

Universidad de las Ciencias Informáticas
Facultad 5



**Título: Segmentación de Imágenes Médicas, mediante Técnicas de
Contornos y Técnicas de Regiones.**

**Trabajo de Diploma para optar por el título de
Ingeniero en Ciencias Informáticas.**

Autor: Alcides González Zaldivar.

Tutor: Ing. Osvaldo Pereira Barzaga.

DECLARACIÓN DE AUTORÍA

Declaramos ser autores de la presente tesis y reconocemos a la Universidad de las Ciencias Informáticas los derechos patrimoniales de la misma, con carácter exclusivo.

Para que así conste firmo la presente a los ____ días del mes de _____ del año _____.

Alcides González Zaldivar

Ing. Osvaldo Pereira Barzaga.

DATOS DE CONTACTO

Tutor: Ing. Osvaldo Pereira Barzaga.

Edad: 25 años.

Ciudadanía: cubano

Institución: Universidad de las Ciencias Informáticas (UCI)

Título: Ingeniero en Ciencias Informáticas

Categoría Docente: -

E-mail: *opereira@uci.cu*

Graduado de la UCI, con seis años de experiencia en el tema de la Gráfica Computacional y líder de un proyecto de Visualización Médica en la Universidad de las Ciencias Informáticas.

AGRADECIMIENTOS

A mí querida y adorada madre:

Esa persona que aunque no me trajo al mundo siempre ha estado a mi lado y que me ha apoyado en todo momento, que ha luchado tanto por mi futuro y que daría la vida, si fuera necesario, por verme triunfar. Por ser siempre comprensible y por haber sacrificado muchas cosas para que hoy yo fuera la persona que soy.

A mí querido y adorado padre:

Por siempre estar a mi lado y ser un gran ejemplo de padre para mí, por enseñarme desde muy pequeño muchas cosas buenas que han hecho posible mi formación y por estar siempre pendiente de mis cosas y que, igual que mi mamá, sé que estaría dispuesto a dar lo que no tiene por verme feliz.

A mis hermanos:

Estas bellas personas de las cuales siempre he recibido un gran apoyo y mucho amor. Que siempre han estado muy cerca de mí para guiarme y ayudarme en las cosas más importantes de mi vida. Por haber sido un gran ejemplo para mí.

A mis familiares:

Por estar siempre cuando los necesité, por apoyarme en los momentos más difíciles de mi carrera de mi vida y por permitirme ser miembro de una familia tan unida.

A mis profes:

Por enseñarme tantas cosas que a lo largo de mi vida me han formado para ser un profesional comprometido con su profesión, sobre todo a mi tutor Osvaldo y a los profe Ernesto Carrasco, Gerandys y la Profe Lilian Cid, por apoyarme tanto en mi tesis. A la profesora Lida González Álvarez por ser una persona carismática, sociable y muy buena en el arte de enseñar, por ser ejemplo de sacrificio para nosotros y en especial para mí.

A mis amigos:

Por permitirme conocerlos y compartir conmigo estos largos 5 años, Sobre todo a mi gran amigo Lázaro Campoalegre y Yoel Martín. Por ser mi mano derecha y por darme el ejemplo como estudiante y como persona. Por haberme dado su amistad, sobre todo cuando a veces se está tan lejos del hogar.

A mí querida universidad:

Por permitirme aprovechar estos cinco años para formarme como un profesional comprometido con la Revolución. Y por permitirme desarrollarme como persona como profesional.

DEDICATORIA

A mi madre:

Por ser la flor que me ha forjado como persona en este mundo, por cobijarme bajo su sombra y darme su abrigo toda mi vida.

A mi padre:

Por ser mi amigo desde siempre, por caminar a mi lado cuando era pequeño, por guiarme y quererme tanto, por enseñarme que las grandes victorias y lo que uno más ama y quiere viene del sacrificio diario lo que uno sea capaz de forjar.

A mis hermanos:

Por ser mi ejemplo y mis compañeros, amigos y por jugar conmigo cuando estaba enfermo, por darme una palmadita en la espalda cuando hacía algo mal y por enseñarme a ser el hombre que soy.

A mi familia:

Por estar ahí siempre que los he necesitado, por acogerme en sus senos como un miembro más de ella, y por tenerme gran amor.

A Fidel y la Revolución:

Por crear la Universidad de las Ciencias Informáticas que me ha dado la posibilidad de ser ingeniero y crecer intelectualmente, y por ser el líder de una Revolución que ha traído tanto bien para mí a todos los cubanos.

Quisiera agradecer a todas aquellas personas que de una forma u otra han tenido que ver con mi desarrollo como persona; a mi grupo del Luis Urquiza Jorge, a mis compañeros del 5109, a mis compañeros de aula, a todas las amistades que hice en esta universidad. A todas esas personas que han sido mi ejemplo como persona y como amigo.

RESUMEN

En la actualidad, el creciente desarrollo de las técnicas de adquisición de imágenes médicas está revolucionando la medicina. Estas imágenes juegan un papel importante en el diagnóstico y tratamiento de enfermedades, debido que les permiten a los médicos y científicos obtener información vital al observar el interior del cuerpo humano de una forma no invasiva. En consecuencia, la comunidad de análisis de imágenes ha centrado sus esfuerzos en resolver el desafiante problema de extraer, con ayuda del computador, información clínica útil acerca de estructuras anatómicas a partir de imágenes de Tomografía Computarizada (CT – *Computer Tomography*), Resonancia Magnética (MR – *Magnetic Resonance*) y otras modalidades. En particular, los algoritmos que extraen información relevante de una imagen son conocidos como algoritmos de segmentación de imágenes, y aunque estos han resuelto problemas particulares de segmentación, no existe ninguno que responda a todas las necesidades. Estos algoritmos a su vez juegan un papel importante en numerosas aplicaciones biomédicas de tratamiento de imágenes. Por la importancia tiene la segmentación de imágenes, en el software de visualización tridimensional para el diagnóstico de patologías, en este trabajo; a partir del marco teórico estudiado se propone un algoritmo de segmentación semiautomático basado en crecimiento de regiones para imágenes médicas digitales.

PALABRAS CLAVE

DICOM, Imágenes Médicas, Procesamiento de Imágenes, Segmentación, Segmentación Automática, Segmentación Asistida, Vóxel.

ÍNDICE

INTRODUCCIÓN:.....1

CAPÍTULO 1: FUNDAMENTACIÓN TEÓRICA.....4

1.1. IMÁGENES MÉDICAS.....4

 1.1.1. *Neuroimagen*.....4

 1.1.2. *Modalidades de neuroimágenes*.....5

 1.1.3. *Formatos de representación de neuroimágenes*.....5

 1.1.3.1. DICOM.....5

 1.1.3.2. ANALYZE 7.5.....6

 1.1.3.3. Neuroimaging Informatics Technology Initiative (NIfTI 1.1).....7

1.2. PREPROCESAMIENTO DE LAS IMÁGENES MÉDICAS.....7

 1.2.1. *Realce punto a punto*.....8

 1.2.1.1. Transformaciones logarítmicas.....8

 1.2.1.2. Transformaciones exponenciales.....10

 1.2.1.3. Histograma.....12

 1.2.1.4. Filtro Gaussiano.....14

 1.2.2. *Filtrado espacial*.....15

 1.2.2.1. Filtros lineales suavizadores o promediadores.....16

 1.2.2.2. Filtros lineales Laplaciano (2da Derivada).....17

 1.2.2.3. Laplaciano de Gaussiano.....18

 1.2.2.4. Filtros lineales por Gradiente (1ra Derivada).....18

 1.2.2.5. Filtro de la mediana.....21

1.3. TÉCNICAS CLÁSICAS DE SEGMENTACIÓN DE IMÁGENES MÉDICAS.....22

 1.3.1. *Métodos de umbralización*.....23

 1.3.2. *Crecimiento de regiones o región creciente*.....24

 1.3.3. *Detección de discontinuidades*.....25

1.4. OTRAS TÉCNICAS DE SEGMENTACIÓN.....26

 1.4.1. *Clasificadores*.....26

 1.4.2. *Métodos de agrupamiento (Clustering Methods)*.....27

 1.4.3. *Modelos de campos aleatorios de Markov*.....27

 1.4.4. *Redes neurales artificiales*.....28

 1.4.5. *Modelos deformables*.....28

 1.4.6. *Métodos guiados por plantillas (Atlas Guided Methods)*.....29

CAPÍTULO 2: SOLUCIÓN PROPUESTA DEL SISTEMA Y RESULTADOS.....31

2.1 ADQUISICIÓN DE IMÁGENES MÉDICAS.....31

 2.1.1 *Imágenes tridimensionales*.....32

2.1.2	<i>Vecindad entre vóxeles</i>	32
2.1.3	<i>Distancia entre vóxeles</i>	33
2.2	PROCESAMIENTO DE IMÁGENES MÉDICAS 3D	34
2.2.1	<i>Filtros implementados 3D</i>	35
2.3	SEGMENTACIÓN DE IMÁGENES 3D	37
2.4	ENFOQUE A LA SEGMENTACIÓN ASISTIDA	37
2.5	CRECIMIENTO DE REGIONES O VOXEL GROWING	40
2.5.1	<i>Especificación de semillas</i>	41
2.5.2	<i>Aceptación de vóxeles</i>	42
2.5.3	<i>Incorporación de vóxeles guiada por conocimiento</i>	44
2.6	ANÁLISIS, COMPARACIÓN Y VALORACIÓN DE LOS RESULTADOS	45
 CAPÍTULO 3: ANÁLISIS Y DISEÑO DEL SISTEMA		48
3.1.	REGLAS DEL NEGOCIO	48
3.2.	MODELO DE DOMINIO	48
3.2.1.	<i>Descripción del Modelo de Dominio</i>	49
3.3.	CAPTURA DE REQUISITOS	49
3.3.1.	<i>Requisitos Funcionales</i>	49
3.3.2.	<i>Requisitos No Funcionales</i>	50
3.4.	MODELO DE CASOS DE USO DEL SISTEMA	51
3.4.1.	<i>Actores del Sistema</i>	52
3.4.2.	<i>Diagrama de Casos de Uso del Sistema</i>	52
3.4.3.	<i>Descripción de casos de Uso del Sistema</i>	53
3.5.	DIAGRAMA DE CLASES DE ANÁLISIS	57
3.6.	DIAGRAMAS DE COLABORACIÓN	58
3.7.	DIAGRAMAS DE SECUENCIA DEL DISEÑO	60
3.8.	DIAGRAMA DE CLASES DEL DISEÑO DEL SISTEMA	61
3.9	DIAGRAMAS DE COMPONENTE	62
 CONCLUSIONES		64
 RECOMENDACIONES		65
 REFERENCIAS BIBLIOGRAFÍA		66
	 [5] REVISTA CUBANA DE INVESTIGACIONES BIOMÉDICAS. [EN LÍNEA] 2006 [CITADO EL: 20 DE OCTUBRE DE 2010.] DISPONIBLE EN:.....	66
 ANEXOS		68

GLOSARIO.....69

INTRODUCCIÓN:

En la medicina actual, hacer diagnósticos utilizando imágenes es invaluable. Las modalidades de adquisición de imágenes de Resonancia Magnética (RM), Tomografía Axial Computarizada (TAC) y Mamografía Digital por mencionar algunas, proveen un medio no-invasivo y efectivo de representar la anatomía de un paciente. Estas tecnologías han creado las condiciones para que se pueda incrementar en gran medida el conocimiento de anatomías y patologías para la investigación médica, de igual forma son un componente esencial e inexorable en la planificación de diagnósticos y tratamientos de enfermedades.

Con el incremento en tamaño y número de imágenes médicas que se pueden obtener a partir de un estudio realizado por alguna modalidad a un paciente, se ha hecho necesario el uso del computador para facilitar el procesamiento y análisis de las mismas. En particular, los algoritmos para identificar estructuras anatómicas relevantes y delinear con precisión los bordes de dichas estructuras, son conocidos como algoritmos de segmentación de imágenes y son un componente clave para asistir y automatizar ciertas tareas radiológicas. Estos algoritmos de segmentación de imágenes desempeñan un papel importante en numerosas aplicaciones biomédicas de tratamiento de imágenes [1], ya que le facilitan a los especialistas un adecuado aprovechamiento de la cuantiosa información disponible sobre las imágenes de los pacientes.

Los métodos para llevar a cabo las segmentaciones varían ampliamente dependiendo de la aplicación específica, el tipo de la imagen, y otros factores. Actualmente no existe un algoritmo de segmentación que alcance resultados aceptables para todo tipo de imagen médica. Ni hay técnicas que sean generales y que puedan ser aplicados a cualquier variedad de datos [2]. De cualquier forma, los métodos que son especializados para aplicaciones particulares, pueden obtener mejores resultados tomando en cuenta la existencia del conocimiento a priori. Por lo tanto, la selección de una técnica o algoritmo apropiado para un problema de segmentación puede ser muy difícil.

Hoy en día en el mundo existen diferentes equipos calificados que utilizan algoritmos y técnicas que nos permiten, dada una serie de imágenes obtenidas por los tomógrafos, obtener e identificar diferentes partes del cuerpo radiografiado en imágenes en tres dimensiones (3D); de este modo, los médicos pueden estudiarlas y dar un mejor diagnóstico o tratamiento a una patología específica. Los algoritmos que

poseen estos equipos segmentan individualmente cada imagen por lo que los especialistas tienen que extrapolar de un resultado en dos dimensiones (2D) a un resultado en tres dimensiones (3D) para poder establecer una correspondencia entre lo segmentado en dos imágenes distintas.

Dada la **situación problemática** expuesta anteriormente, se plantea como **problema científico**: ¿Cómo identificar las estructuras anatómicas de interés en imágenes médicas 3D? A raíz de esto, se toma como **objeto de estudio** Segmentación de imágenes digitales y como **objetivo general**: Desarrollar un módulo para la segmentación de imágenes médicas 3D. Y dentro de esta extensa área de trabajo se toma como **campo de acción**: Segmentación de imágenes médicas ó Digital Imaging and Communication in Medicine (DICOM).

Para dar cumplimiento al objetivo de la investigación se han tomado las siguientes **tareas investigativas**:

- Investigar sobre los adelantos en la segmentación de imágenes DICOM, para estructurar el marco teórico.
- Identificar y documentar las diferentes técnicas de preprocesamiento y segmentación de imágenes médicas.
- Seleccionar y documentar los algoritmos y técnicas adecuados para las técnicas propuestas en el proyecto.
- Describir los requisitos funcionales y no funcionales del módulo de segmentación de imágenes médicas.
- Describir los casos de usos del sistema.
- Configuración de los diagramas de clases del diseño.
- Implementar los algoritmos de segmentación de imágenes médicas.
- Desarrollar el módulo de segmentación de imágenes médicas.
- Integrar el módulo de segmentación de imágenes médicas al proyecto visualización médica.

De igual forma, para todo el proceso de investigación es necesaria la utilización varios **métodos científicos de investigación**. Los cuales se reseñan a continuación.

- **Método Analítico-Sintético:** Con el objetivo de analizar las teorías, documentos e información, permitiendo la extracción de los elementos más importantes que se relacionan con el objeto de estudio.
- **Inductivo – deductivo:** Para luego de Inducir una serie de conocimientos referentes a la visualización médica, para poder arribar a razonamientos que conlleven a la deducción de conocimientos que puedan ser aplicables al problema a tratar en particular.
- **Análisis histórico-lógico:** El cual permitirá analizar y estudiar la trayectoria y evolución de los Algoritmos de Segmentación, para así poder contar con una noción de cuan desarrollado está el tema a nivel global y tomar la decisión de cual o cuales desarrollar.
- **Experimento:** Método empírico mediante el cual, se realizaran experimentos y pruebas de los principales algoritmos de per-procesamiento y de segmentación de imágenes médicas 3D, para examinar los resultados en busca de escoger los más adecuados.
- **Observación:** Mediante este método empírico se observarán los resultados obtenidos en la caracterización e identificación de los principales algoritmos utilizados, para poder decidir luego cuál o cuáles serán más adecuados.

CAPÍTULO 1: FUNDAMENTACIÓN TEÓRICA.

En este capítulo se abordaran de manera sintetizada los elementos básicos teóricos, de las técnicas de segmentación de imágenes 3D en el mundo. Estudiándose así tres elementos importantes en la segmentación de imágenes médicas, “Obtención de imágenes médicas”, “PreProcesamiento de las imágenes” y “Segmentación”.

1.1. Imágenes médicas.

Se le llama imagen médica al resultado de aplicar un conjunto de técnicas y procesos, que son usados con el fin de crear imágenes del cuerpo humano, o parte de él, aprovechando en sí las características físicas y químicas de estas, con propósitos clínicos (procedimiento médico que buscan revelar, diagnosticar o examinar enfermedades) o para la ciencia médica [1].

Entre las modalidades de adquisición de imágenes médicas se destacan las de Rayos X y las Tomografía Axial Computarizada (TAC), ambas basadas en radiaciones electrónicas. Otra de estas modalidades es la “Tomografía Computarizada” (TC), la cual por su facilidad de realización, la precisión diagnóstica y la ausencia de riesgo, la ha convertido en la primera alternativa de diagnóstico que se les realiza a los pacientes con patología neurológica. Igualmente, se destaca la Imagen por Resonancia Magnética (IRM), basada en la capacidad de algunos núcleos para absorber ondas de radiofrecuencia cuando son sometidos al efecto de un campo magnético.

1.1.1. Neuroimagen.

La neuroimagen, es el resultado de aplicar un conjunto de técnicas de adquisición de imágenes médicas en Neurología, para realizar el diagnóstico mediante la obtención de imágenes de los órganos y tejidos del sistema nervioso [3].

Otras definiciones dadas por otros autores consideran que, la neuroimagen es la expresión fisiológica del cerebro. Hoy, la resonancia magnética funcional ofrece una película de la actividad cerebral [4].

Tras estudiar varios de estos conceptos, consideramos desde este momento como neuroimagen, el resultado de aplicar un conjunto de técnicas para obtener imágenes médicas, específicamente la representación del sistema nervioso.

1.1.2. Modalidades de neuroimágenes.

Las modalidades de las neuroimágenes se pueden agrupar en dos grupos diferentes según la información que proporcionan al especialista, neuroimágenes anatómicas o estructurales y las neuroimágenes funcionales.

Las neuroimágenes anatómicas o estructurales son las que describen o brindan a los especialistas, información detallada acerca de la anatomía cerebral, dígase tejidos, disposición de órganos, existencia de otras estructuras relevantes; dentro de las mismas se pueden encontrar modalidades como las TAC y las RM.

Las neuroimágenes funcionales, por su parte, brindan a los especialistas información detallada del funcionamiento de la anatomía cerebral, al mostrar las estructuras, órganos y áreas cerebrales que se activan ante cierto estímulo; dentro de este grupo se encuentran modalidades como las Positron Emission Tomography (PET), Magneto Encefalografía (MEG), Electroencefalografía (EEG), Resonancia Magnética funcional (fMRI), entre otras [5].

1.1.3. Formatos de representación de neuroimágenes.

Casi la totalidad de los sistemas de procesamiento, fusión y visualización tridimensional de neuroimágenes utilizan archivos de formatos especialmente diseñados para imágenes médicas, a continuación se exponen algunos de dichos formatos con sus principales características.

1.1.3.1. DICOM.

El formato DICOM, está contemplado en el estándar DICOM 3.0, para el almacenamiento, procesamiento y transmisión de imágenes médicas, el cual fue creado por American College of Radiology (ACR) y National Electric Manufacturers Association (NEMA), para lograr una estandarización dentro de los fabricantes de equipos de adquisición de imágenes médicas. Por su uso a nivel mundial por parte de los

sistemas informáticos que implementan el estándar DICOM, constituye uno de los formatos de almacenamiento de imágenes médicas más extendidos y populares que existen.

DICOM permite la integración de escáneres, servidores, estaciones de trabajo, impresoras y hardware de red de múltiples proveedores dentro de un sistema de almacenamiento y comunicación de imágenes. Este estándar define: las estructuras de datos para las imágenes médicas y la información relacionada, ciertos servicios orientados a las comunicaciones (transmisión de imágenes, consulta de un archivo de imagen) los formatos para el intercambio de los datos almacenados, y los requisitos de compatibilidad para dispositivos y programas. Internamente, un fichero DICOM está formado por dos componentes [6].

- El primero es una cabecera que contiene un número variable de conjuntos de datos o DataSet. Cada DataSet se compone de varios elementos de datos o DataElement. [Ver Anexo 1.](#)

Define la información asociada a la imagen médica, así por ejemplo se tienen elementos de datos tales como: nombre del paciente, edad, espacio entre píxeles, modalidad y dimensión de la imagen y otros, almacenados en un archivo único (.dcm).

- El segundo componente de un fichero DICOM contiene una o más imágenes, es decir, el flujo de bytes donde se codifican las imágenes en sí. No debe confundirse con los datos de la imagen (capas, bits dedicados, filas, columnas) que se codifican en la cabecera.

1.1.3.2. ANALYZE 7.5.

El formato ANALYZE 7.5, se creó para ser usado en el software de procesamiento de imágenes médicas ANALYZE, dicho formato es ampliamente usado en el campo de las neuroimágenes funcionales, y ha sido implementado por numerosos programas comerciales de procesamiento de imágenes médicas entre los que se puede mencionar: SPM, FreeSurfer, MRico.

Entre las principales características del formato ANALYZE 7.5, se encuentran:

- La información se encuentra almacenada en dos archivos, un archivo imagen (.img), que posee datos como son el flujo de vóxeles, tipo de dato y orden que presentan los mismos, los cuales están descritos por un archivo cabecera (.hdr), que contiene información sobre las dimensiones de

las imágenes, datos del paciente, y otros.

- Es un formato flexible y extensible, pues permite la inclusión de nuevos tipos de datos si el usuario los necesitara [7].

1.1.3.3. Neuroimaging Informatics Technology Initiative (NifTI 1.1).

El formato NifTI 1.1, propuesto por el Data Format Working Group (DFWG) de Neuroimaging Informatics Technology Initiative (NifTI), tiene una estructura basada en la del formato ANALYZE 7.5, pero NifTI 1.1 introduce una serie de mejoras enmarcadas sobre todo para facilitar el análisis de datos en las fMRI.

Entre las principales características de NifTI 1.1, se encuentran:

- La información puede ser almacenada ya sea en el formato archivo cabecera-archivo imagen (.hdr y .img) al igual que en el formato ANALYZE 7.5 o también puede ser almacenada en un archivo único (.nii).
- Mantiene la compatibilidad con programas que utilizan como formato de almacenamiento de imágenes médicas el formato ANALYZE 7.5.
- Ha extendido las capacidades que ya existían en el formato ANALYZE 7.5, dígame desde nuevos tipos de datos, códigos y parámetros para lograr una mejor descripción del significado de los datos hasta la modificación del propósito de campos ya existentes en la cabecera del formato ANALYZE 7.5 [8].

1.2. Preprocesamiento de las imágenes médicas.

Las imágenes obtenidas a partir de los diferentes dispositivos de captura son en sí, una serie secuencial de cortes digitales transversales de la zona analizada, a partir de los cuales es posible generar una estructura tridimensional (3D) que simule el volumen del objeto originalmente escaneado. Uno de los grandes retos que ofrece el preprocesamiento de imágenes médicas es poder definir con exactitud el límite de cada estructura anatómica de interés o disminuir el ruido presente en la imagen. Para obtener estas mejoras se utilizan filtros cuya respuesta se ajuste a las necesidades del proceso.

1.2.1. Realce punto a punto.

Se conoce que una operación **es puntual** cuando el resultado de la imagen de salida depende del valor del píxel de entrada, es decir, $g(x, y) = T f(x, y)$, donde $f(x, y)$ es el valor del píxel de entrada en el punto (x, y) , T es una transformación dada y $g(x, y)$ es el valor del píxel de salida en el punto (x, y) . A continuación se muestran algunas de estas operaciones.

1.2.1.1. Transformaciones logarítmicas.

La forma general de la transformación logarítmica es:

$$s = c \log(1 + r)$$

donde C es una constante, y se asume que siempre $r \geq 0$, la forma de la curva logarítmica en la **Figura 1.1** muestra la transformación de mapas en un estrecho rango de niveles de grises, los valores de entrada en la imagen y un amplio rango de niveles de salida. A los valores de entrada se le aplica una de estas transformaciones para ampliar los valores de intensidades oscuras en los píxeles de la imagen o para comprimir los mismos.

Cualquier curva con la forma general de las funciones logarítmicas mostradas en la **Figura 1.1** llevaría a cabo esta difusión entre la compresión de los niveles de gris en una imagen. Las funciones logarítmicas tienen como característica importante que comprime el rango dinámico de las imágenes con grandes variaciones en los valores de los píxeles. Un ejemplo clásico de una solicitud en el que los valores de píxeles tienen un amplio rango dinámico es el espectro de Fourier [9].

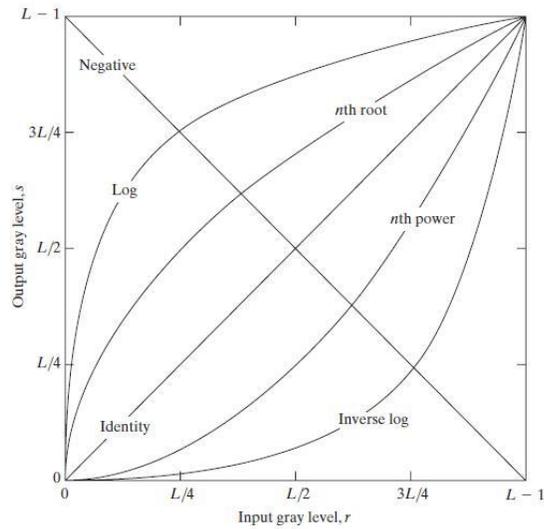


Figura 1.1 Algunas transformaciones básicas a niveles de grises para la mejora de la imagen.

En la **Figura 1.2** (a) se muestra un espectro de Fourier con valores en el rango de $0 - 1.5 \times 10^6$. Estos valores se escalan linealmente para indicar en un sistema de 8-bits, donde dominará el píxel más brillante de la pantalla.

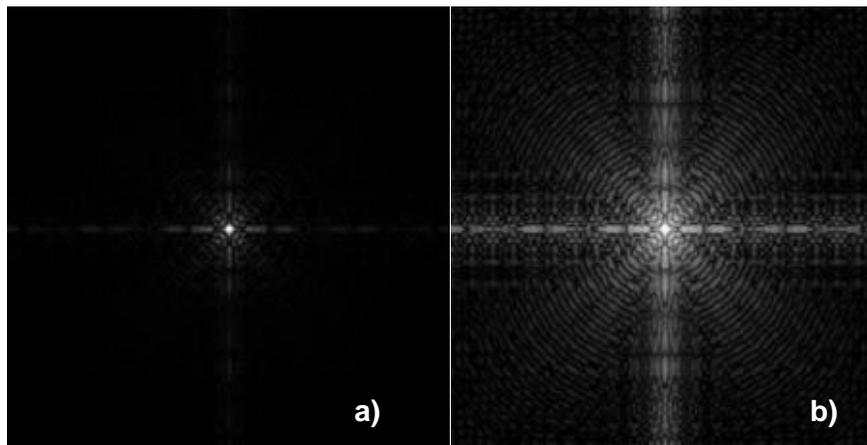


Figura 1.2 (a) Espectro de Fourier. (b) Resultado al aplicar Transformaciones log donde $c=1$.

Figura 1.2 (b) muestra el resultado de esta nueva gama de escala lineal y la visualización del espectro en la misma imagen de 8-bit de entrada. Los nuevos detalles visibles en la presente imagen nos muestran zonas que anteriormente no se veían en la imagen de entrada por el espectro de Fourier.

Según Rafael G. [9], la mayoría de los espectros de Fourier visto en las publicaciones de procesamiento de imágenes han sido reducidos precisamente de esa manera **Figura 1.1**.

1.2.1.2. Transformaciones exponenciales.

Las transformaciones exponenciales tienen la siguiente forma básica $s = cr^\gamma$ donde **C** y γ son constantes positivas. Aunque en otras bibliografías la podemos encontrar de la siguiente forma $s = c (r + \epsilon)^\gamma$ y se escribe así para dar cuenta de un desplazamiento (es decir, un resultado medible cuando la entrada es cero). Sin embargo, las compensaciones suelen ser un problema de calibración de la pantalla y como resultado normalmente se ignoran en la ecuación. [9]

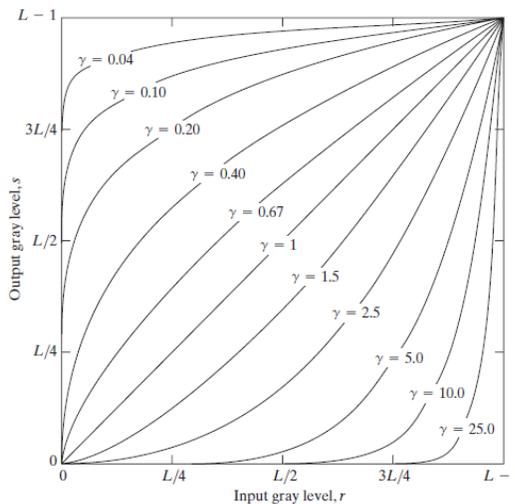


Figura 1.3 Gráfica de la ecuación $S = CR^\gamma$ para varios valores de γ ($C=1$ y otros casos).

En la **Figura 1.3** se muestra la familia de curvas que se pueden obtener simplemente variando γ , además se puede ver que las curvas generadas con los valores $\gamma > 1$ tienen exactamente el efecto contrario que las generadas por los valores de $\gamma < 1$.

Con el acercamiento a la corrección gamma, transformaciones exponenciales, son usados con el propósito general de la manipulación del contraste en imágenes. En la **Figura 1.4** se muestra una (MR) la imagen de una parte superior de la espina dorsal humana con una fractura dislocación de impacto externo de la médula espinal. En la imagen original no se observa con claridad la magnitud del problema, y ya al ser aplicado la transformación exponencial se pueden ver con claridad estos daños.

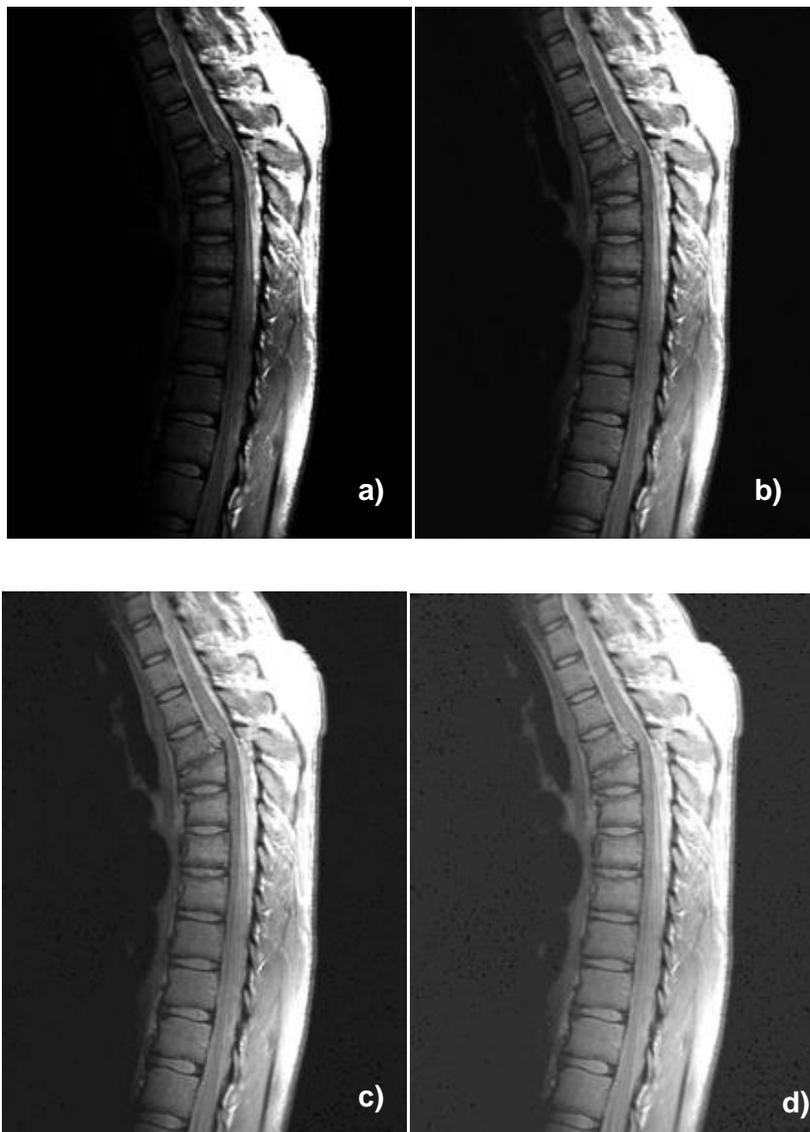


Figura 1.4 (a) Imagen de resonancia magnética (MR), fractura de espina dorsal humana.

(b-d) resultado al aplicar transformaciones exponenciales con $C = 1$, y $\gamma = 0.6, 0.4, 0.3$.

Cuando la imagen a analizar tiene un aspecto descolorido, esto indica que hay una compresión de los niveles de grises, por lo que para mejorar la visión de esta imagen se le aplicara las transformaciones exponenciales pero esta vez con $\gamma > 1$, lo que te acarrearía una descompresión de los niveles de grises y con esto obtendrías aéreas más oscuras, mejorando así el contraste de la imagen de entrada.

1.2.1.3. Histograma.

El histograma es una representación gráfica de los niveles de grises definido: $[0, L-1]$ en forma de barras, donde la superficie de cada barra es proporcional a la frecuencia de los valores representados. En el eje vertical se representan las frecuencias, y en el eje horizontal los valores de los niveles de grises, normalmente, señalando las marcas de clase, es decir, la mitad del intervalo en el que están agrupados los datos.

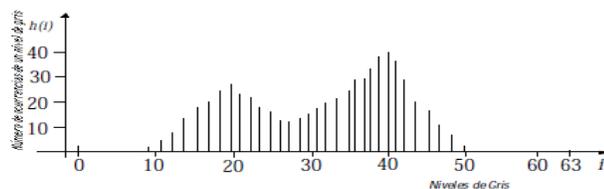


Figura 1.5 Histograma de una imagen.

Ecuación del histograma:

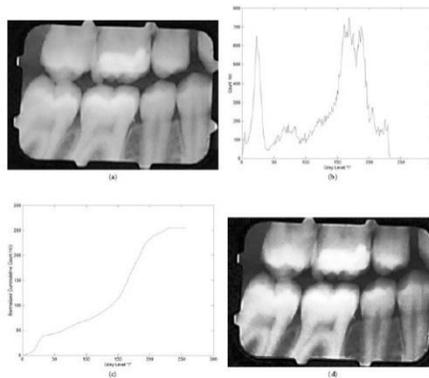
En algunos casos se logra mejora significativa en la visualización de una imagen al maximizar el aprovechamiento del rango de nivel de gris disponible. Esto se logra distribuyendo la información de intensidad de la imagen sobre todo el rango. La técnica se basa en la interpretación del histograma de la imagen como una distribución de probabilidad de la intensidad de los píxeles.

El número total de píxeles en una imagen es $M \times N$ y es igual a la suma de todos los valores en el arreglo $h(i)$. Para distribuir de manera uniforme todos los píxeles de la imagen en el rango $(0, P-1)$, debemos tener $(M \times N)/P$ píxeles en cada elemento de $h(i)$. Para lograr esto se utiliza el histograma acumulado normalizado:

$$H(j) = \frac{1}{M * N} \sum_{i=0}^j h(i), \quad j = 0, 1, \dots, P - 1.$$

Una vez calculado, el histograma acumulado normalizado se puede utilizar como un mapeo entre la imagen original y una nueva imagen de salida. La imagen final tendrá un histograma de máxima uniformidad si se calcula como:

$$g(m, n) = (P - 1) * H(f(m, n)).$$



En la Figura 1.6 Ecuación del histograma.

Ecuación local del histograma:

Esta operación no lineal proporciona incrementos importantes en el contraste de una imagen. Se basa en la aplicación del método de ecuación descrito antes, aplicado sobre una ventana de tamaño $(2K+1 \times 2L+1)$ de manera traslapada:

$$h_{LA}(m, n)(i) = \sum_{k=-K}^K \sum_{l=-L}^L \delta(f(m+1, n+k) - i), \quad i = 0, 1, \dots, P - 1$$

$$H_{LA}(m, n)(i) = \frac{1}{(2K+1) * (2L+1)} \sum_{j=0}^i h_{LA}(m, n)(j) \quad j=0, 1, \dots, P-1$$

$$g(m, n) = (P-1) * H_{LA}(m, n)(f(m, n))$$

Donde $h_{LA}(m,n)(i)$ es el histograma local, $H_{LA}(m,n)(j)$ es el histograma local acumulado, y $g(m,n)$ es la imagen de salida. La **Figura 1.7** se muestra una imagen con ecualización local. El método tiene tiempos de procesamiento muy grandes.



Figura 1.7 Ecualización local del histograma.

1.2.1.4. Filtro Gaussiano.

Este filtro tiene un mejor desempeño que el filtro de mediana. La respuesta en frecuencia de ambos se muestra en la **Figura 1.8**.

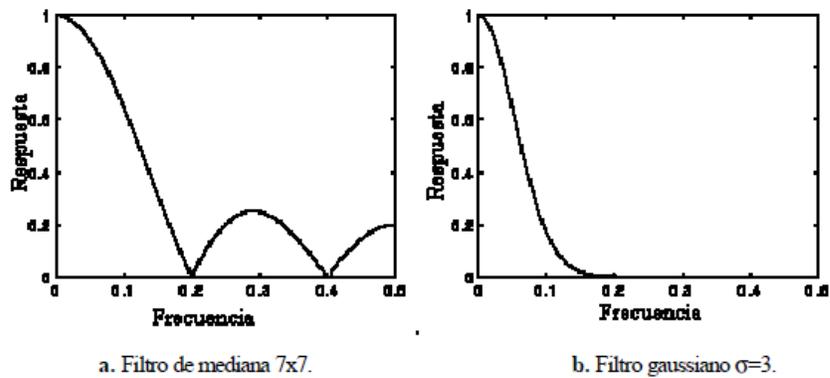


Figura 1.8 Comparación entre la frecuencia de gaussiano y la mediana 7x7.

En la **Figura 1.9** se puede observar que el filtro gaussiano, el cual brinda una mayor atenuación de las componentes de alta frecuencia. El filtro gaussiano en dos dimensiones tiene la forma.

$$G(x, y) = \frac{1}{2\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

Donde σ es la desviación estándar de la distribución y se ha asumido una media igual a cero.

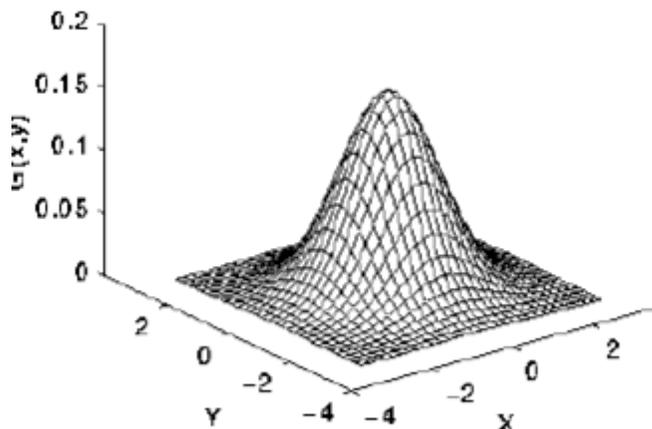


Figura 1.9 Distribución gaussiana en dos dimensiones con $m=0$ y $\sigma=1$.

La distribución gaussiana es significativa en un rango de tres desviaciones estándar a partir de la media, por lo tanto, el tamaño de la máscara que aproxima la respuesta deseada se calcula teniendo en cuenta este criterio.

1.2.2. Filtrado espacial.

Una operación **es local** cuando el valor del píxel de salida depende tanto del valor del píxel de entrada como de los valores de los píxeles que les rodea, es decir:

$$g(x, y) = T \{ f(x_i, y_j) \} \text{ donde } i, j = 1, 2, \dots, 8.$$

Donde T es una transformación dada y $f(x_i, y_j)$ significa el entorno alrededor del punto (x_i, y_j) .

En general en este tipo de operaciones el tamaño de la ventana puede ser variable en dependencia del

objetivo de la aplicación. Tamaños típicos de ventanas pueden ser de 3x3, 5x5 y 7x7. Por lo general las máscaras para la convolución son cuadradas y de dimensión impar con el fin que el píxel de la imagen que se procese que en el medio.

1.2.2.1. Filtros lineales suavizadores o promediadores.

Los filtros suavizadores se utilizan para difuminar y para reducir el ruido. El difuminado se suele emplear en etapas de pre-procesado de imágenes por ejemplo para eliminar pequeños detalles de una imagen para luego extraer algún objeto de mayor tamaño o para eliminar trozos que han desaparecido de líneas o curvas. La reducción de ruido puede conseguirse tanto utilizando un filtro que difumine, como empleando un filtrado no lineal.

La forma de la respuesta al impulso necesario para implementar un filtro paso bajo espacial nos indica que todos los coeficientes de la máscara han de ser positivos (**ver figura 1.10**). Un ejemplo de máscara con todos los valores positivos es aquella en que todos los coeficientes tienen valor 1. Para asegurar que el valor del nuevo píxel resultado de la suma de los productos de la máscara no excede el rango de valores de los tonos de grises se suele dividir la suma por el número de coeficientes de la máscara. En la figura se puede observar una máscara paso bajo y su efecto al ser aplicada sobre una imagen.

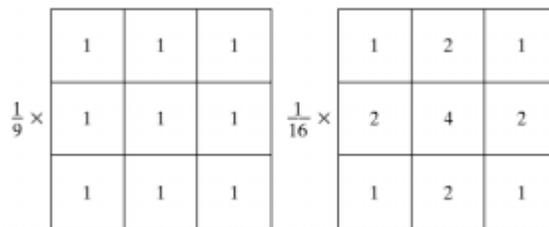


Figura: 1.10 Máscara para filtros paso bajo espacial.

$$R = \frac{1}{9} \sum_{i=1}^9 Z_i \quad g(x, y) = \frac{\sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x+s, y+t)}{\sum_{s=-a}^a \sum_{t=-b}^b w(s, t)}$$

El problema del método explicado anteriormente es que difumina los bordes y otros detalles afilados. Si el objetivo es reducir el ruido en vez de difuminar, una alternativa es utilizar **filtros de mediana**. En estos

filtros, el nivel de gris del cada píxel es reemplazado por la mediana de los niveles de gris de los píxeles que lo rodean. Este método de filtrado es particularmente efectivo cuando el patrón de ruido consiste en fuertes impulsos y se pretende mantener los bordes sin difuminar.

1.2.2.2. Filtros lineales Laplaciano (2da Derivada).

Este filtro consiste básicamente en la definición de una formulación discreta de la derivada de segundo orden y luego la construcción de la máscara de filtrado [9].

$$\nabla^2 = [f(x + 1, y) + f(x - 1, y) + f(x, y + 1) + f(x, y - 1) - 4f(x, y)] +$$

$$[f(x - 1, y - 1) + f(x + 1, y + 1) - 2f(x, y)] +$$

$$[f(x + 1, y - 1) + f(x - 1, y + 1) - 2f(x, y)]$$

1	1	1
1	-8	1
1	1	1

Figura 1.11 Máscara de Laplaciano.

Este operador es poco utilizado para la detección de bordes debido a que es extremadamente sensible al ruido, produce bordes dobles y no brinda información sobre la dirección del borde. Sin embargo, puede utilizarse en combinación con un filtro gaussiano, aprovechando sus propiedades de cruce por cero, y obteniendo así un mejor detector de bordes llamado Laplaciano de Gaussiano (LoG). El Laplaciano es un operador que aproxima la segunda derivada de la imagen, por lo tanto, la respuesta de la máscara en los contornos de los objetos presentes en la imagen es positiva en un lado del contorno y negativa en el otro, este es el motivo por el cual este operador produce bordes dobles. La propiedad importante del Laplaciano es que utilizando los cruces por cero, es decir, el paso de un valor positivo a uno negativo, se puede encontrar la posición real del borde. Este efecto se muestra en la **Figura 1.12**.

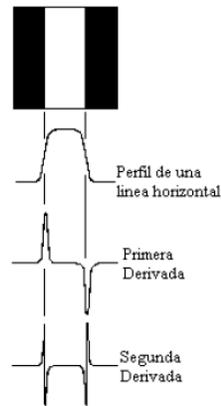


Figura 1.12 Propiedad de cruce por cero del Operador Laplaciano.

Al aplicar este filtro da la sensación de:

- Detalles más claros.
- Realce de las variaciones de nivel de gris.

1.2.2.3. Laplaciano de Gaussiano.

Este detector de bordes aprovecha la propiedad de suavizado de un filtro gaussiano y la característica de cruce por cero del Laplaciano, mejorando la respuesta del operador Laplaciano gracias a la disminución de ruido producida por el filtro gaussiano. La máscara utilizada por este detector se calcula utilizando la siguiente expresión [10].

$$G(x, y) = -\frac{1}{\pi\sigma^2} \left(1 - \frac{x^2 + y^2}{2\sigma^2}\right) e^{-\frac{x^2 + y^2}{2\sigma^2}}$$

1.2.2.4. Filtros lineales por Gradiente (1ra Derivada).

Existen diferentes formas de aplicar filtros lineales por Gradiente (Derivada 1ra), entre otras que se encuentra "Diferencia Cruzadas (gradiente a lo largo de las direcciones a 45° y a -45°)" [9], [11].

Magnitud del vector:

$$\nabla f = \text{mag}(\nabla f) = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2}$$

Se aproxima con:

$$\nabla f \approx |G_x| + |G_y|$$

Robert en [9] propone 4 formas de filtrado de imágenes:

Derivada parcial en X:

$$\frac{\partial f}{\partial x} = f(x, y + 1) - f(x, y) \begin{bmatrix} -1 & 0 \\ 1 & 0 \end{bmatrix}$$

Derivada parcial en Y:

$$\frac{\partial f}{\partial y} = f(x + 1, y) - f(x, y) \begin{bmatrix} -1 & 1 \\ 0 & 0 \end{bmatrix}$$

Diferencias cruzadas (gradiente a lo largo de las direcciones a 45° Y a -45°)

$$G_x = f(x+1, y+1) - f(x, y) \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}$$

$$G_y = f(x, y+1) - f(x+1, y) \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$$

Pero generalmente se usan máscaras 3x3.

z_1	z_2	z_3
z_4	z_5	z_6
z_7	z_8	z_9

Figura 1.13 Máscara 3x3

$$G_x = (Z_7 + Z_8 + Z_9) - (Z_1 + Z_2 + Z_3)$$

$$G_y = (Z_3 + Z_6 + Z_9) - (Z_1 + Z_4 + Z_7)$$

Operador de Sobel: Este operador se basa en el concepto de gradiente. El gradiente de la función f en el punto de coordenadas (x, y) se define como el vector:

$$\Delta f \rightarrow = \begin{pmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{pmatrix} = \begin{pmatrix} G_x \\ G_y \end{pmatrix}$$

La magnitud y la dirección del gradiente son de importancia en la detección de bordes, porque brindan información valiosa que se puede utilizar para aceptar o rechazar un borde que no posea determinadas características, por ejemplo, si se desea reconocer los contornos pertenecientes a las líneas que delimitan los carriles de una carretera, se prestaría especial atención a contornos fuertes (magnitud) que formen líneas rectas con un ángulo de inclinación determinado (dirección). La magnitud del gradiente está dada por la distancia euclídea y se expresa como:

$$\Delta f \rightarrow = \left(\frac{\partial f}{\partial x}^2 + \frac{\partial f}{\partial y}^2 \right)^{1/2}$$

y su dirección por:

$$\alpha(x, y) = \tan^{-1} \frac{G_x}{G_y}$$

Donde G_x y G_y son las derivadas de la función f en las direcciones x, y respectivamente.

El gradiente se puede calcular de diferentes maneras, sin embargo, los operadores de Sobel tienen la ventaja de proporcionar tanto una diferenciación como un efecto de suavizado, razón por la cual fueron escogidos para realizar las pruebas. Estos operadores se muestran en la Figuras siguientes.

-1	-2	-1	-1	0	1
0	0	0	-2	0	2
1	2	1	-1	0	1

a) **b)**

Figura 1.14 a) Máscara usada para calcular Gx. b.)Máscara usada para calcular Gy.

Máscara de Prewitt:

-1	-1	-1	-1	0	1
0	0	0	-1	0	1
1	1	1	-1	0	1

Figura 1.15 Máscara de prewitt.

- Al aplicar estas máscaras nos dan diferentes efectos de suavización, esto es según el filtro aplicado.

1.2.2.5. Filtro de la mediana.

Este filtro de mediana, que, como su nombre lo indica sustituye el valor de un píxel por la mediana de los niveles de gris en el barrio de ese píxel (el valor original del píxel está incluido en el cálculo de la mediana) **Figura 1.16**.

Los filtros de medios son muy populares, porque, para determinados tipos de ruido aleatorio, proporcionan una excelente reducción de la presencia de ruidos de impacto, también llamada sal y pimienta, debido a su aparición como puntos en blanco y negro superpuesto a una imagen ver **Figura 1.17** La mediana, j , de un conjunto de valores es tal que la mitad de los valores en el conjunto son menos que o igual a j , y la mitad son mayores que o igual a j . Para llevar a cabo el filtrado en un punto en una imagen, en primer lugar, ordenar los valores de los píxeles en cuestión y sus vecinos, determinar su medio, y asignar este valor a que píxel. Por ejemplo, en un barrio de 3×3 la mediana es el valor de 5 más grande, en un barrio de 5×5 el valor más grande de 13 **[9]**.

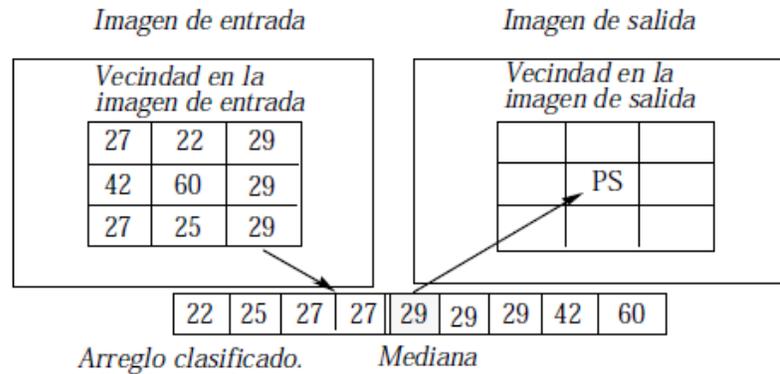


Figura 1.16 Ilustración del procedimiento para implantar el filtro de mediana.

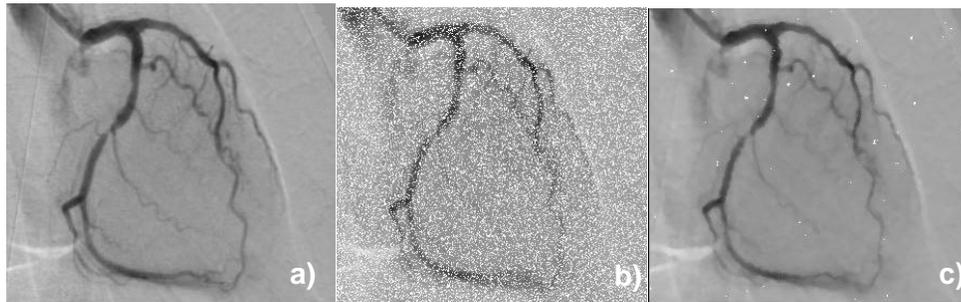


Figura 1.17 Ejemplo de filtro de mediana (a) imagen original,(b) imagen contaminada con ruido impulsivo

(c) Imagen procesada con un filtro de mediana.

1.3. Técnicas clásicas de segmentación de imágenes médicas.

El Análisis de imágenes médicas se compone de todos los métodos y técnicas que se utilizan para extraer características anatómicas del cuerpo humano e información válida para diagnosticar enfermedades. El primer paso para ello en los diagnósticos de enfermedades lo compone la segmentación de imágenes médicas, que se ocupa de descomponer una imagen en sus partes constituyentes, es decir, los objetivos de interés y el fondo, basándose en ciertas características locales que les permiten distinguir el objeto señalado.

La segmentación es la etapa crucial en cualquier sistema de visión por computadora tanto por las dificultades que conlleva como por la importancia de sus resultados. La segmentación no es más que la

extracción de estructuras (objetos) de la imagen, extracción de contornos, detección de regiones, detección de movimiento, dividir una imagen en objetos o partes. La clasificación de tejidos de imágenes de resonancia magnética (RMI) y tomografía computada (TC) es un proceso en el cual los elementos de imagen que representan el mismo tipo de tejido son agrupados en un solo conjunto y son referenciados en una misma clase.

1.3.1. Métodos de umbralización.

La umbralización es una técnica efectiva para obtener la segmentación de imágenes donde estructuras diferentes tienen intensidades contrastantes u otras características diferenciables. La partición usualmente es generada interactivamente, pero también existen métodos automáticos. Para imágenes escalares, los métodos interactivos pueden estar basados en la apreciación visual del usuario ya que la operación de umbralización es implementable en tiempo real. La **Figura 1.18** muestra un histograma de una imagen que, aparentemente posee tres clases lo cual deja dos posibles valores de umbral en los valles del histograma. La determinación de más de un valor de umbral es un proceso llamado multiumbralización (multithresholding). [2]

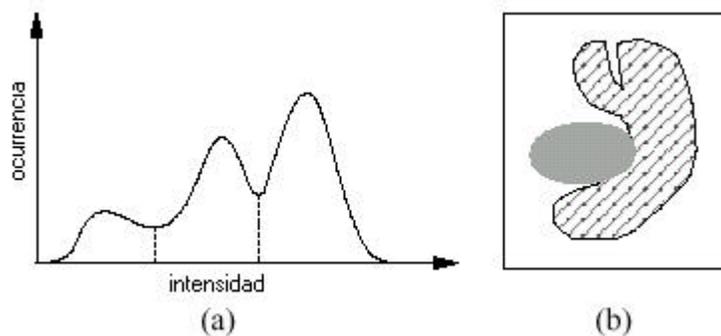


Figura 1.18 Histograma de intensidades de grises en la imagen mostrando los posibles umbrales (b) Imagen en escala de grises.

Algunas características de esta técnica son:

- Transforma un conjunto de valores, variando en algún rango, en otro conjunto de valores que contienen sólo los valores deseados. Lo cual se realiza aplicando un nivel de umbralización a los datos.
- Existen 2 clasificaciones posibles para cada píxel: si el píxel está por debajo del nivel del umbral recibirá un valor y si está por encima de este, otro.
- Como existen sólo 2 posibles clasificaciones, el resultado será una imagen binaria (2 tonos).
- La medida del umbral marca el nivel de gris (es un atributo global).

1.3.2. Crecimiento de regiones o región creciente:

Región creciente (*región growing*) es una técnica para extraer regiones de la imagen, que están conectadas según cierto criterio predefinido. Este criterio puede estar basado en información de intensidades y bordes de la imagen [12]. En su forma más simple, este método requiere un punto semilla (*seed point*) que es seleccionado manualmente por el usuario, y extrae todos los píxeles conectados a la semilla, que tengan el mismo valor de intensidad. La **Figura 1.19** muestra un ejemplo donde se utiliza el método de región creciente para aislar una estructura.

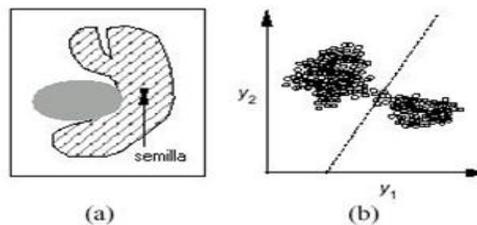


Figura 1.19(a) Imagen mostrando semilla inicial (b) Ejemplo de región Creciente.

Al igual que la umbralización, por lo general no se utiliza la región creciente solamente en una imagen, sino que se utiliza como parte de un conjunto de operaciones de procesamiento de imágenes, particularmente en la delineación de pequeñas y simples estructuras como tumores y lesiones. Su desventaja principal es que requiere interacción manual para obtener el punto semilla. Los algoritmos de división y mezcla (*split and merge*) están relacionados con la región creciente pero no requieren una semilla. La región creciente también puede ser sensible al ruido, causando que las regiones extraídas tengan agujeros e inclusive que se desconecten [13].

Algunas características de esta técnica son:

- Tiene en cuenta una serie de semillas que define el operador. Las semillas son píxeles seleccionados por una persona.
- Intenta hacer crecer una región conectada uniforme originada en cada semilla.
- Un píxel se agrega a la región si:
 - I. No se asignó antes a otra región.
 - II. Es vecino de la región.
 - III. Si cumple con una serie de condiciones anteriormente programadas.
 - IV. Si es frontera con otra región.
- La región creada al agregar el nuevo píxel sigue siendo uniforme.

Problemas:

- Da distintos resultados de acuerdo con el concepto de vecindad empleado (4 vecinos u 8 vecinos.)
- Los resultados son muy sensibles a las semillas seleccionadas.

1.3.3. Detección de discontinuidades.

Esta técnica es para detectar varios tipos de discontinuidades: puntos, líneas y bordes. El método más común de buscar discontinuidades es la correlación de la imagen con una máscara. Este procedimiento se realiza el producto de los elementos de la máscara por el valor de gris correspondiente a los píxeles de la imagen encerrados por la máscara. La respuesta a la máscara de cualquier píxel de la imagen viene dado por:

$$R = \sum_{i=1}^9 w_i z_i$$

Donde Z_i es el nivel de gris asociado al píxel de la imagen con coeficiente de la máscara W_j . Como suele ser habitual, la respuesta de la máscara viene referida a su posición central. Cuando la máscara esté centrada en un píxel de borde de la imagen, la respuesta se determina empleando el vecindario parcial apropiado [11].

1.4. Otras técnicas de segmentación.

Estas técnicas han surgido en otros campos de ciencias, pero se han podido aplicar a la segmentación de imágenes médicas.

1.4.1. Clasificadores.

Los métodos clasificadores son técnicas de reconocimiento de patrones que buscan particionar un espacio característico derivado de la imagen usando datos con etiquetas conocidas. Un espacio característico es un rango espacial de cualquier función de la imagen, siendo las intensidades de la imagen el más común de los espacios característicos. La **Figura 1.19 (b)** muestra un ejemplo de un espacio característico 2D particionado en dos clases aparentes. Todos los píxeles cuyas características estén en el lado derecho de la partición serían agrupados en una clase.

Los clasificadores son conocidos como *métodos supervisados* debido a que requieren datos de entrenamiento que son segmentados manualmente, para luego ser utilizados en la segmentación automática de nuevos datos. Hay una gran cantidad de maneras en las que los datos de entrenamiento pueden ser aplicados en los métodos de clasificación. Un clasificador simple es el clasificador del vecino más cercano, donde cada píxel o vóxel es clasificado en la misma clase que el dato de entrenamiento con la intensidad más cercana. Los k vecinos más cercanos (k NN – *k Nearest Neighbor*) es una generalización de este método. Otros clasificadores utilizados son la ventana de Parzen y el clasificador de Bayes.

Los clasificadores estándares requieren que la estructura a ser segmentada posea características cuantificables distintas, debido a que los datos de entrenamiento pueden ser etiquetados, los clasificadores pueden transferir estas etiquetas a los nuevos datos siempre que el espacio característico distinga cada etiqueta lo suficiente. Estos no son iterativos, por lo que son relativamente eficientes computacionalmente y pueden ser aplicados a imágenes multicanales. Una desventaja de los clasificadores es que no obedecen a ningún modelo espacial. Otra desventaja es la necesidad de la interacción manual para obtener los datos de entrenamiento. Los conjuntos de entrenamiento pueden ser adquiridos para cada imagen que requiera segmentación, pero esto puede tomar mucho tiempo y esfuerzo. En adición, el uso del mismo conjunto de entrenamiento para un gran número de imágenes

puede llevar a resultados viciados, ya que no toman en cuenta las variaciones anatómicas y fisiológicas entre diferentes sujetos.

1.4.2. Métodos de agrupamiento (*Clustering Methods*).

Los algoritmos de agrupamiento (*clustering*) propuestos por llevan a cabo esencialmente la misma función que los métodos clasificadores, pero sin utilizar datos de entrenamiento. Por lo tanto, son métodos *no supervisados*. Para compensar la falta de los datos de entrenamiento, los métodos de agrupamiento iteran entre segmentar la imagen y caracterizar las propiedades de cada clase. En este sentido, los métodos de agrupamiento se entrenan a sí mismos usando los datos disponibles. Un algoritmo de agrupamiento común es el algoritmo de las *K*-medias o algoritmo ISODATA [2].

1.4.3. Modelos de campos aleatorios de Markov.

Los modelos de campos aleatorios de Markov (MRF – *Markov Random Fields*) no constituyen un método de segmentación en sí mismos, pero son un modelo estadístico que puede ser usado dentro de los métodos de segmentación. Los MRF modelan las interacciones espaciales entre vecinos o píxeles cercanos. Estas correlaciones locales proveen un mecanismo para modelar una variedad de propiedades de la imagen. En el tratamiento de imágenes médicas, se utilizan frecuentemente para tomar en cuenta el hecho de que la mayoría de los píxeles pertenecen a la misma clase a la que pertenecen sus píxeles vecinos. En términos físicos, esto implica que bajo la asunción del MRF, cualquier estructura anatómica que consista de un solo píxel tiene una probabilidad muy baja de ocurrir.

Los MRF son incorporados frecuentemente en los algoritmos de segmentación por agrupamiento, como las *K*-medias bajo un modelo Bayesiano previo. La segmentación es obtenida maximizando la probabilidad *a posteriori* de la segmentación a partir de los datos de la imagen, obtenidos mediante métodos iterativos como los Modos Condicionales Iterados, presentados por [14], o el Templado Simulado, presentado por [15]. La **Figura 1.20 (b)** muestra la robustez de la segmentación frente al ruido, resultante de un MRF previo. Una dificultad asociada con los modelos MRF es la selección apropiada de los parámetros que controlan la fuerza de las interacciones espaciales. Una selección muy alta puede resultar en segmentación excesivamente suave y una pérdida de los detalles estructurales.

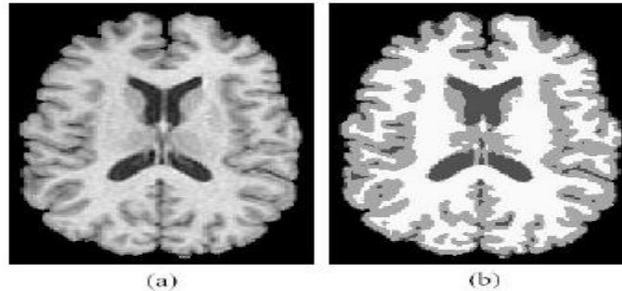


Figura 1.20 (a) Imagen original (b) Segmentación usando el algoritmo de *K*-medias usando un MRF previo.

En adición, los métodos MRF usualmente requieren algoritmos computacionalmente intensivos. A pesar de estas desventajas, los MRF son ampliamente utilizados no solo para modelar clases de segmentación, sino también para modelar propiedades de texturas e inhomogeneidades de las intensidades.

1.4.4. Redes neurales artificiales.

Las Redes Neuronales Artificiales (*Artificial Neural Network - ANN*) son redes masivamente paralelas de procesamiento de elementos o nodos que simulan el aprendizaje biológico. Cada nodo en una ANN es capaz de llevar a cabo cálculos elementales. Aprendizaje se alcanza a través de la adaptación de pesos asignados a las conexiones entre nodos. En [16] se realiza un tratamiento más profundo de las redes neuronales.

1.4.5. Modelos deformables.

Los modelos deformables están basados en motivaciones físicas, utilizados para delinear bordes de regiones usando curvas o superficies paramétricas cerradas que se deforman bajo la influencia de fuerzas externas e internas. Para delinear el borde de un objeto en la imagen, se debe colocar una curva o superficie cerrada cerca del borde deseado y luego permitirle experimentar un proceso iterativo de relajación. Las fuerzas internas se calculan en el interior de la curva o superficie para mantenerla suave a lo largo de la deformación. Las fuerzas externas son frecuentemente derivadas de la imagen para llevar la curva o superficie hacia la característica de interés deseada.

1.4.6. Métodos guiados por plantillas (*Atlas Guided Methods*).

Los métodos guiados por plantillas (*atlas guided methods*) son una poderosa herramienta para la segmentación de imágenes médicas cuando está disponible una plantilla o mapa estándar. El mapa o plantilla es generada por información compilada de la anatomía que requiere segmentación. Este mapa es utilizado como un marco de referencia para segmentar nuevas imágenes. Conceptualmente, los métodos guiados por plantillas son similares a los clasificadores con la excepción de que están implementados en el dominio espacial de la imagen en lugar de en un espacio característico.

Los métodos estándar guiados por plantillas primero encuentran una transformación uno-a-uno que transforma la plantilla de la imagen pre-segmentada a la imagen deseada que requiere segmentación. Este proceso se conoce como una deformación de plantilla (*atlas warping*). La deformación puede ser realizada usando transformaciones lineales, pero debido a la variabilidad anatómica, frecuentemente se utiliza una aplicación secuencial de transformaciones lineales y no lineales. Un ejemplo de *atlas warping* para una RM de una cabeza se muestra en la **Figura 1.21**.

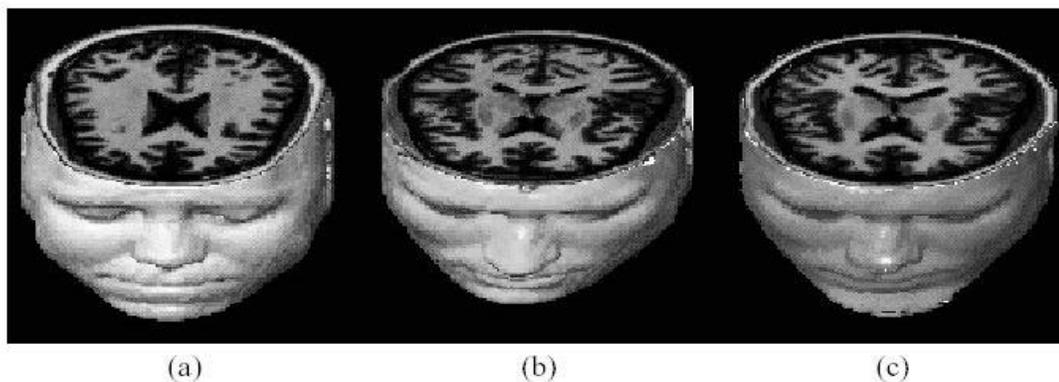


Figura 1.21 (a) imagen plantilla (b) imagen deseada (c) deformación de plantilla

Los métodos guiados por plantilla han sido aplicados principalmente en el tratamiento de imágenes de RM del cerebro. Esto es debido a que los métodos guiados por plantilla, por lo general se adaptan mejor a la segmentación de estructuras que son estables en toda la población de estudio.

Consideraciones del Capítulo:

Después del estudio para darle cumplimiento al **problema científico** “(¿Cómo identificar las estructuras anatómicas de interés en imágenes médicas 3D?)” se toma la decisión de trabajar con imágenes médicas DICOM 3.0, ya que es el estándar establecido en la comunidad científica internacional para la comunicación entre los equipos de adquisición de imágenes médicas, siendo este el formato universal más utilizado para el diagnóstico médico. Además, se proponen técnicas para el mejoramiento de imágenes como la de mediana, la del promedio, la de brillo entre otras. Para extraer características relevantes de las imágenes se propone el algoritmo “Crecimiento de Regiones”, pues este ofrece la posibilidad de extraer la región anatómica que realmente el médico desea, con solo seleccionar a través de un clic el vóxel que pertenezca a la región de interés.

CAPÍTULO 2: SOLUCIÓN PROPUESTA DEL SISTEMA Y RESULTADOS.

Después del estudio teórico realizado en el capítulo anterior, en este se describen las técnicas y algoritmos básicos seleccionados que conformarán los procesos de segmentación. Con el objetivo de adaptarlos a las particularidades de nuestra solución y se fundamentan las razones por las cuales no se hace uso de ninguna biblioteca de clases de las existentes a nivel mundial.

2.1 Adquisición de imágenes médicas.

Las imágenes DICOM obtenidas a partir de los diferentes dispositivos de captura consisten de una serie secuencial de finos cortes transversales de la zona analizada, donde cada corte representa una imagen 2D. La cual está compuesta por píxeles que están organizados en una rejilla bidimensional (grid 2D) donde la distancia entre dos píxeles por lo general es constante en cada dirección **Figura 2.1**. En las modalidades de adquisición de imágenes médicas TAC y RM las direcciones horizontales (eje x) y verticales (eje y) tienen igual la distancia entre los píxeles, la cual desde este momento nombraremos “*distancia entre píxeles*” y es un atributo que está presente como un elemento de dato (DataElement) en los ficheros DICOM

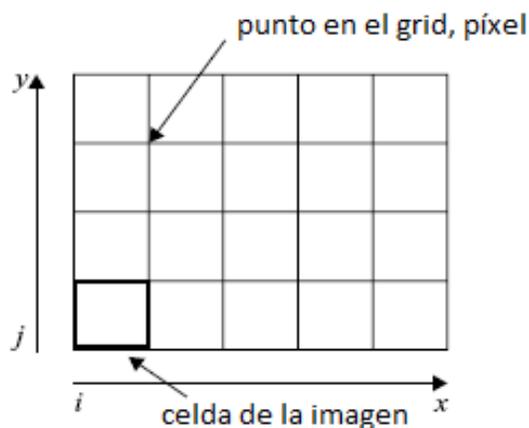


Figura 2.1. Representación de una Rejilla Bidimensional. (Grid 2D).

2.1.1 Imágenes tridimensionales.

Mediante esta secuencia de cortes es posible generar un volumen de imágenes tridimensionales (grid 3D), ya que los estudios TAC y RM enumeran cada imagen en el orden que se van obteniendo, lo que nos permite obtener el grid 3D ordenando estas imágenes. Posteriormente el espacio tridimensional se convierte en una estructura de datos conocida como rejilla tridimensional. **Figura 2.2**

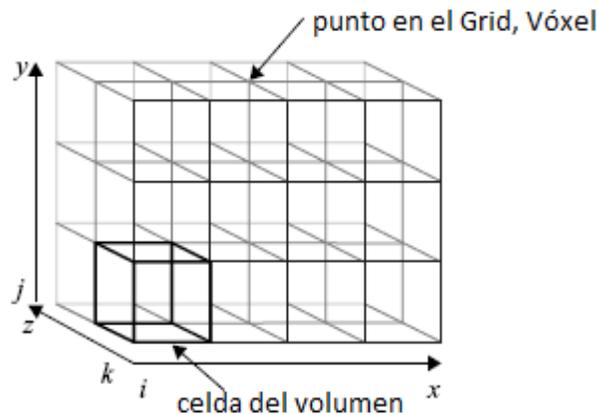


Figura 2.2. Representación de una rejilla Tridimensional. (Grid 3D).

Cada uno de los elementos de este volumen (o vóxeles) se considera de valor constante, asociado a algún atributo medible del objeto real, dependiendo de la modalidad de imagen considerada. Por ejemplo, en el caso de una CT representa el valor de atenuación de rayos X debido a los materiales presentes en el volumen, mientras que en una MRI se asocia a características de densidad y movilidad de protones.

2.1.2 Vecindad entre vóxeles.

La vecindad entre los vóxeles suele ser un elemento importante en el algoritmo Voxel Growing, ya que uno de los aspectos interesantes de esta técnica es que las regiones crecen a través de la incorporación de los vecinos de los vóxeles ya incluidos, por lo que se asegura la conectividad entre los elementos de la región segmentada. Algunos de los criterios de crecimiento de regiones vienen dados por la vecindad de 6, 18 y 26 vecinos **Figura 2.3**, para evaluar si pertenecen a la región.

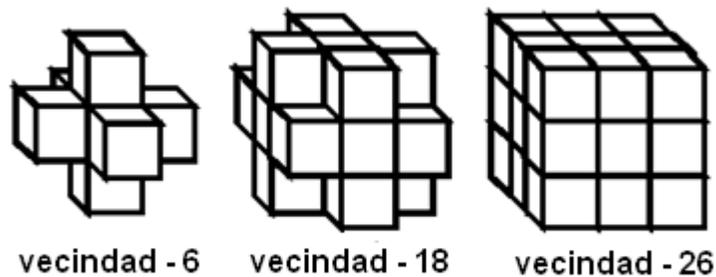


Figura 2.3 Vecindad de vóxeles.

Mientras mayor sea el criterio de vecindad mejor va ser la región segmentada, ya que de esta forma se analizaran vóxeles que según otro criterio de vecindad pueden quedar como fronteras sin ser analizados previamente, puesto que el vecino que comparte cara con el no pertenece a la región que se iba creciendo. Para evitar estos problemas se toma el criterio de vecindad de 26 para que se analicen los vóxeles más cercanos a la semilla, para otros casos como puede ser los vecinos de los vecinos de la semilla se recomendaría una máscara cubica, y así se puedan analizar todos los vóxeles y no suceda lo anteriormente mencionado.

2.1.3 Distancia entre vóxeles.

Si la distancia entre píxeles es idéntica a la distancia entre cortes, entonces se dirá que el grid obtenido es un grid isotrópico; si no es este el caso, entonces se trata de un grid anisotrópico. A causa de las características físicas de los equipos de captura, la distancia entre los sucesivos cortes suele ser mayor que la distancia entre las muestras dentro de cada capa, produciendo una imagen 3D de resolución anisotrópica. Esta situación implica que se debe considerar el tratamiento de vóxeles de tamaño arbitrario durante el proceso de segmentación y aún durante la visualización. Sin embargo, las imágenes generadas de este modo presentan un efecto de *jagging* (efecto de escalonamiento) bastante notorio, especialmente cuando poseen una cantidad reducida de cortes **Figura 2.4.a**. Otra opción de tratamiento de la imagen consiste en la generación de capas intermedias, calculadas por interpolación de la información provista por los cortes originales contiguos **Figura 2.4.b**. De esta manera, es posible mantener la relación de aspecto del objeto original y además se logra reducir notoriamente el efecto mencionado anteriormente. Pero no se recomienda ya que la interpolación es una aproximación de la realidad, por lo que se pueden generar estructura desde el punto de vista biológico erróneo. Algunos autores plantean que es preferible

contar con el efecto de escalonamiento que realizar una interpolación; ya que cuando los especialistas médicos están en presencia de este efecto, están consiente que durante el diagnóstico se omitieron cortes intermedios que pudieran ser de interés en el diagnostico. Sin embargo, al aplicar la interpolación esto elimina el efecto y pudiera traer análisis erróneos. Podemos plantear que es por ello que en ocasiones es preferible realizar cortes menos con distancias menores a un milímetro aunque el paciente reciba mayor cantidad de radiación.

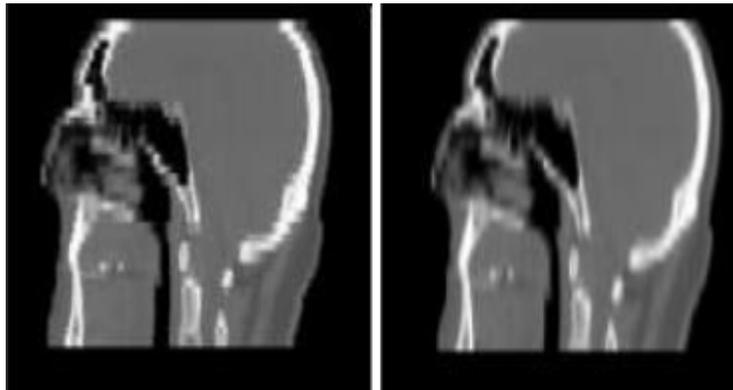


Figura 2.4: Construcción del modelo 3D de una CT: (a) Considerando vóxeles de tamaño irregular según la distancia entre capas, (b) Vóxeles cúbicos por interpolación de capas.

2.2 Procesamiento de imágenes médicas 3D.

El marco teórico estudiado nos permitió validar, comprobar y seleccionar las técnicas dentro del área del conocimiento del procesamiento de imágenes (filtrado y segmentación) que se ajustaban más al problema de la segmentación de imágenes médicas.

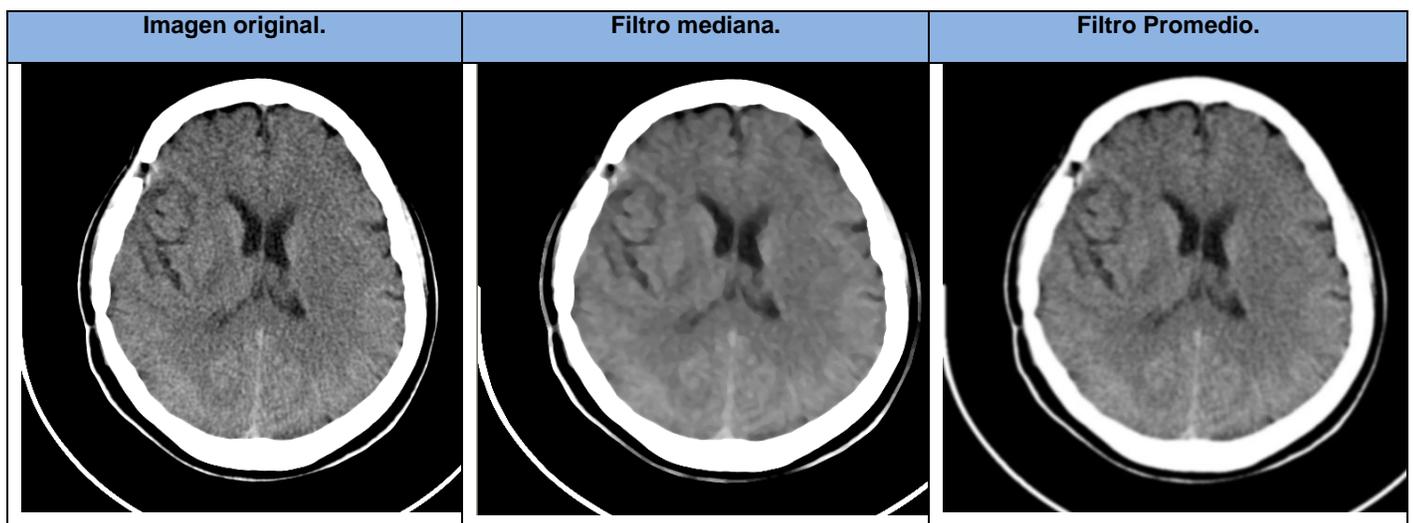
Este estudio se realizó desde una perspectiva bidimensional, lo cual se había identificado como una limitante; puesto que en el momento de realizar la unión de los resultados obtenidos de segmentar dos imágenes independientes podrían apareces incongruencias. Por lo que en este epígrafe explicaremos nuestros algoritmos basados en los principios y conceptos básicos del análisis de imágenes medicas digitales pero desde una perspectiva tridimensional; lo cual constituye unos de los principales aportes de esta investigación.

El procesamiento de las imágenes médicas es fundamental ya las imágenes DICOM contienen ruido que afectan de cierto modo la calidad visual de las mismas. Por lo que cuando se genera el grid 3D este volumen de información no se ve con la calidad requerida. Para mejorar la calidad visual de la misma es necesario realizar este proceso sobre el grid 3D utilizando máscaras cubicas y así evitar el problema de correlación entre una imagen y su siguiente.

2.2.1 Filtros implementados 3D.

La primera etapa en el proceso del análisis de cualquier imagen es el de corrección de la misma a partir de modificaciones de las tonalidades de colores que de una buena calidad visual (criterio que como se enunció en epígrafes anteriores es bastante subjetivo y depende en gran medida del usuario final); por lo que existen gran cantidad de algoritmos que permiten de acuerdo con el tipo de segmentación que se aplicara realizar un preprocesamiento de la imagen con el objetivo de descartar información poco relevante dentro de la misma (ruido).

De los filtros estudiados los más adaptados a nuestros requerimientos iniciales fueron (mediana, promedio, máximo, mínimo y palaciano). De la implementación de los mismos se obtuvieron los siguientes resultados visuales. Poner Tabla.



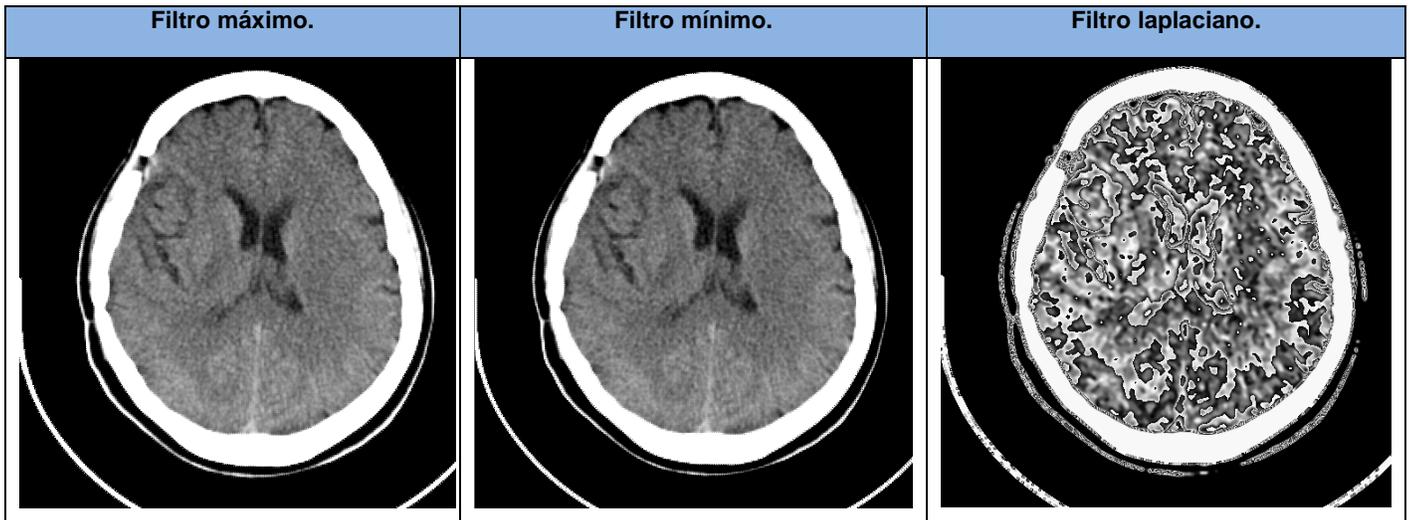


Tabla 2.1 Comparación de las técnicas de preprocesamiento de imágenes medicas.

Partiendo de estos resultados se seleccionó como mejor algoritmo el de la mediana 3x3, el cual, a medidas que aumenta el número de imágenes disminuye su rendimiento en tiempo de respuesta, pero mantiene la calidad de visualización en el grid de salida, puesto que no se ve afectada por vóxeles individuales ruidosos. Elimina una gran cantidad de ruido en las imágenes y homogeniza la misma, dándole un efecto de brillo-contraste. Esta técnica no empaña los bordes de las imágenes, es decir, no difumina los bordes de las mismas, siendo esta última una característica importante para el algoritmo implementado "Voxel Growing". Los filtros suavizadores con máscaras 5x5 presentan un rendimiento de respuesta mejor que el de mediana pero a pesar de que mejora la calidad visual de las imágenes difumina o desgasta los bordes de las estructuras anatómicas presente en el grid 3D

Además, se implementaron otros filtros de Gradiente (Sobel, Prewitt, Frei-Chen, Robert), los cuales dan como resultado una imagen de salida con los bordes de todas las estructuras anatómicas del volumen **Figura 2.5**, recomendándose el filtro Frei-Chen por sus resultados al delinear las estructuras anatómicas en estas series de imágenes.

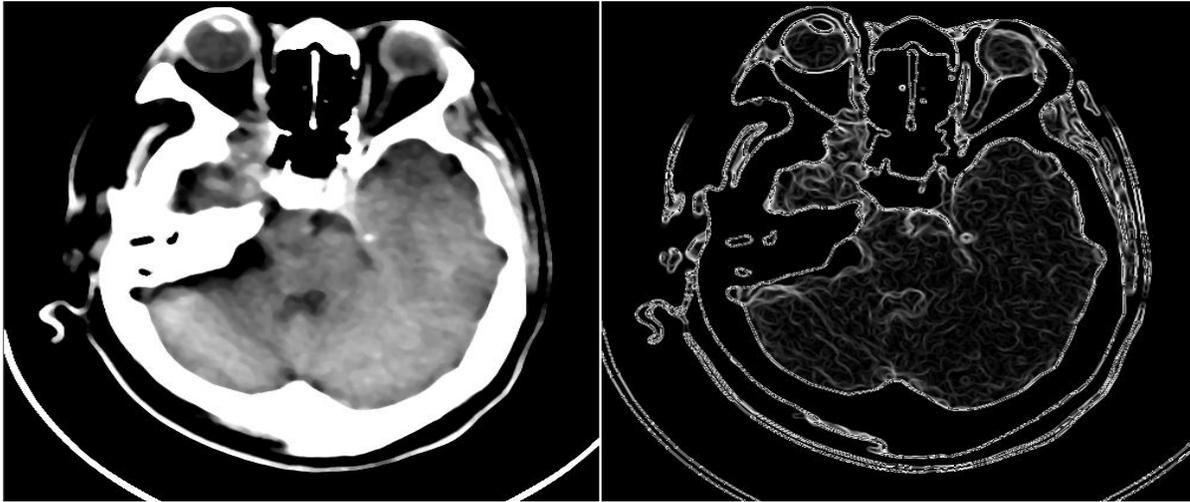


Figura 2.5 a) Imagen DICOM b) Imagen DICOM después de aplicado el filtro Frei-Chen.

2.3 Segmentación de imágenes 3D.

Una vez concluido el proceso de eliminación de ruido dentro de la imagen se procede a identificar las estructuras de interés para los médicos especialistas, siempre desde una perspectiva tridimensional. Evitando, de este modo, los problemas de correspondencia entre los resultados parciales que puedan aparecer en el momento de conformar el volumen segmentado a partir de la información obtenida en cada imagen o corte por separado. Este esquema resulta conveniente sobre todo en casos de componentes complejas, como por ejemplo en el caso de segmentación de estructuras como cráneo o cerebro, que al poseer numerosas circunvoluciones puede provocar que puntos que no han sido integrados a la región en alguno de los cortes, sí pueden resultar incluidos en los cortes contiguos.

2.4 Enfoque a la segmentación asistida.

El algoritmo de segmentación implementado depende de una semilla para posteriormente ejecutarse. Siendo este un enfoque de interés para el que este interactuando con la aplicación, ya que tiene la posibilidad de obtener lo que realmente él desea, separando esta región de interés de las demás estructuras anatómicas presentes en el grid 3D. Para esto en el entorno de visualización de imágenes provisto, el usuario puede especificar el punto de semilla por medio de la exploración interactiva de la imagen, sabiendo qué punto ciertamente pertenece a la región buscada. Con el fin de asistir al usuario en

este proceso, se brinda información adicional acerca de la posición, tonalidad y gradiente en cada punto en que el usuario se detenga durante la navegación a través del volumen **Figura 2.6**. Esta información puede servir de orientación para determinar la conveniencia de la selección.

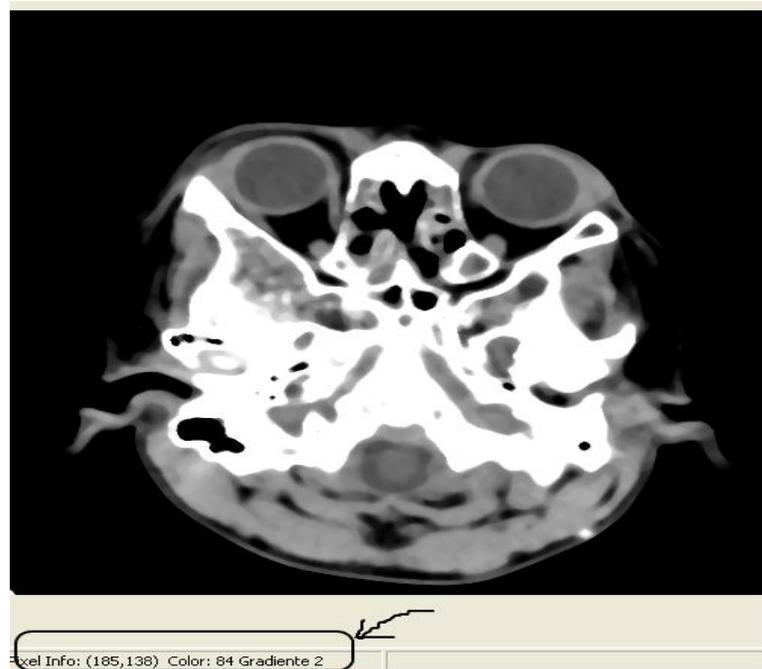


Figura 2.6 Muestra las coordenadas, umbral-color y umbral gradiente del píxel donde está señalando el cursor.

Por otra parte, se le permite al usuario reajustar el grid 3D segmentado de acuerdo con su criterio de aceptación, mostrándole en la parte inferior los valores de los umbrales con el cual fue segmentado el volumen, y en la parte superior se le brinda la posibilidad de poder cambiar estos valores a su conveniencia hasta que él esté de acuerdo con el resultado **Figura 2.7**. Además, se brinda la posibilidad de reiniciar el proceso a partir del grid original, ya que la aplicación no cuenta todavía con la funcionalidad de deshacer la última acción realizada evitándole así al usuario la tediosa tarea de volverlo a cargar.

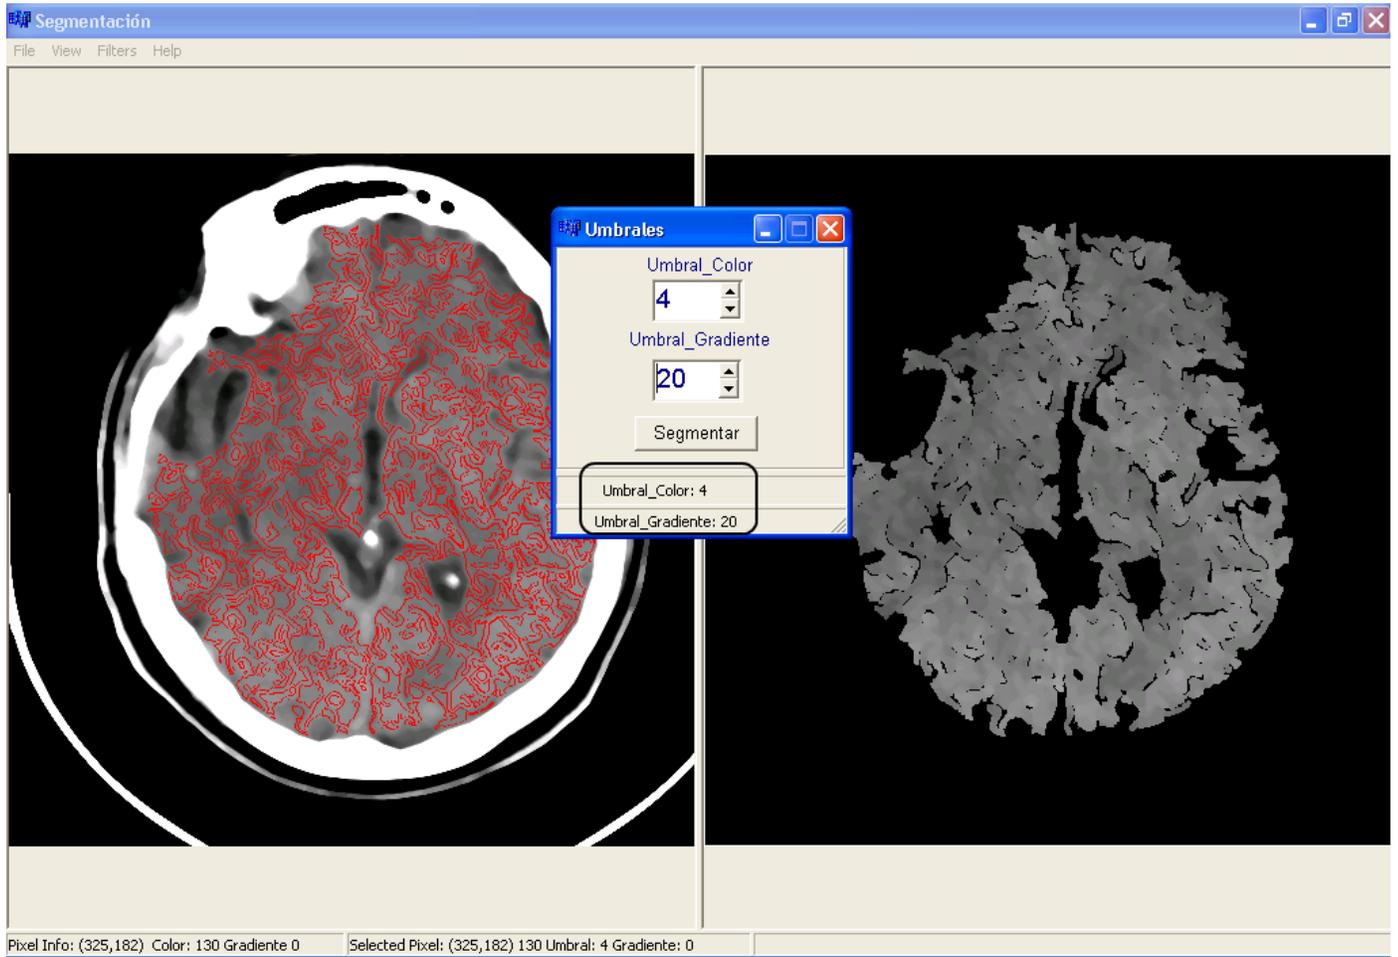


Figura 2.7 Reajuste de la segmentación.

Después de segmentada la región, al lado derecho aparece el grid 3D segmentado y del lado izquierdo el grid 3D original, en el cual se representa en color rojo los píxeles fronteras **Figura 2.8**. Para así darle una idea al médico o al especialista que está analizando este volumen de datos, de cuán bien fue segmentado la estructura anatómica de su interés.

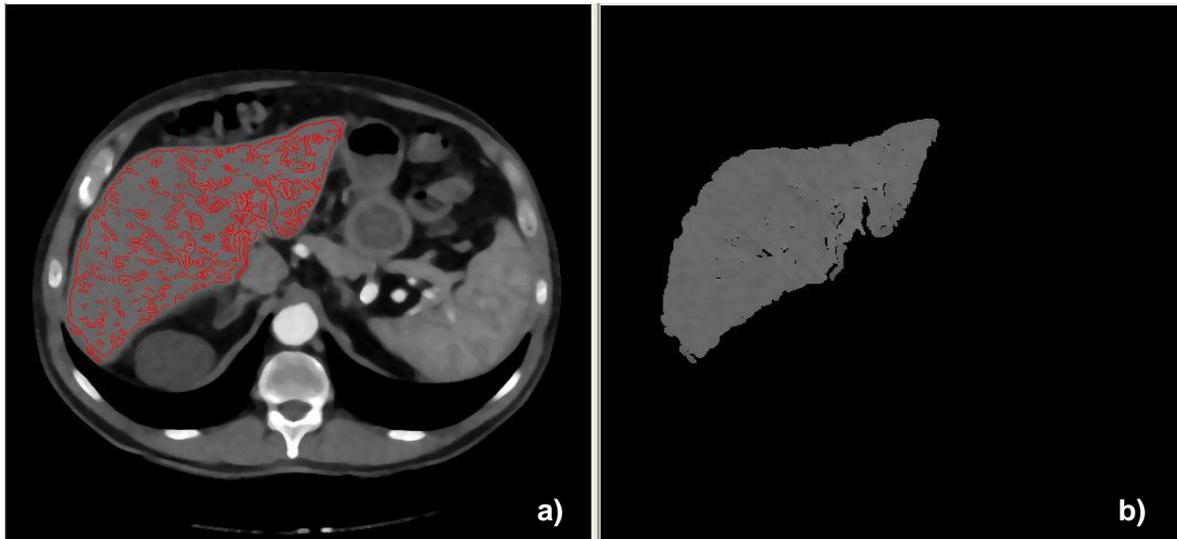


Figura 2.8 a) Imagen original resaltando los píxeles fronteros de la segmentación b) Imagen segmentada.

2.5 Crecimiento de regiones o Voxel Growing.

Luego que el usuario señale la región (R) la cual desea segmentar el algoritmo intenta crecer esa región, agregando este vóxel (v) a una cola de análisis. Mientras la cola no esté vacía se va a extraer el primer elemento de esta, verificando según el criterio de vecindad 26 **Figura 2.3**, si cumplen con la condición para ser aceptados y no han sido visitado anteriormente, se marca ese vóxel como visitado y se adiciona a la lista de regiones aceptadas y posteriormente se adicionan a la cola, de no cumplir con este criterio se adiciona a una lista de fronteras. Antes de que el algoritmo vuelva a iterar se pasan esos vóxeles que están como frontera a la lista de regiones aceptadas **Figura 2.9**.

```
Voxel VoxelGrowingColor(Region R)
{
  Insertamos a R la semilla en la cola C.
  Mientras ( La cola C no esté Vacía)
  {
    vóxel v = extraer el primer elemento de la cola
    Para cada elemento v' de v
    {
      Si (v' no ha sido visitado y
          satisface el criterio de aceptación)
      {
        Marcar a v' como visitado.
        Adicionar v; a la cola C.
      }
      Sino
        Marcar a v como frontera
    }
    Si (v es frontera )
      adicionar a la región Ri
  }
}
```

Figura 2.9 Seudocódigo del algoritmo Crecimiento de Regiones.

2.5.1 Especificación de semillas.

El punto de partida del algoritmo de segmentación consiste en la determinación de la semilla, la cual el usuario experto desea segmentar **Figura 2.10**. La determinación suele ser un aspecto crítico del algoritmo y se han propuesto diferentes métodos para esta etapa [19]. Por un lado, los métodos completamente automáticos pueden resultar imprácticos debido a que la complejidad y variabilidad de las imágenes tiende a limitar el alcance de su aplicabilidad. Por otro lado, la ubicación de los puntos iniciales sobre zonas ruidosas o correspondientes a bordes puede provocar una segmentación errónea de la imagen, la cual finalmente podrá requerir una etapa de corrección.

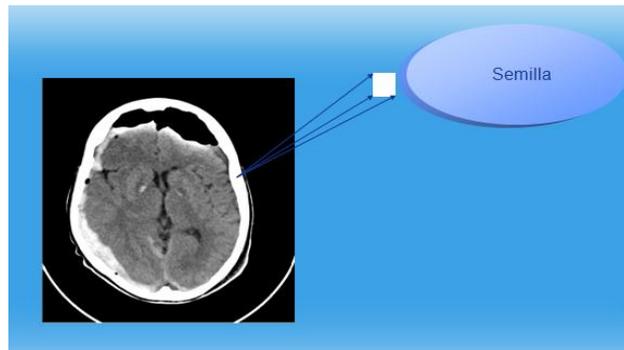


Figura. 2.10 Especificación de semilla.

2.5.2 Aceptación de vóxeles.

Hay diferentes formas de evaluar la pertenencia o no de un vóxel a una región. El criterio más simple considera la variación de intensidad del vóxel con respecto al valor de la semilla. También se puede tener en cuenta la diferencia de intensidad con el vóxel recientemente incorporado a la región o incluso la variación con respecto al entorno del vóxel siendo evaluado y criterio de gradiente para la incorporación de los vóxeles a la región. El algoritmo de crecimiento desarrollado provee las tres posibilidades:

- Crecimiento según semilla. Cada nuevo vóxel visitado se incorpora a la región correspondiente si la diferencia entre el valor del vóxel y el promedio de intensidades de las semillas especificadas para la región se encuentra dentro de cierto nivel de tolerancia. Debido a que sólo se controla la similitud de los vóxeles individuales, los puntos con ruido son excluidos de la región y por lo tanto puede requerirse posteriormente un post-procesamiento de la imagen segmentada con el fin de completar la integración de tales puntos por similitud al entorno.

- $\text{valor}(v) - \text{valor}(s) \leq t$

- En este caso se considera que un vóxel pertenece a una región si la diferencia entre su intensidad y la del vecino anteriormente incorporado a la misma se encuentre dentro de la tolerancia especificada. Cuando el proceso de crecimiento se aproxima a los bordes de la región, la diferencia de intensidades comienza a aumentar, por lo tanto, este criterio ocasionará que el algoritmo se detenga en esa zona. Debido a que las intensidades van variando progresivamente, el

factor de tolerancia elegido es determinante para controlar la posibilidad de desborde del llenado sobre otros componentes contiguos.

- **$\text{valor}(v) - \text{valor}(v') \leq t$**

- Crecimiento por gradiente. La magnitud del gradiente en un punto es una medida de la variación de intensidades alrededor de ese punto [4, 7]. Esta alternativa de crecimiento utiliza este valor para establecer los límites de la región, ya que el proceso de llenado se detiene si el gradiente en un vóxel v supera el umbral dado. Entonces, la condición de aceptación de un vóxel en este caso es:

- **$\text{valor}(\text{gradiente}(v)) - \text{valor}(\text{gradiente}(v')) \leq t$**

- Criterio integrado. En este caso la información acerca de los bordes proveniente del mapa de gradientes de la imagen se incluye en la condición de aceptación junto con la evaluación del contraste entre las intensidades del entorno del vóxel analizado y el promedio de las intensidades de las semillas, para controlar el crecimiento de la región. La integración de ambos criterios asegura la detención del llenado sobre zonas de transición entre componentes, controlando el problema de sobre-segmentación. Con el fin de relajar la exigencia de similitud de todo el entorno, la cual torna al criterio demasiado estricto y puede generar huecos dentro de la región segmentada, se ha considerado la similitud de un porcentaje de vóxeles dentro del entorno. Esta estrategia brinda mayor flexibilidad que el caso anterior, a la vez limita las oportunidades de escape.

En general, los dos primeros criterios analizan sólo la información individual del vóxel, permitiendo una rápida evaluación de pertenencia, pero su simplicidad también puede provocar situaciones no deseables por lo que deben utilizarse en forma controlada. Todas las opciones obligan de alguna manera a que el algoritmo de crecimiento se detenga en zonas próximas a los bordes de la región; sin embargo, el crecimiento por gradiente en el punto o por evaluación del entorno ofrece un criterio más robusto, disminuyendo la posibilidad de desbordes hacia otras componentes, por lo que resultan opciones más convenientes.

A partir de los puntos iniciales definidos para cada región, el algoritmo de segmentación debe permitir que éstas crezcan por incorporación de otros vóxeles con propiedades similares. Entre las posibilidades analizadas, los mejores resultados se obtuvieron al considerar la información local sobre los valores de intensidad, para verificar la homogeneidad del punto analizado, y además tener en cuenta el valor del gradiente en tal punto, como medida de la variación de intensidades alrededor del mismo [20]. Este criterio integrado permite incorporar un vóxel a la región correspondiente si se cumplen dichas condiciones.

Finalmente, la opción que ha ofrecido los mejores resultados consiste en la integración del criterio de evaluación del entorno y la información sobre el valor del gradiente en el punto analizado. Enfoques similares a este se han utilizado también en otros trabajos [21], aunque en la solución propuesta la evaluación del contraste se efectúa con respecto a la media de intensidades de los puntos semilla, sin requerir re-actualizaciones ante cada operación de inserción.

2.5.3 Incorporación de vóxeles guiada por conocimiento.

Uno de los aspectos interesantes de esta técnica es que las regiones crecen a través de la incorporación de los vecinos de los vóxeles ya incluidos, por lo que se asegura la conectividad entre los elementos de la región segmentada. **Figura 2.11.**

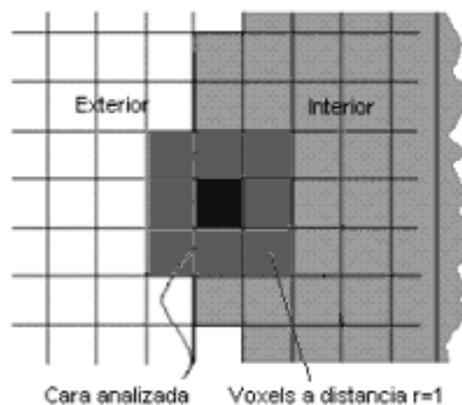


Figura 2.11 Esquema de Crecimiento.

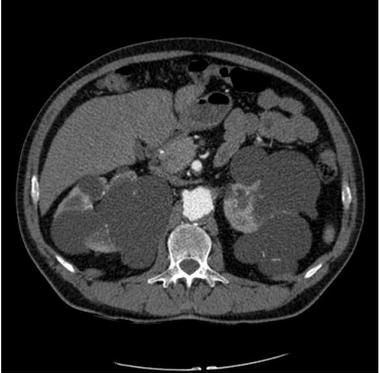
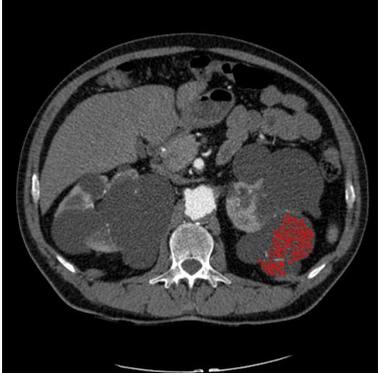
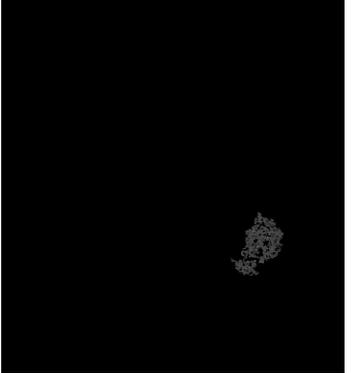
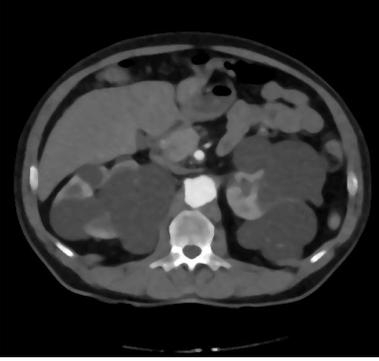
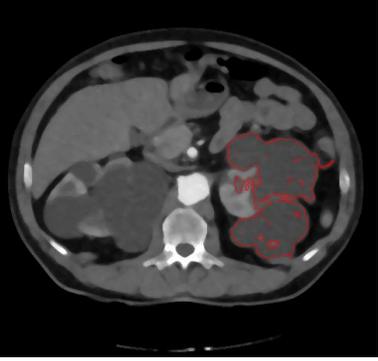
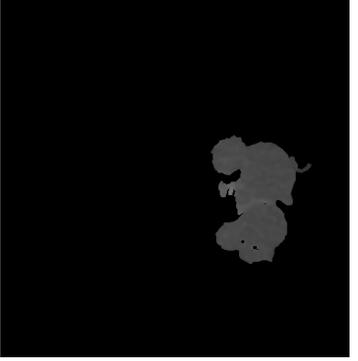
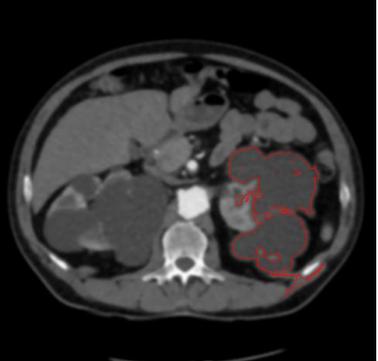
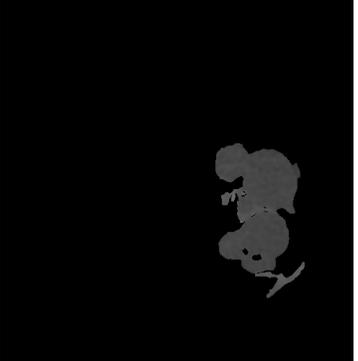
La salida del algoritmo consiste de una estructura de iguales dimensiones que el volumen original, en el cual aparecen rotuladas las distintas componentes correspondientes a las regiones detectadas. Esta

información se tiene en cuenta además durante la etapa de visualización del volumen segmentado. En la estructura de salida puede haber desbordes o simplemente la región segmentada puede no cubrir el volumen de datos que el especialista desea. Para esto el algoritmo implementado tiene la funcionalidad de segmentar a través de un umbral de color de 4 y un umbral de gradiente de 20 que según lo estudiado previamente da buenos resultados, si el médico o especialista que este analizando este grid 3D no le gusta la región segmentada y desea cambiar estos umbrales para agrandar o disminuir la región del grid 3D segmentado puede hacerlo cambiando estos umbrales.

2.6 Análisis, comparación y valoración de los resultados.

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

Los resultados de la siguiente tabla se recomienda para una buena segmentación aplicando el algoritmo de crecimiento de regiones utilizar el algoritmo de filtrado por mediana, ya que este al ser aplicado varias veces mejora la calidad en las imágenes sin difuminar los contornos de las estructuras anatómicas quedando homogenizadas las mismas, lo que nos permite aplicar el algoritmo Voxel Growing obteniendo resultados muy cercanos a lo que desean los especialistas.

Filtro	Imagen Procesada	Resultado de la Segmentación	
Imagen original			
Mediana			
Promedio			

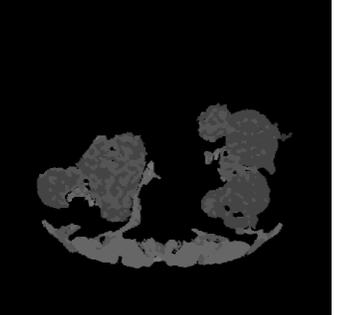
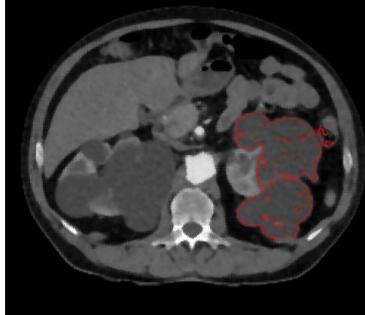
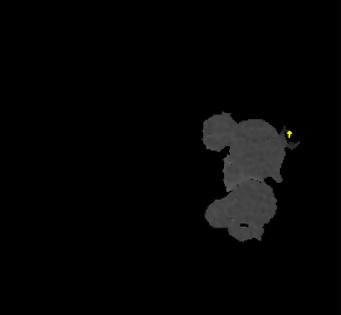
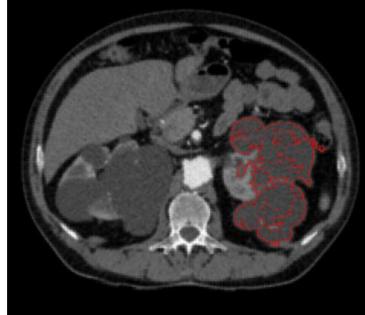
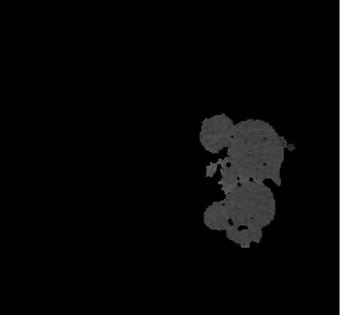
Máximo con Mediana			
Mínimo con Mediana			
Mínimo con Promedio			

Tabla 2.2 Comparación al aplicar filtro con resultado de la segmentación.

CAPÍTULO 3: ANÁLISIS Y DISEÑO DEL SISTEMA.

En este capítulo se hará una descripción de la solución propuesta en el capítulo anterior. Se definen las reglas del negocio, como vía para establecer las condiciones necesarias para el correcto funcionamiento del módulo. Se analizarán los conceptos fundamentales en el área de interés mediante el modelo de dominio. Se describirán tanto los requisitos funcionales como los no funcionales. Se definirán los casos de uso del sistema y los actores que interactúan con el mismo. Se identificarán temas del análisis, como los diagramas de clases del análisis y los diagramas de colaboración. Luego del análisis, donde se tiene ya una idea de la solución, se realizará el diseño del módulo a través de los diagramas de clases del diseño y sus respectivos diagramas de secuencia.

3.1. Reglas del Negocio.

Las Reglas del Negocio describen con un nivel adecuado de detalle las políticas, normas, operaciones, definiciones y restricciones presentes en una organización, estas son de vital importancia para alcanzar los objetivos planteados.

3.2. Modelo de Dominio.

A continuación se muestra en la **Figura 3.1** una descripción del modelo de dominio, donde se pretende facilitar la comprensión del funcionamiento del mismo.

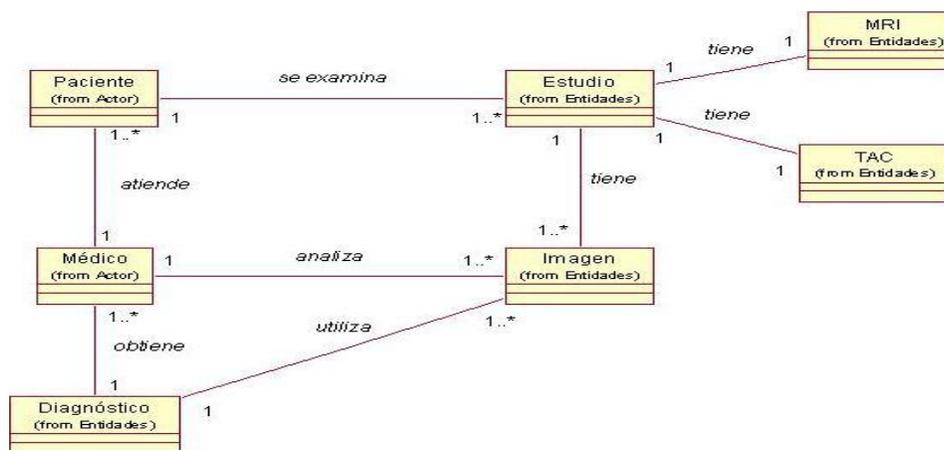


Figura 3.1 Modelo de Dominio.

3.2.1. Descripción del Modelo de Dominio.

Al paciente se le realizan una serie de estudios por parte de los médicos, lo cual puede ser a través de tomografías computarizadas (TAC) o resonancias magnéticas (RM). Estos estudios adquiridos están formados por un conjunto de imágenes que pueden estar orientadas en el plano sagital, coronal o el axial. El médico especialista analiza las imágenes a través de una herramienta de visualización para obtener un diagnóstico de paciente.

3.3. Captura de Requisitos.

Un requerimiento es una condición o capacidad que debe tener un sistema o un componente de un sistema para satisfacer los diversos requisitos de los inversores o contratistas, que pueden entrar en conflicto entre ellos, norma, especificación u otro documento formal, facilitando el entendimiento entre clientes y desarrolladores. A continuación se exponen los requisitos funcionales y no funcionales, por los cuales se va a regir el desarrollo del módulo.

3.3.1. Requisitos Funcionales.

Los requisitos funcionales definen el comportamiento interno del software: cálculos, detalles técnicos, manipulación de datos y otras funcionalidades específicas que muestran cómo los casos de uso serán llevados a la práctica. Son complementados por los requisitos no funcionales, que se enfocan en cambio en el diseño o la implementación. Los requisitos funcionales son capacidades o funciones que el sistema debe cumplir. A continuación se presentan los requerimientos del módulo a desarrollar.

R1. Cargar archivos.

El sistema debe permitir:

R1.1 Seleccionar el directorio donde se encuentran guardados los ficheros.

R1.2 Cargar archivos DICOM (*.DCM).

R2. Filtrar imágenes.

R2.1 Eliminar la mayor cantidad de ruido al grid 3D generado de forma automática.

R2.2 Eliminar ruido al grid 3D generado de forma semiautomática.

R2.3 Resaltar los contornos de forma semiautomática al grid 3D generado.

R2.4 Manipulación del Brillo y Contraste del grid 3D generado.

R3. Segmentar imágenes.

R3.1 Realizar el proceso de segmentación semiautomática hasta que el usuario experto obtenga los resultados deseados.

3.3.2. Requisitos No Funcionales.

Los requisitos no funcionales son propiedades o cualidades que el producto debe tener y representan las características que hacen al producto atractivo, usable, rápido o confiable. Seguidamente se enumeran los requisitos no funcionales del módulo a desarrollar.

1. De Software:

Sistema Operativo Linux o Windows XP.

2. De Hardware:

Tarjeta gráfica de 512 MB con soporte para textura 3D.

Procesador Pentium 4 a 3.0 GHz o superior.

Memoria RAM de 1GB de capacidad.

Espacio en disco duro de 512 Mb.

3. De Seguridad:

Confidencialidad: Los modelos 3D obtenidos en la visualización deben representar lo más real posible la anatomía humana.

Integridad: No se debe perder información del estudio inicial a la hora de generar la textura 3D y aplicarla para visualizar.

4. De Usabilidad:

Los usuarios deben tener un conocimiento básico sobre la visualización tridimensional aplicada a la medicina.

5. De Apariencia o interfaz externa:

La interfaz propuesta debe ser lo más atractiva y fácil de usar para el usuario final, implicando que todas las funcionalidades faciliten la interactividad en tiempo real.

6. De Soporte:

Soporte para los sistemas operativos Windows XP y versiones de Linux.

7. De Restricciones en el diseño e implementación:

Se utilizará el lenguaje de programación C++ utilizando el paradigma orientado a objetos.

8. Legales:

Se registrará por las normas ISO 9000.

3.4. Modelo de Casos de Uso del Sistema.

En esta sección se reconocen los actores del sistema, así como los casos de uso del módulo a desarrollar.

3.4.1. Actores del Sistema.

Los actores del sistema son agentes externos, que pueden cambiar información con él. Pueden representar el rol que juega una o varias personas, un equipo o sistema automatizado. En el caso particular quien interactuará con el módulo es un especialista médico, por lo que como actor del sistema se le llamará médico. En la tabla 3.1 se justifica la selección de este actor.

Actores	Justificación
Médico	El médico es quien interactúa con el sistema para ejecutar las funcionalidades de: cargar imágenes DICOM perteneciente a un estudio realizado a un paciente, visualizar el modelo 3D obtenido, mejorar la calidad visual, segmentar la estructura anatómica de su interés.

Tabla 3.1 Actor del Sistema.

3.4.2. Diagrama de Casos de Uso del Sistema.

El diagrama de casos de uso del sistema representa una técnica para la captura de requisitos potenciales de un nuevo sistema o una actualización de software. Cada caso de uso proporciona uno o más escenarios que indican cómo debería interactuar el sistema con el usuario o con otro sistema para conseguir un objetivo específico. En la **Figura 3.2** se muestra el diagrama de casos de uso del sistema para el módulo en cuestión [22].

Caso de Uso:	Pre-Procesar imágenes DICOM.
Actor:	Médico
Propósito:	Mejorar la calidad de las imágenes DICOM.
Resumen:	El caso de uso se inicia una vez que se haya seleccionado el estudio a cargar, donde se interactúa con una interfaz, la cual es la encargada de cargar las imágenes y proveer el grid 3D, el



Figura 3.2 Diagrama de

Casos de Uso del Sistema Segmentar Imágenes.

3.4.3. Descripción de casos de Uso del Sistema.

Cada caso de uso tiene una descripción de las funcionalidades que ejecutará el sistema propuesto como respuesta a las acciones del usuario. Las tablas presentadas a continuación argumentan los flujos operacionales del caso de uso Visualizar Modelo 3D. La descripción del caso de uso Cargar Fichero, así como los diagramas de secuencia y clases correspondientes al mismo se encuentran en el Trabajo de Diploma Reconstrucción Tridimensional de Modelos Anatómicos a partir de Imágenes Médicas Digitales [23]. Con el caso de uso Cargar Fichero se le da solución a los requisitos funcionales R1.1 y R1.2.

	cual es utilizado para generar el modelo 3D. Luego se visualiza el mismo. El usuario puede filtrar el grid 3D si así lo desea para obtener mejoras en las imágenes.
Referencia:	R1.1, R1.2, R2.1, R2.2, R2.3, R2.4.
CU asociados:	
Precondiciones:	
Flujo Normal de Eventos	
Acción del Actor	Respuesta del Sistema
1. El médico selecciona la opción Cargar imágenes.	1.1 Muestra un cuadro de diálogo donde el médico podrá seleccionar el directorio y las imágenes que desea cargar.
2. El médico selecciona las imágenes que desea cargar y oprime el botón aceptar.	2.1 Cierra el cuadro de diálogo y procede a cargar las imágenes seleccionadas. 2.2 Interactúa con la Interfaz Cargar Fichero para cargar las imágenes y generar el grid 3D. 2.3 El sistema aplica un filtro al grid 3D para mejorar la calidad de las imágenes. 2.4 Visualiza el modelo 3D con el filtro automático aplicado.
3. El médico puede seleccionar las opciones de filtrado para el mejoramiento de imágenes o para filtrado de contornos.	3.1. El sistema ejecuta una de las acciones siguientes: <ul style="list-style-type: none"> • Si el médico selecciona utilizar el filtrado para el mejoramiento de imágenes, consultar la sección filtrado para el mejoramiento de imágenes. • Si el médico selecciona utilizar el filtrado de contornos, consultar la sección filtrado de

	contornos.
Flujos Alternos	
Acción del Actor	Respuesta del Sistema
2. El médico selecciona las imágenes que desea cargar y oprime el botón aceptar.	2.1 Si no han sido seleccionadas las imágenes a cargar, muestra " Seleccione las imágenes a cargar". Como un mensaje de error.
Poscondiciones:	Se filtra para mejorar las imágenes o se filtra para obtener contornos.
Prioridad:	Crítico
Sección:	Filtrado para el mejoramiento de imágenes.
Flujo Normal de Eventos	
Acción del Actor	Respuesta del Sistema
1. El médico selecciona el filtrado para el mejoramiento de imágenes.	1.1 Muestra un formulario con los filtros disponibles.
2. El médico selecciona el filtro a utilizar.	2.1. Visualiza el modelo 3D después de ser aplicado el filtro seleccionado.
Flujos Alternos	
Acción del Actor	Respuesta del Sistema
Poscondiciones:	Se visualizará en pantalla el modelo 3D generado.
Prioridad:	Crítico
Sección:	Filtrado de contornos.
Flujo Normal de Eventos	

Acción del Actor		Respuesta del Sistema
3. El médico selecciona la opción filtrado para el mejoramiento de imágenes.		1.2 Muestra un formulario con los filtros disponibles.
4. El médico selecciona el filtro a utilizar.		2.1. Visualiza el modelo 3D después de ser aplicado el filtro seleccionado.
Flujos Alternos		
Acción del Actor		Respuesta del Sistema
Poscondiciones:	Se visualizará en pantalla el modelo 3D generado.	
Prioridad:	Crítico	

Caso de Uso:	Segmentar imágenes DICOM.
Actor:	Médico
Propósito:	Resaltar características anatómicas del grid 3D de imágenes analizadas.
Resumen:	El caso de uso se inicia una vez que se haya seleccionado el estudio a cargar, donde se interactúa con una interfaz, la cual es la encargada de cargar las imágenes y proveer el grid 3D al que se le aplica un filtro automático para generar el modelo 3D. El usuario puede seleccionar con un clic la estructura anatómica a segmentar y el sistema le mostraría un grid 3D con la estructura segmentada.
Referencia:	R1.1, R1.2, R3.1, CU_Cargar Fichero, CU_ Pre-Procesar imágenes DICOM.
CU asociados:	
Precondiciones:	
Flujo Normal de Eventos	

Acción del Actor		Respuesta del Sistema
1. El médico da clic sobre la estructura anatómica de interés.		1.2 Muestra el grid 3D resaltando la estructura seleccionada.
Poscondiciones:	Se visualiza la estructura seleccionada dentro del modelo 3D.	
Prioridad:	Crítico	

3.5. Diagrama de Clases de Análisis.

Un **diagrama del Análisis** es un diagrama de actividad simplificado, que se usa para capturar procesos del negocio del alto nivel y modelos tempranos del comportamiento y de los elementos del sistema. Es menos formal que algunos otros diagramas, pero proporciona buenos medios de capturar las características y las necesidades esenciales del negocio [22].

Los diagramas del análisis están compuestos por clases entidad, interfaz y control. Las clases de interfaz es la encargada de modelar la interacción entre el sistema y sus actores. Las clases entidad modelan información que posee una larga vida y que a menudo es persistente. Las clases de control coordinan el trabajo de uno o unos pocos casos de uso, coordinando las actividades de los objetos que implementan la funcionalidad del caso de uso, por lo que definen el flujo de control y las transacciones dentro de un caso de uso delegando el trabajo a otros objetos

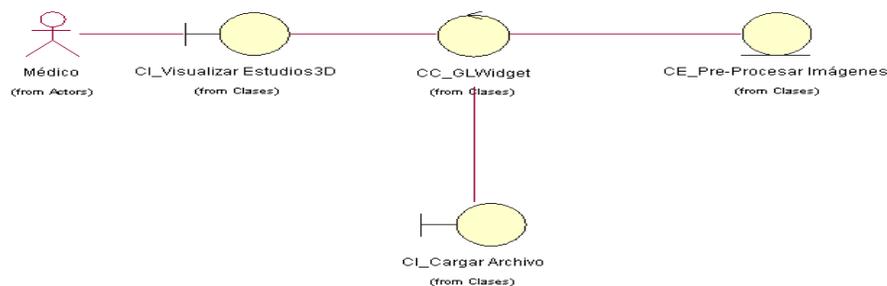


Figura 3.4 Diagrama de Clases del Análisis CU_Pre-Procesar Imágenes.

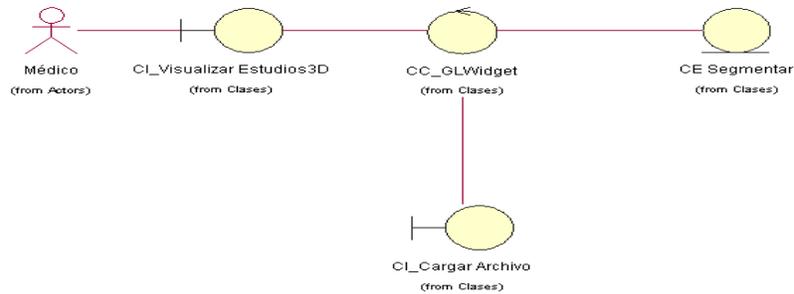


Figura 3.5 Diagrama de Clases del Análisis CU_Segmentar Imágenes.

3.6. Diagramas de Colaboración.

Un **Diagrama de Colaboración** muestra una interacción organizada basándose en los objetos que toman parte en la interacción y los enlaces entre los mismos (en cuanto a la interacción se refiere). A diferencia de los Diagramas de Secuencia, los Diagramas de Colaboración muestran las relaciones entre los roles de los objetos. La secuencia de los mensajes y los flujos de ejecución concurrentes deben determinarse explícitamente mediante números de secuencia [22].

Diagrama de Colaboración del Caso de Uso Pre-Procesar imágenes.

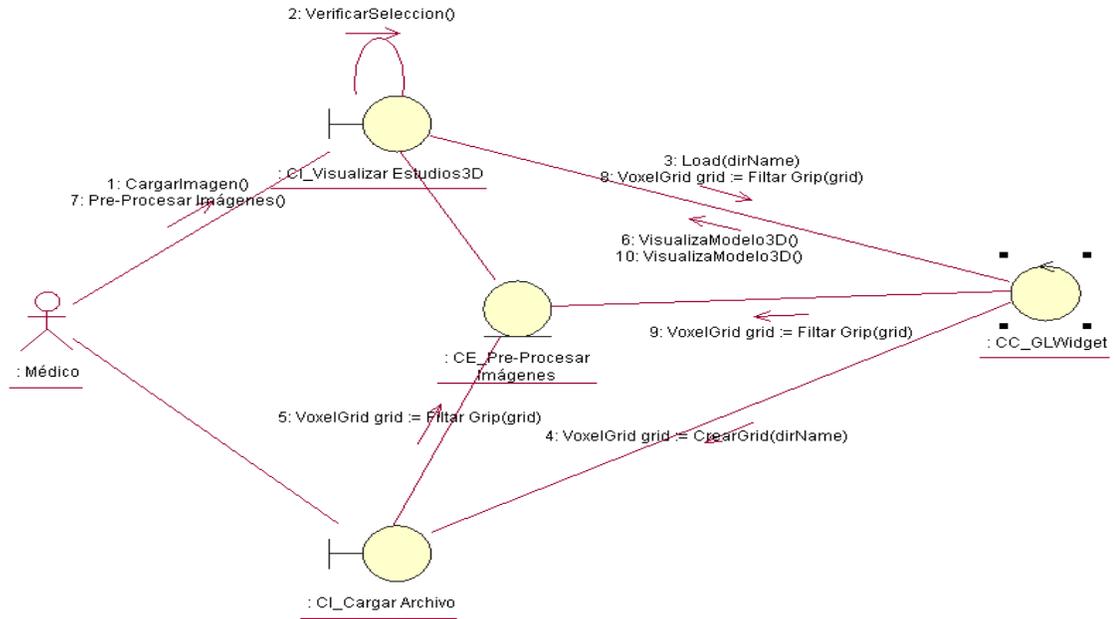


Figura 3.6 Diagrama de Colaboración del caso de uso Pre-Procesar imágenes.

Diagrama de Colaboración del Caso de Segmentar Imágenes.

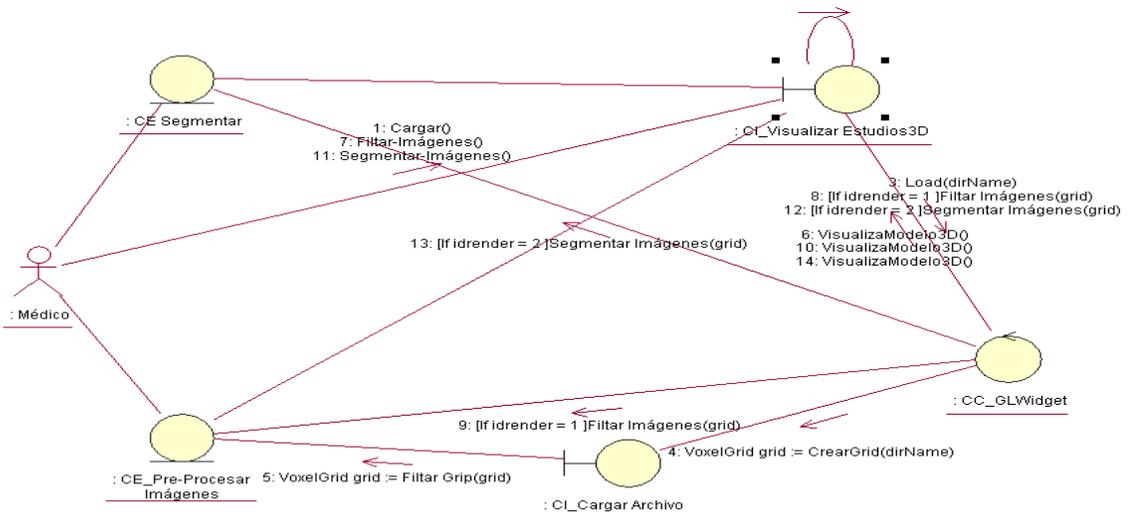


Figura 3.7 Diagrama de Colaboración del caso de uso Segmentar imágenes.

3.7. Diagramas de Secuencia del Diseño.

El **diagrama de secuencia** es uno de los diagramas más efectivos para modelar interacción entre objetos en un sistema. Un diagrama de secuencia muestra la interacción de un conjunto de objetos en una aplicación a través del tiempo y se modela para cada método de la clase. Para un mejor entendimiento de los diagramas de clases del diseño se han confeccionado los diagramas de secuencias por escenario de cada uno para lograr la automatización del sistema a implementar [22].

Diagrama de Secuencia del Diseño del Caso de Uso Pre-Procesar imágenes.

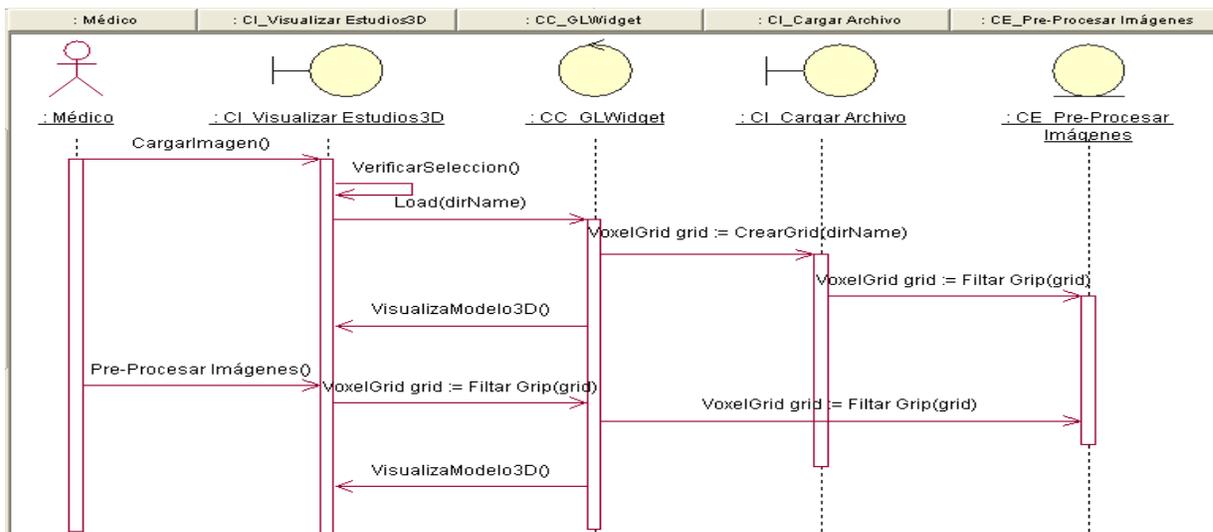


Figura 3.8 Diagrama de Secuencia del Diseño del Caso de Uso Pre-procesar Imágenes.

Diagrama de Secuencia del Diseño del Caso de Uso Pre-Procesar imágenes.

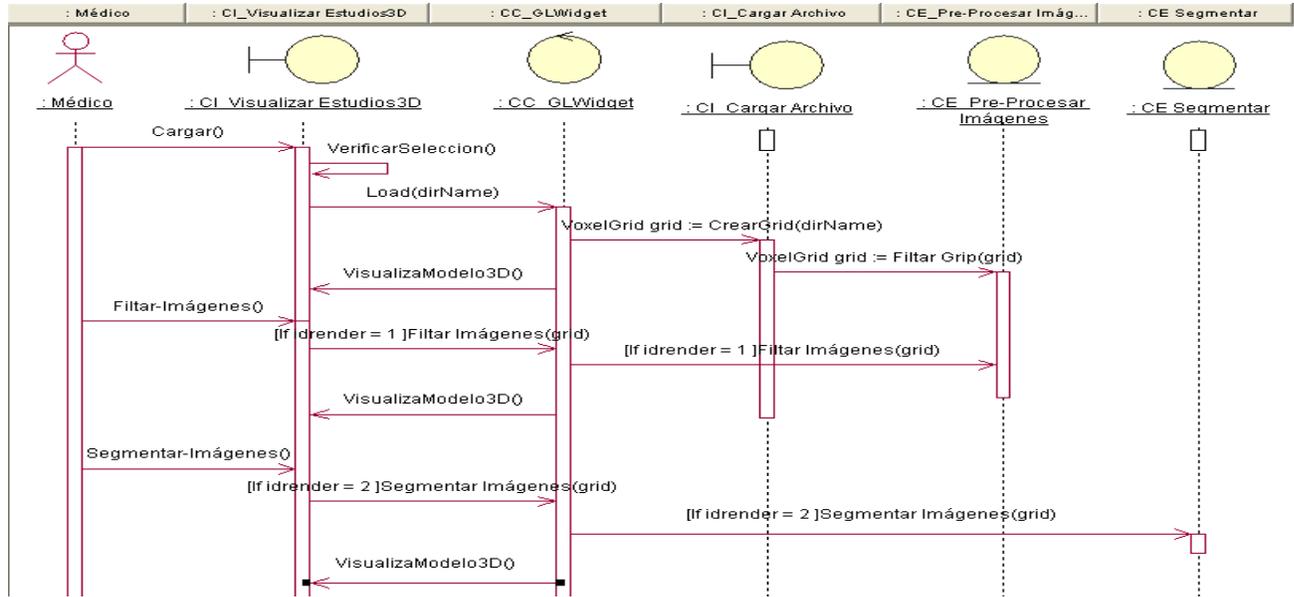


Figura 3.9 Diagrama de Secuencia del Diseño del Caso de Uso Segmentar Imágenes.

3.8. Diagrama de Clases del Diseño del Sistema.

Un **diagrama de clases** es un tipo de diagrama estático que describe la estructura de un sistema mostrando sus clases, atributos y las relaciones entre ellos. Los diagramas de clases son utilizados durante el proceso de análisis y diseño de los sistemas, donde se crea el diseño conceptual de la información que se manejará en el sistema, y los componentes que se encargaran del funcionamiento y la relación entre uno y otro [22].

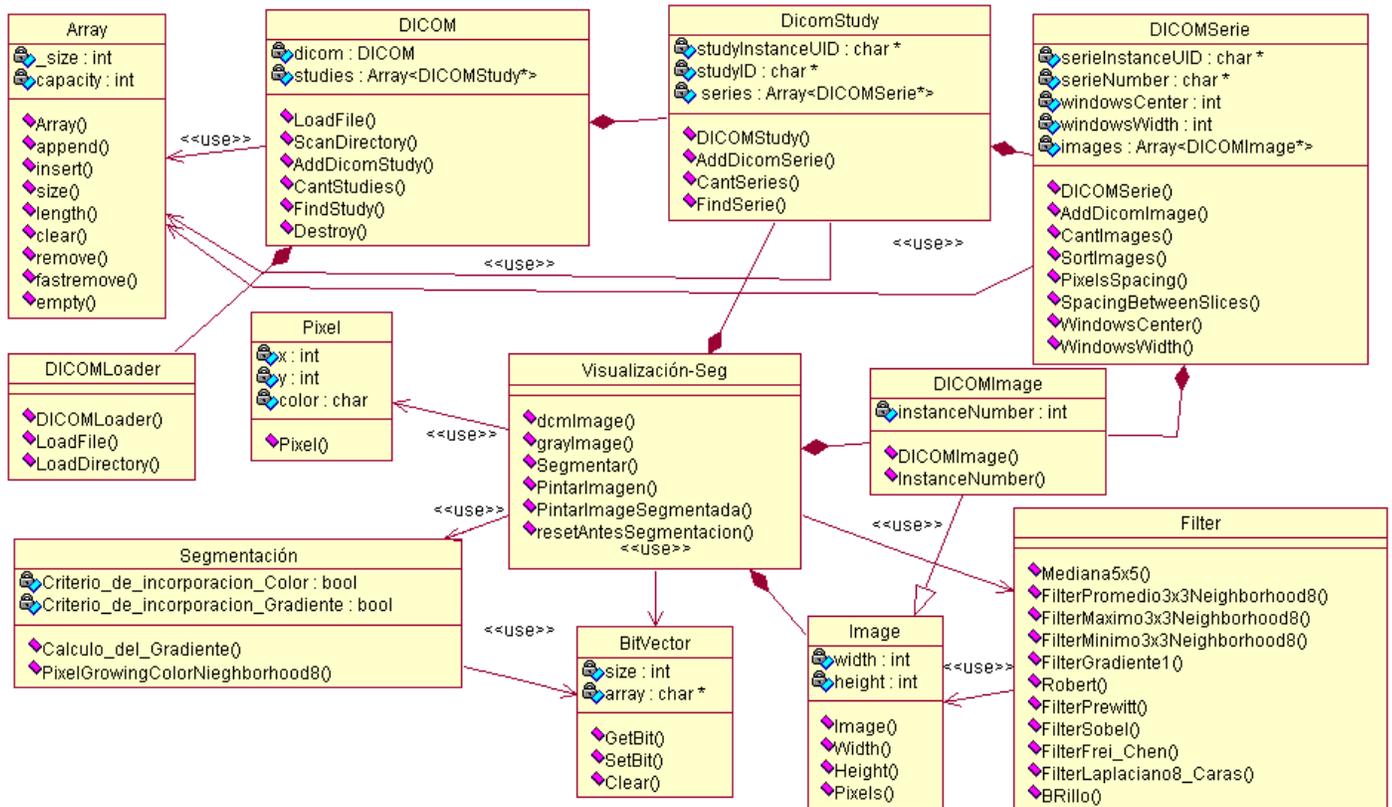


Figura 3.10 Diagrama de Clases del Diseño.

3.9 Diagramas de Componente.

Un **diagrama de componentes** es un diagrama tipo del Lenguaje Unificado de Modelado. Representa cómo un sistema de software es dividido en componentes y muestra las dependencias entre estos componentes. Los componentes físicos incluyen archivos, cabeceras, librerías compartidas, módulos, ejecutables, o paquetes. Los diagramas de Componentes prevalecen en el campo de la arquitectura de software pero pueden ser usados para modelar y documentar cualquier arquitectura de sistema. Uno de los usos principales es que puede servir para ver qué componentes pueden compartirse entre sistemas o entre diferentes partes de un sistema [22].

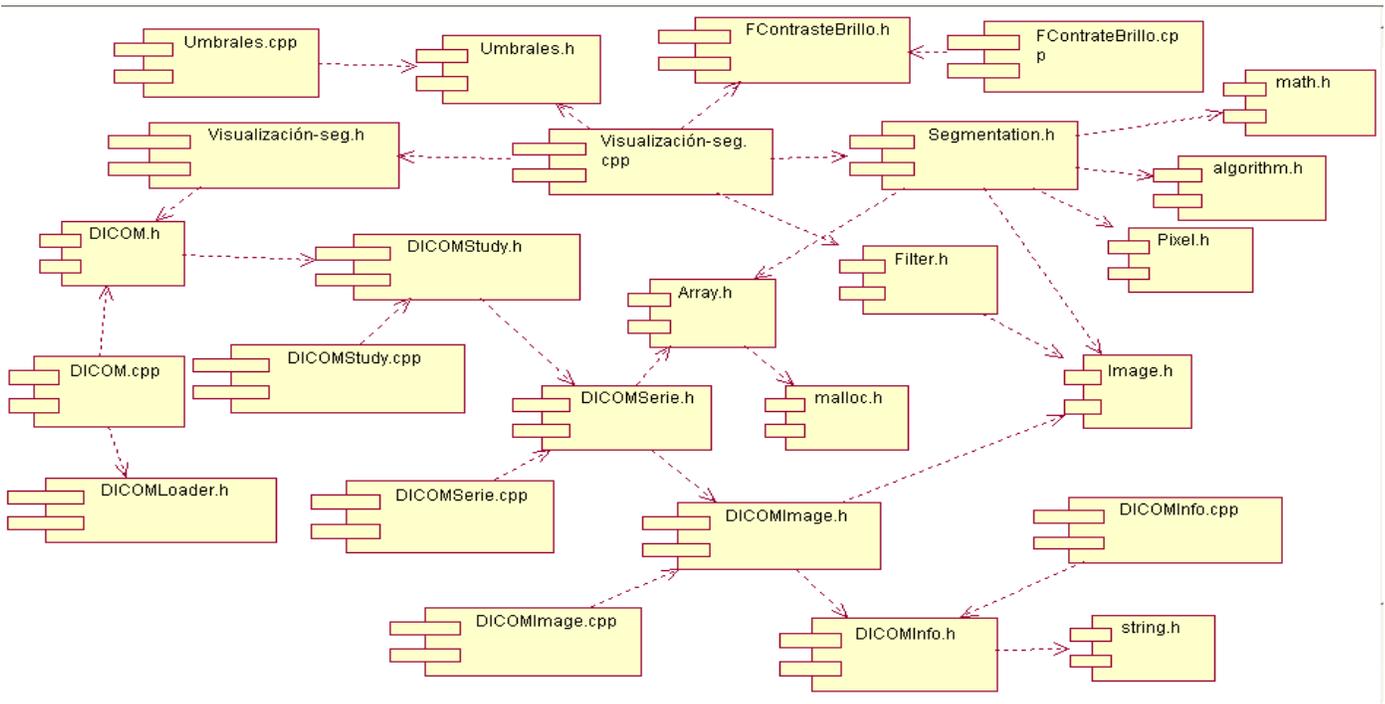


Figura 2.11 Diagrama de Componente.

CONCLUSIONES.

Con la realización de este trabajo se logró desarrollar un módulo que permite la segmentación de modelos anatómicos 3D, a partir de imágenes médicas digitales, facilitando una mejora en la calidad visual de las imágenes permitiéndole así a los especialistas un mejor entendimiento del volumen; utilizándose para ello las técnicas de filtrado de imágenes (Técnica de mediana) y de segmentación de imágenes (Crecimiento de regiones con información adicional), seleccionada a partir de un profundo estudio bibliográfico realizado. Lográndose de esta forma el cumplimiento de los objetivos planteados.

- Se demostró que los enfoques de segmentación bidimensionales presentan problemas de correspondencia en el momento de conformar la estructura anatómica tridimensional.
- Se atenuaron las deficiencias de las técnicas clásicas de segmentación de una sola imagen, al ser implementado una variante tridimensional para el filtrado por mediana y la segmentación utilizando el algoritmo "Voxel Growing".
- Se elaboró un módulo de segmentación de imágenes médicas tridimensionales de modalidades de TAC y RM que permitirá a los usuarios del software VISMEDIC identificar de forma semiautomática las estructuras anatómicas de interés.
- Se realizaron pruebas al módulo desarrollado para garantizar que su desempeño cumpla con los objetivos trazados.

De esta forma, quedó demostrado que el empleo de la técnica mediana en el preprocesado de las imágenes nos lleva a obtener buenos resultados en la segmentación de modelos anatómicos de neuroimágenes, a partir de imágenes DICOM.

RECOMENDACIONES.

El desarrollo de esta investigación abrió el camino a futuras investigaciones que pudieran de alguna forma complementar el resultado obtenido durante la investigación. Algunas de las cuales se enuncian a continuación en forma de recomendaciones:

- Optimizar el proceso de segmentación y preprocesamiento de Imágenes mediante el empleo de técnicas de programación GPGPU.
- Desarrollar y aplicar algoritmos y técnicas de posprocesamiento utilizando la morfología matemática al resultado de la segmentación.
- Permitir al usuario experto reajustar la región segmentada.

REFERENCIAS BIBLIOGRÁFICA.

- [1] **Bernhard Preim, Dirk Bartz.** *Visualization in medicine*, Burlington, Elsevier, 2007. Pág. 120
- [2] **Xu, Chenyang; Pham, Dzung L; Prince, Jerry L.** *Current Methods in Medical Image Segmentation. Annual Review of Biomedical Engineering, Annual Reviews*, vol. 2, pp. 315-337, Annual Reviews, Palo Alto, CA, 2000.
- [3] **David S. Klein, M.D.** Paín Center of Orlando, Inc. [Citado el: 20 de Octubre de 2010.] Disponible en: <http://diccionario.babylon.com/Neuroimagen>
- [4] **Revista chilena de Anatomía** [En línea] 1999. [Citado el: 20 de Octubre de 2010.] Disponible en: http://www.fsjd.org/cas/ic2_noticies.php?art_id=106&idioma=2
- [5] **Revista Cubana de Investigaciones Biomédicas.** [En línea] 2006 [Citado el: 20 de Octubre de 2010.] Disponible en: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0864-03002006000400003
- [6] **Cesar J. Acuña, Esperanza Marcos, Valeria de Castro, Juan A. Hernández, Marcos López Sanz.** *Gestión de Imágenes Médicas a Través de la Web.* [En línea] [Citado el: 20 de Octubre de 2010.] Disponible en: http://caribdis.unab.edu.co/pls/portal/docs/PAGE/REVISTACOLOMBIANACOMPUTO/RCC_ESPANOL/NUMEROSANTERIORES/JUNIO2007/R81_ART1_C.PDF
- [7] **TheAnalyze data format.** [En línea] 1 de septiembre de 2006. [Citado el: 20 de Octubre de 2008.] Disponible en: <http://imaging.mrc-cbu.cam.ac.uk/imaging/FormatAnalyze>
- [8] **NifTI: Neuroimaging Informatics Technology Initiative.** [En línea] 25 de Septiembre de 2007. [Citado el: 25 de Octubre de 2008.] Disponible en: <http://nifti.nimh.nih.gov/nifti-1>
- [9] **Rafael C. Gonzalez, Richard E. Woods.** *Digital Image Processing Second Edition* 2002, Chapter 3
- [10] **FISHER A., PERKINS S., WALKER A., WOLFART E.** *Gaussian Smoothing.*

<http://www.dai.ed.ac.uk/HIPR2/gsmooth.htm>:

[11] **Marcos Martín**, *Técnicas Clásicas de Segmentación de Imagen*, 2004.

[12] **N. A. Mat-Isa, M. Y. Mashor, and N. H. Othman**, *Seeded Region Growing Features Extraction Algorithm; Its Potential Use in Improving Screening for Cervical Cancer*.

[13] **Mariana del Fresno, Marcelo J. Vénere**. *Segmentación de imágenes médicas por crecimiento de regiones con conocimiento adicional 2002*

[14] **Besag, J.** *On the statistical analysis of dirty pictures. Journal Royal Statistical Society B*, vol. 48, num. 3, pp. 259–302. 1986.

[15] **Geman, S.; Geman, D.** *Stochastic relaxation, Gibbs distribution, and the Bayesian restoration of images. IEEE Transactions on Pattern Analysis and Machine Intelligence: vol. 6*, pp. 721–741. 1984.

[16] **Haykin, S.** *Neural networks: a comprehensive foundation*. Macmillan College, New York, 1994.

[17] **Bernd Jähne**, *Digital Image Processing, 6th edition*, 2005.

[18] **Rubén Medina, Jesús Bellera**, *Bases del Procesamiento de Imágenes Médicas*.

[19] **Scott T. Acton and Nilanjan Ray**, *Biomedical Image Analysis: Segmentation*, 2009.

[20] **K. Castleman**, *Digital Image Processing*, Prentice Hall, (1996).

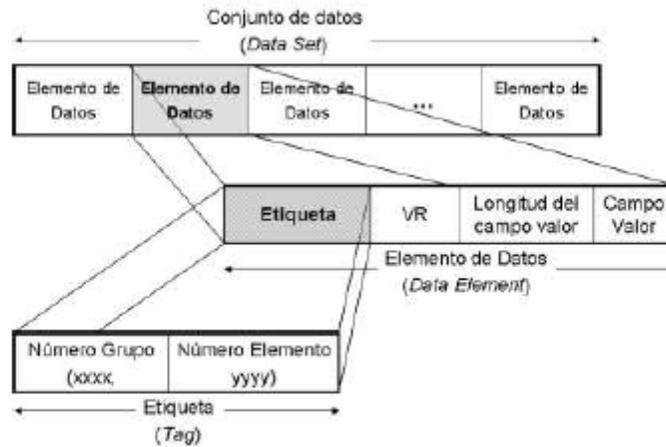
[21] **Zheng Lin, Jesse Jin, Hugues Talbot**, *Unseeded region growing for 3D image segmentation*.

[22] <http://www.sparxsystems.com.ar/download/ayuda/index.html?analysisdiagram.htm>

[23] **Pereira Barzaga, Osvaldo y Kindelan Nuñez, Rolando**. *Reconstrucción Tridimensional de Modelos Anatómicos a partir de Imágenes Médicas Digitales*. 2008.

ANEXOS.

Anexo 1: Estructura de los DataSet que forman la cabecera de un archivo DICOM.



GLOSARIO.

A

Algoritmo: Es una lista que, dado un estado inicial y una entrada, propone pasos sucesivos para arribar a un estado final obteniendo una solución.

B

Borde: En una imagen, es el lugar en el que coinciden dos formas. Por ejemplo, la unión del cielo con la tierra. La línea que separa dos formas, o una forma y un espacio.

C

Contorno: Conjunto de las líneas que limitan una figura o composición. Ver frontera.

CPU: Unidad de procesamiento central.

D

Diagnóstico: Etimológicamente el concepto diagnóstico proviene del griego, tiene dos raíces, dia- que es a través de, por. Y gignoskein que es conocer, así etimológicamente diagnóstico significa conocer a través de. El concepto de este significado es la identificación de la naturaleza o esencia de una situación o problema y de la causa posible o probable del mismo, es el análisis de la naturaleza de algo.

Digital: Quiere decir que utiliza o que contiene información convertida al código binario, el lenguaje de números (ceros y unos) que emplean los ordenadores para almacenar y manipular los datos.

E

Estándar: adj. Se dice de lo que sirve como tipo, modelo, norma, patrón o referencia por ser corriente.

F

Función de transferencia: Es un modelo matemático que a través de un cociente relaciona la respuesta de un sistema a una señal de entrada o excitación.

Frontera: Sinónimo de borde, límite.

G

GPU: Unidad de procesamiento gráfico.

Gradiente: Denota una dirección en el espacio según la cual se aprecia una variación de una determinada propiedad o magnitud física.

Grid 3D: Estructura para almacenar la información de las imágenes médicas contenidas en los estudios.

I

Imagen: Figura, representación, semejanza y apariencia de algo.

Invasivo: Que invade o tiene capacidad para invadir. Irrumpir, entrar por la fuerza. Ocupar anormal o irregularmente un lugar.

M

Metodología: Conjunto de métodos que se siguen en una investigación científica o en una exposición doctrinal.

Modelo 3D: Modelo tridimensional, real o virtual para representar un cuerpo o una parte del mismo.

Módulo: Pieza o conjunto unitario de piezas que se repiten en una construcción de cualquier tipo, para hacerla más fácil, regular y económica.

Módulo: Pieza o conjunto unitario de piezas que se repiten en una construcción de cualquier tipo, para hacerla más fácil, regular y económica.

O

Optimización: Acción y efecto de optimizar. Buscar la mejor manera de realizar una actividad.

P

Patología: Conjunto de síntomas de una enfermedad.

Píxel: Abreviatura de “pictureelement”. Es la mínima unidad de información dentro de una imagen bidimensional.

R

RAM: Es la memoria de acceso aleatorio (en inglés: *random-accessmemory*), desde donde el procesador recibe las instrucciones y guarda los resultados. Es el área de trabajo para la mayor parte del software de un computador.

Reconstrucción 3D: Es el proceso mediante el cual objetos reales son reproducidos en la memoria de un computador, manteniendo sus características físicas (dimensiones, volumen y forma).

Render: el proceso de convertir modelos geométricos 3D en escenas 2D para presentarlas a los usuarios.

Resolución: Es el número de píxeles que se muestran en una pantalla. Al ser ésta una matriz de filas y columnas de píxeles, primero se nombra la cantidad de columnas (resolución horizontal) y luego la cantidad de filas (resolución vertical).

Resonancia magnética (RM): La RM es una técnica de diagnóstico que posee la capacidad de generar finas secciones de modo no invasivo y proporciona imágenes estáticas y dinámicas de alta calidad de las estructuras internas de todo el cuerpo, desde cualquier ángulo y dirección. En su funcionamiento utiliza magnetos súperconductoras y ondas de radio-frecuencia para producir las imágenes, donde el análisis computarizado, de los cambios de energía de los tejidos cuando reaccionan a fuerzas magnéticas, crea una imagen compuesta de los tejidos. En la visualización 3D permite la visualización de las arterias y venas empleando la técnica denominada angiografía por resonancia magnética, la visualización del corazón con exquisito detalle anatómico empleando la técnica del trazado electro cardiográfico, el rastreo de componentes bioquímicos que corresponden a cualquier corte anatómico del cuerpo humano.

Es la técnica de diagnóstico de elección esencial para todos los procesos del cerebro y del sistema nervioso central.

S

Segmentación: Se utiliza en el Procesamiento de Imágenes para el reconocimiento de objetos o estructuras de interés en la imagen.

Shader: conjunto de instrucciones capaces de ser ejecutadas por un procesador gráfico.

Sagital: El plano sagital en anatomía es aquel plano perpendicular al suelo y paralelo al plano mediosagital, y que divide al cuerpo en mitades izquierda y derecha.

T

Tomografía: Técnica de registro gráfico de imágenes corporales, correspondiente a un plano predeterminado.

Tomografía Computarizada (TC): La TC es también conocida como Tomografía Axial Computada (TAC), es un método de diagnóstico que muestra imágenes bidimensionales de las estructuras internas del cuerpo de una persona sin el empleo de procedimientos invasivos. Esta técnica utiliza rayos-x para obtener vistas de cortes cruzados verticales y horizontales de zonas internas del cuerpo. Para aplicaciones de visualización 3D, es usada frecuentemente para la visualización de la estructura de los huesos además de algunos tejidos blandos.

Topología: Es el método matemático – lógico usado para definir las relaciones espaciales entre los objetos espaciales. Hace referencia a las propiedades de vecindad o adyacencia, inclusión, conectividad y orden, es decir, propiedades no métricas.

Tridimensional: adj. Se dice de lo que se desarrolla en las tres dimensiones espaciales, altura, anchura y profundidad.

U

Ultrasonidos: También conocido con ecografía, constituye una técnica de diagnóstico en la que un sonido de frecuencia muy alta es dirigido hacia el organismo, donde las interfaces

tisulares reflejan el sonido, y el patrón de reflexión del sonido resultante es digitalizado para producir una imagen móvil en una pantalla o una fotografía. Los ultrasonidos se utilizan para explorar el sistema arterial, el corazón, el páncreas, la cavidad peritoneal, el tracto urinario, los ovarios, el sistema venoso y la médula espinal. Su aplicación más conocida es la exploración del feto durante el embarazo. Cuando se utilizan para explorar el corazón, se denomina ecocardiografía. La ecocardiografía se emplea en el estudio de cardiopatías congénitas, enfermedades de las arterias coronarias, tumores del corazón y, de forma especial, para las alteraciones de las válvulas cardíacas. Los ultrasonidos son también útiles para guiar intervenciones quirúrgicas, por ejemplo durante la amniocentesis o para introducir una aguja de biopsia en una región determinada.

Unidimensional: Término utilizado para describir figuras que sólo se pueden medir en una dirección, o sea, que poseen una sola dimensión, como una línea, que sólo tiene longitud.

V

Vértices: Son los puntos en el espacio 3D que definen primitivas gráficas tales como triángulos, polígonos y rectángulos, usados para construir la geometría de la escena que será dibujada.

Vóxel: (del inglés: *volumetricpixel*) es la unidad cúbica que compone un objeto tridimensional. Constituye la unidad mínima procesable de una matriz tridimensional y es, por tanto, el equivalente del píxel en un objeto 2D.