	<i>Target Tracking</i>	<i>C-means Clustering</i>
		<i>Graph Search</i>	<i>Neural Networks</i>
		<i>Neural Networks</i>	<i>Multiresolution</i>
3rd	<i>Shape Models</i>		<i>Atlas-based</i>
	<i>Appearance Models</i>		<i>Rule-based</i>
	<i>Rule-based</i>		
	<i>Coupled Surfaces</i>		

Tabla 1.1 Clasificación de los métodos de segmentación de imágenes médicas.

Entre las principales aplicaciones de esta técnica están la optimización de diagnósticos médicos y la automatización de procesos industriales. En este trabajo de tesis nos centramos en el procesamiento de imágenes médicas provenientes del sitio de MeDEISA [2] en formato DICOM, específicamente en imágenes de Resonancia Magnética (RM) de la cabeza.


## **1.1 Técnicas de segmentación aplicadas en las imágenes médicas**

Hoy en día existe una gran variedad de métodos de segmentación, por esa razón la selección del método depende en gran medida de la aplicación, del tipo de imagen y de las características de la misma, entre otros factores [3]. En esta sección se hará una descripción breve de los métodos de segmentación que gozan de popularidad en el campo de la medicina [4], [5], específicamente métodos de la primera generación y especialmente uno de la segunda, el cual es el centro de estudio de este trabajo de tesis.

### **1.1.1 Umbralización (*Thresholding*)**

Dentro de la gama de métodos de segmentación se tiene la Umbralización, que consiste básicamente en una comparación de nivel de intensidad píxel a píxel con un determinado umbral, definido previamente por el usuario [6]. Para establecer dicho umbral, es necesario analizar la región de interés que se desea aislar con el propósito de encontrar un nivel de gris característico y exclusivo que la defina. Para cumplir con esta tarea, se suele recurrir al histograma de la imagen [7]. Para completar el análisis, se debe tomar una decisión significativa: ¿qué hacer con los píxeles que corresponden a la región de interés, y qué con el resto de los píxeles de la imagen? La respuesta no es única, ya que estará en función de lo que se requiera para la aplicación. Por ejemplo si se desea conservar la información de interés tal cual, el algoritmo implementado debe dejar intactos los valores de los píxeles que corresponden a la región, sin embargo, todos aquellos que no cumplan con la condición del umbral, se les debe asignar un nuevo y único nivel de gris para evitar que la primera información nuevamente se mezcle. Por otra parte, si los niveles de gris de

los píxeles que conforman la región de interés tienen valores muy bajos, podemos reasignarlos a todos, con un solo y único nivel de gris, naturalmente distinto al que le asignemos al resto, para diferenciarlos. Este último caso se implementa por ejemplo, en la segmentación del texto alojado en una hoja deteriorada y maltratada, donde no tiene sentido conservar el valor de amplitud de cada píxel. La salida de la Umbralización se puede ver como la formación de dos planos, el primero que contiene la información aislada y el segundo, la información sobrante, este ejemplo es ilustrado en la figura 1.1.



*Figura 1.1* Umbralización de un documento viejo y maltratado.

Para sintetizar el funcionamiento del método de Umbralización, se muestra un diagrama de bloques en la figura 1.2.

Hasta aquí se ha considerado a la Umbralización solo con un umbral, y tiene un funcionamiento aceptable siempre y cuando la distribución del histograma sea bimodal, por

lo que el umbral debe ser colocado entre ambos modos [7]. Sin embargo, hay una gran cantidad de imágenes que no tienen un comportamiento análogo, por lo que se tiene que recurrir a una umbralización tipo multinivel, donde la cantidad de umbrales dependerá del comportamiento del histograma. Este último caso acarrea un problema considerable para el usuario, ya que la selección de varios umbrales de forma manual se puede convertir en una tarea ardua y compleja, por esa razón varios trabajos han tratado de desarrollar técnicas que automaticen la Umbralización, entre ellos se pueden destacar [7]: Weszka, Rigaut, Prewitt y Mendelson, solo por mencionar algunos.

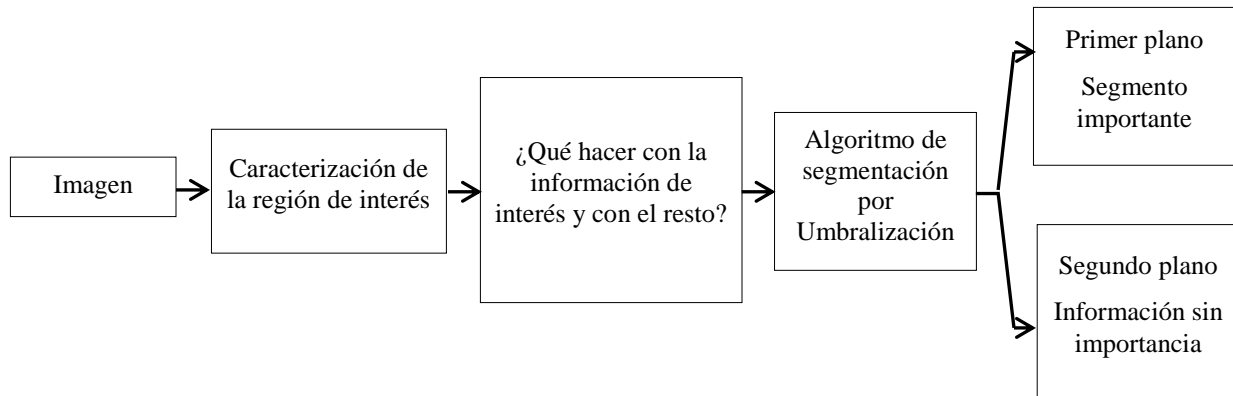


Figura 1.2 Diagrama de bloques del método de Umbralización

En cuanto a las imágenes de origen médico, la gran mayoría no presenta una distribución bimodal de intensidad, en este caso, la Umbralización no puede dividir las estructuras anatómicas de la imagen [8]. Sin embargo, algunos autores han sacado provecho de esta técnica, al combinarla con una etapa de filtrado de textura, como es el caso de Mayuresh Kulkarni [9], que ha logrado segmentar bordes de los huesos contenidos en una radiografía, como se ilustra en la figura 1.3.




Figura 1.3 Segmentación de huesos utilizando filtrado y Umbralización (extraído de [9]).

### 1.1.2 Crecimiento de región (*Region Growing*)

Es un método basado en similitud, es decir, tiene como objetivo determinar los píxeles que cumplen con cierto criterio de semejanza y permite agruparlos en regiones [6].

El crecimiento de región es un proceso iterativo [10], que inicia con puntos semilla, los cuales representan las características que definen a la región y que deben tener los píxeles candidatos para poder ser agregados a la misma, este procedimiento se lleva a cabo mediante la comparación de los píxeles vecinos con los puntos semilla, o los puntos pertenecientes a la región. Por lo tanto la selección de los puntos semilla es un paso significativo en este método, ya que los resultados dependerán directamente del criterio de semejanza que se establezca. El criterio de semejanza es establecido por el usuario [3] y debe contener las características de la información que se desea separar de la imagen original (intensidad, textura, entre otras [6]) para poder fijar el umbral, por lo tanto los píxeles que cumplan con el criterio de dicho umbral, se adicionan a las semillas formando

una región, que a su vez será la nueva semilla en la siguiente iteración.

Una vez seleccionados los puntos semilla la región crecerá únicamente hacia los píxeles vecinos que cumplan con el criterio establecido con anterioridad, con lo cual se garantiza conectividad entre los píxeles que constituyen una región [11]. En la imagen pueden existir puntos que cumplan con el criterio de semejanza pero si estos no son adyacentes a los puntos semilla, o a algún píxel perteneciente a la región no podrán adicionarse a la misma, esto representa una protección contra el ruido aunque puede producir regiones con orificios.

Para el crecimiento de la región, básicamente se necesitan dos condiciones:

- Los píxeles candidatos deben cumplir con un criterio de semejanza.
- Los píxeles candidatos pueden adherirse a la región, si y solo si, son vecinos de los puntos semilla, o de algún píxel de la región.

Este proceso se repite, y el crecimiento de la región se detendrá cuando los píxeles vecinos a las semillas, ya no cumplan con el criterio de semejanza que define a la región.




Figura 1.4 Crecimiento de región.

En la figura 1.4(a) se observa el punto semilla y los píxeles adyacentes (con conectividad 8) que cumplen con el criterio de semejanza, los cuales se adicionan a la región formando una nueva región que se muestra en la imagen 1.4(b) con sus nuevos píxeles vecinos, que al cumplir nuevamente con el criterio de semejanza forman una nueva


región, y en la figura 1.4(c) se muestra esta región con sus píxeles vecinos que ya no cumplen con el criterio de semejanza. Es así que se detiene el crecimiento de la región.

El crecimiento de región es un método utilizado en imágenes médicas bajo la hipótesis de que los píxeles pertenecientes a un mismo tejido u órgano presentan características similares con un significado semántico. Además de que presenta ciertas ventajas sobre los métodos basados en frontera, sobre todo en imágenes ruidosas donde los bordes son difíciles de detectar [12], pero a costa de un mayor esfuerzo computacional. Sin embargo, este método tiene los siguientes inconvenientes: es dependiente de los puntos semilla, aunque, trabajos sobre el mismo buscan disminuir esta dependencia [13], o cuando la región se propaga hacia zonas fuera del área de interés por alguna abertura [11].

En la figura 1.5 se muestra un ejemplo de crecimiento de región en una imagen de ultrasonido tomada de [14].



(a) Imagen original.



(b) Imagen segmentada con crecimiento de región.

*Figura 1.5* Segmentación con el método de Crecimiento de región

### 1.1.3 Detección de bordes

Los bordes son aquellas zonas de la imagen donde el nivel de intensidad varía bruscamente, precisamente estas partes son las que los algoritmos de “Detección de Bordes” tratan de rescatar y sobresaltar [6]. En cuanto más rápido se produzca el cambio de intensidad, el borde será más pronunciado y fácil de detectar por dichos algoritmos.

Para detectar los bordes que delimitan a los objetos, es necesario identificar aquellos puntos (píxeles) que los conforman. Esta detección es el paso más delicado del método y la



razón por la que existe una gran variedad de algoritmos que tratan de satisfacer esta necesidad. Para determinar que píxeles pertenecen al borde, las técnicas buscan una conectividad entre ellos, bajo las siguientes dos condiciones:

- Ser vecinos.
- Cumplir con un criterio de similitud.


La forma común de implementar la “Detección de Bordes”, es mediante filtros u operadores que se basan en herramientas matemáticas para su funcionamiento: gradiente y Laplaciano, por mencionar algunos [6]. Ejemplos de filtros que pertenecen a este tipo de técnicas son el operador Sobel y Prewitt, considerados como detectores de discontinuidades [15].

En cuanto a las aplicaciones médicas, se ha utilizado la detección de bordes en imágenes de Rayos X [8] [9], sin embargo, los resultados han sido pobres, ver figura 1.6. También se ha probado sobre imágenes de Resonancia Magnética (RM) [8].

La Detección de bordes resulta apropiada para imágenes con características bien definidas, con amplio contraste. En cuanto a sus limitaciones se puede mencionar el hecho de que detecta todos los bordes [8], por lo que el usuario no puede obtener un borde en específico; es impactado fácilmente por el ruido y los resultados entregados solo son útiles para la visualización del ser humano, pero no para procesamiento de alto nivel, el cual da sentido a los objetos obtenidos después de la segmentación [16].



Imagen de Rayos X.



Bordes obtenidos por el detector de Canny.

*Figura 1.6* Detección de bordes en imágenes de Rayos X (extraído de [8]).

#### 1.1.4 Modelos activos deformables

Los modelos activos deformables comprenden los siguientes métodos [17]:

- Contornos activos.
- Contornos dinámicos.
- Plantillas deformables.

En este trabajo de tesis nos ocupa el estudio de los Contornos activos, modelo de detección de fronteras de objetos en imágenes, también conocidos como *Snakes* en imágenes 2D y como modelos deformables para el caso 3D [18].

Este modelo incorpora información *a priori*, es decir, la manipulación de los parámetros iniciales se realiza de acuerdo a la forma a segmentar, además las características deseables del contorno son impuestas desde el inicio, en vez de esperar obtenerlas de las propiedades de la imagen [17], tales como continuidad y flexibilidad, ya que la continuidad se ve afectada por artefactos espurios que aparecen alterando la forma de interés, debido al ruido, o a los métodos de obtención de bordes.

Los *Snakes* son curvas paramétricas, deformables en el tiempo, cuya forma y posición final, son determinadas por la minimización de un funcional de energía, compuesta de energía interna y externa; esta minimización es autónoma, lo que le da un carácter dinámico al *Snake*, el cual se detiene una vez encontrado el límite del objeto cuando se ha llegado a un equilibrio entre fuerzas internas y externas.

$$E_{\text{snake}} = E_{\text{externa}} + E_{\text{interna}}$$

La energía interna proporciona las restricciones de estiramiento y curvatura del contorno, es decir, de la deformación que sufre la curva al acercarse al objetivo, debida a la minimización de energía. Mientras que la energía externa guía al *Snake* hacia los límites buscados dentro de la imagen.

Entre las ventajas que presenta este método están:

- El contorno se adapta a cualquier tipo de forma [19].

- Son curvas cerradas y suaves [20].
- Ofrecen robustez frente al ruido y bordes falsos [20].

Sin embargo, este modelo presenta las siguientes desventajas:

- Para obtener resultados satisfactorios, se requiere que la inicialización del contorno sea lo más cerca posible del objetivo, es decir, el resultado es directamente dependiente del contorno inicial [20] [21].
- Es incapaz de detectar concavidades [22].
- Puede perderse en mínimos locales [22].

## **1.2 Justificación de la elección del método: Contornos Activos**

Dado que no existe un método que funcione para todo tipo de imágenes, la selección del método no es una tarea sencilla, y como se mencionó, dependerá en gran medida de la aplicación. La bibliografía menciona que los *Snakes* han sido muy utilizados en la segmentación de imágenes, en especial de imágenes RM [20], objetivo de este trabajo. Además incluir información *a priori* presenta una ventaja sobre los métodos anteriormente expuestos que solo toman en cuenta la información local de las características de la imagen, como intensidades y discontinuidades. Por lo tanto en este trabajo de tesis se optó por el método de Contornos activos para la segmentación de imágenes médicas.