

*Implementación de un Sistema para Definición
Automática de Contornos en Imágenes
Tomográficas con la Técnica Narrow Band*

Autores

Dairy Yineth Avila Rueda

Luis Felipe Torrado Soto



ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE
TELECOMUNICACIONES
UNIVERSIDAD INDUSTRIAL DE SANTANDER
BUCARAMANGA

2012

*Implementación de un Sistema para Definición
Automática de Contornos en Imágenes
Tomográficas con la Técnica Narrow Band*

Autores

Dairy Yineth Avila Rueda

Estudiante de Ingeniería Electrónica

Luis Felipe Torrado Soto

Estudiante de Ingeniería Eléctrica

Director

Daniel Alfonso Sierra Bueno
Ph.D. en Ingeniería Biomédica

Codirector

Carlos Andres Niño Niño
M.Sc. en Ingeniería Electrónica



ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE
TELECOMUNICACIONES
UNIVERSIDAD INDUSTRIAL DE SANTANDER
BUCARAMANGA

2012

AGRADECIMIENTOS

Al Ph.D en Bioingeniería, Daniel Sierra Bueno, Director de Proyecto, por su valiosa colaboración y orientación en el desarrollo de cada una de las etapas del proyecto.

A todos los profesores, quienes con su valiosa experiencia y conocimientos, contribuyeron en nuestro proceso de formación como profesionales.

A la UNIVERSIDAD INDUSTRIAL DE SANTANDER, por proporcionar las herramientas para alcanzar nuestras metas académicas y prepararnos para el siguiente paso de nuestras vidas.

A todos los compañeros del grupo de investigación por sus aportes y discusiones que ayudaron a contribuir con los conocimientos necesarios para llevar a cabo la investigación.

Índice general

1. Introducción	3
2. Marco Teórico	5
2.1. Imágenes formato DICOM	5
2.2. Tomografía Axial Computada	6
2.3. Segmentación	8
2.4. Métodos de conjuntos de nivel (<i>Level Sets</i>)	9
2.5. Métodos rápidos (conjuntos de nivel de banda angosta)	9
2.5.1. Velocidad	10
2.5.2. Paso de tiempo	10
3. Método conjuntos de nivel de banda angosta (<i>Narrow Band Level Sets</i>)	13
3.1. Formulación de energía del método conjuntos de nivel	14
3.2. Formulación del método conjuntos de nivel	14
3.3. Algoritmo de Conjuntos de Nivel de Banda Angosta	16
3.4. Esquema de diferencias finitas	17
4. Implementación	19
4.1. Descripción del algoritmo conjuntos de nivel de banda angosta	19
4.1.1. Selección de parámetros	20
4.1.2. Inicialización de la función conjuntos de nivel de banda angosta y establecimiento de la banda	21
4.1.3. Aplicación de la función conjuntos de nivel de banda angosta	23
5. Resultados experimentales	25
6. Proyección en 3D	34
6.1. Descripción del algoritmo de visualización en 3D	34

7. Conclusiones y Recomendaciones	37
7.1. Conclusiones	37
7.2. Recomendaciones	38

Índice de figuras

2.1. Ejemplo de imagen DICOM [1].	6
2.2. TAC de abdomen, en la cual se señala una masa tumoral en la cabeza del páncreas [2].	7
2.3. Ventrículo del cerebro en 2D vista axial de MRI. Comparación de diferentes métodos de segmentación de imágenes con el método conjuntos de nivel de banda angosta [3].	8
2.4. Ejemplo de conjuntos de nivel, la línea oscura corresponde al frente de nivel cero [4].	10
2.5. Ejemplo de conjuntos de nivel de banda angosta, los puntos cuadrículados en el área oscura son miembros de la banda angosta [4].	11
2.6. Representación unidimensional de la banda, los puntos interiores indican el arreglo y los puntos del límite la banda angosta [4].	11
3.1. Porción de una imagen etiquetada, definiendo la banda angosta, esta tiene píxeles etiquetados con los símbolos: $+$, $-$, \oplus , \ominus [4].	18
4.1. Diagrama de flujo del algoritmo conjuntos de nivel de banda angosta fuente: Autor.	19
4.2. Condición inicial para el delineamiento de la función conjuntos de nivel [5].	22
4.3. Interior y exterior de la banda angosta alrededor del conjunto de nivel cero [3].	23
4.4. Movimiento del contorno del nivel cero confinado en una banda angosta [3].	24
5.1. Segmentación de imágenes sencillas utilizando el método de conjuntos de nivel de banda angosta. Izquierda: Contorno inicial. Centro: Curva en evolución. Derecha: Segmentación finalizada fuente: Autor.	26
5.2. Ejemplo 1 de segmentación de imagen tipo DICOM utilizando el método de conjuntos de nivel de banda angosta fuente: Autor.	28
5.3. Ejemplo 2 de segmentación de imagen tipo DICOM utilizando el método de conjuntos de nivel de banda angosta fuente: Autor.	29

5.4.	Ejemplo 3 de segmentación de imagen tipo DICOM utilizando el método de conjuntos de nivel de banda angosta fuente: Autor.	30
5.5.	Comparación segmentación final de los dos métodos en imágenes sencillas fuente: Autor.	31
5.6.	Comparación segmentación final de los dos métodos en imágenes DICOM fuente: Autor.	33
6.1.	Diagrama de flujo del algoritmo Banda Angosta fuente: Autor.	35
6.2.	Imagen reconstrucción de la región segmentada fuente: Autor.	36

Índice de tablas

4.1. Rango de valores de los parámetros del algoritmo de conjuntos de nivel de banda angosta	21
5.1. Comparación en la rutina de los algoritmos - Ejemplos de segmentación en imágenes sencillas en 2D	27
5.2. Comparación en la rutina de los algoritmos - Ejemplo 1 de segmentación imagen DICOM en 2D	28
5.3. Comparación en la rutina de los algoritmos - Ejemplo 2 de segmentación imagen DICOM en 2D	29
5.4. Comparación en la rutina de los algoritmos - Ejemplo 3 de segmentación imagen DICOM en 2D	30

RESUMEN

TÍTULO: IMPLEMENTACIÓN DE UN SISTEMA PARA DEFINICIÓN AUTOMÁTICA DE CONTORNOS EN IMÁGENES TOMOGRÁFICAS CON LA TÉCNICA NARROW BAND ¹.

AUTORES: Dairy Yineth Avila Rueda
Luis Felipe Torrado Soto ²

PALABRAS CLAVES: Conjuntos de Nivel, Banda Angosta, Segmentación de Imágenes, Contornos Activos, reconstrucción tridimensional.

DESCRIPCIÓN:

La segmentación de imágenes médicas ha sido identificada como uno de los problemas clave en su análisis, llegando a ser un área activa de investigación. Por esta razón, se ha visto la necesidad de desarrollar y optimizar métodos de segmentación para incrementar fiabilidad en cuanto a su precisión y disminución del tiempo de procesamiento. Esto se debe a la cantidad de información a procesar y a la repercusión diagnóstica que se deriva de la exactitud de estos métodos en el procesamiento de imágenes médicas.

En este proyecto se desarrolla una aplicación de modelos deformables para obtener la segmentación de zonas de interés en imágenes sencillas y médicas. Este estudio está enfocado específicamente al método de conjuntos de nivel de banda angosta teniendo en cuenta sus características y ventajas sobre el método de conjuntos de nivel estándar. Se implementó un algoritmo para la aplicación del método a imágenes sencillas e imágenes médicas en varios formatos. Se validó el desempeño del algoritmo con imágenes sencillas y con otras imágenes médicas en formato DICOM. Se demostró la validez del método y la eficacia de su aplicación en imágenes sencillas y DICOM, incluso cuando las mismas no tienen bordes bien definidos.

A continuación, se presenta el proyecto de grado titulado: *Implementación de un Sistema para Definición Automática de Contornos en Imágenes Tomográficas con la Técnica Narrow Band*, en el cual trata la aplicación de un método para la segmentación de contornos en las zonas de interés de una imagen utilizando la técnica de conjuntos de nivel de banda angosta en 2D que es un método muy ágil en comparación con el método de conjuntos de nivel.

¹Proyecto de Investigación

²Facultad de FÍSICO-MECÁNICAS. Escuela de Ingeniería Eléctrica, Electrónica, y Telecomunicaciones. Director Daniel Alfonso Sierra Bueno. Codirector Carlos Andres Niño Niño.

ABSTRACT

TITLE: IMPLEMENTATION OF A SYSTEM FOR AUTOMATIC CONTOURS DEFINITION IN TOMOGRAPHIC IMAGES WITH NARROW BAND TECHNICAL ³.

AUTHORS: Dairy Yineth Avila Rueda
Luis Felipe Torrado Soto ⁴

KEY WORDS: Level Sets, Narrow Band, Images Segmentation, Actives Contours, Tri-dimensional Recontruction.

DESCRIPTION:

The segmentation of medical images has been identified as one of the key problems in its analysis, becoming an active area of research. For this reason, we have seen the need to develop and optimize segmentation methods to increase reliability in terms of accuracy and decrease processing time. This is because the amount of information to be processed and derived diagnostic impact of the accuracy of these methods for the processing of medical images.

This project develop an application of deformable models for segmentation of areas of interest in simple and medical images. This study is applied specically to the method Narrow Band Level Set taking into account its characteristics and advantages over the standards Level Sets. We implemented a prototype program for the implementation of the method to simple images and medical images in various formats. The performance of the algorithm was validated with images of literature and other medical images, obtaining excellent results in all cases. The validity and effectiveness of the method were demonstrated in applications of medical imaging, even when they have no sharp edges.

Then, it is present the graduation project entitled: *Implementation of a system for automatic contour definition in tomographic images with the Narrow Band technical*, which is the application of a method for the segmentation of contours in areas of interest in an image using the narrow band sets level technical in 2D the which is a very fast method in comparison with the level set method.

³Research project

⁴Faculty of Mechanical Physical Engineering. School of Electrical, Electronic Engineering, and Telecommunications. Director Daniel Alfonso Sierra Bueno. Codirector Carlos Andres Niño Niño.

Capítulo 1

Introducción

Una imagen médica se utiliza como un conjunto de técnicas y procesos con propósitos clínicos (que buscan diagnosticar o examinar enfermedades) o para la ciencia médica (que incluye el estudio de la anatomía normal y su fisiología). Actualmente la utilización de imágenes médicas ha experimentado una importancia creciente en las distintas áreas de la ciencia con el desarrollo de nuevas técnicas de adquisición de imágenes del cuerpo humano para obtener datos e información de las mismas. La gran cantidad de información disponible con las imágenes ha promovido el desarrollo de métodos de procesado de imagen para su análisis e interpretación de una manera automática a la vez que fiable.

En particular, en el sector de la salud, las imágenes se encuentran ampliamente difundidas debido a la gran cantidad de equipos médicos emisores de imágenes desarrollados. La diversidad de principios de obtención de estas imágenes hace que existan varias modalidades de las mismas, entre las que aparecen las de resonancia magnética (MRI), tomografía axial computarizada (TAC) [6], ultrasonido (US). Estas imágenes forman parte de exámenes médicos de rutina y permiten inferir situaciones referentes a órganos de interés para el especialista, para lo cual debe previamente delimitarse el órgano en cuestión, aplicando, por ejemplo, técnicas de segmentación.

Desde el desarrollo de técnicas de diagnóstico clínico, el análisis de imágenes médicas se ha convertido en una tarea importante para la detección, diagnóstico y tratamiento de múltiples enfermedades. En la mayoría de las aplicaciones clínicas, la segmentación es probablemente uno de los pasos más importantes en este análisis, ya que permite delimitar la geometría y

la cuantificación de las dimensiones de las estructuras de interés. El gran número de imágenes que necesitan ser analizadas en la rutina clínica y la subjetividad introducida por gran segmentación manual han motivado el desarrollo de algoritmos automáticos de segmentación.

La segmentación de imágenes médicas se ha convertido en uno de los temas más importantes de desarrollo computacional, ya que nos permite seleccionar regiones de interés en el análisis médico de diferentes lesiones. En general, las imágenes médicas adquiridas en la práctica clínica tienen un alto contenido de ruido. En la mayoría de los casos, se dificulta la delimitación precisa de las estructuras a segmentar, debido a la falta de bordes fuertes y a la falta de homogeneidad dentro de las estructuras de interés en las imágenes. En ciertos lugares, existen objetos adyacentes con patrones de intensidad similar a la estructura de interés. Todas estas cuestiones hacen que la segmentación sea una tarea compleja que los métodos automáticos de segmentación deben superar.

Debido a lo anteriormente expuesto, se ha propuesto un algoritmo para abordar los problemas planteados por la segmentación de imágenes médicas. La detección de fronteras es una de las técnicas más utilizadas en la segmentación de imágenes, donde se encuentran las técnicas basadas en los modelos deformables, los cuales son conocidos como contornos activos, contornos deformables, curvas minimizantes, entre otros. El concepto de modelo deformable se obtiene a partir de adaptar dinámicamente contornos siguiendo propiedades físicas como la elasticidad, suavidad, dureza y otras. Estos modelos deformables fueron propuestos por primera vez por Kass y Terzopoulos [7]. Uno de los modelos deformables desarrollados actualmente es conocido como conjuntos de nivel el cual fue propuesto por Osher y Sethian [8] es un método capaz de seguir interfaces y formas, que permite realizar cálculos numéricos referentes a curvas y superficies, sin necesidad de parametrizar estos objetos. El método de conjuntos de nivel de banda angosta establece un nivel cero que actualiza su valor en correspondencia al movimiento del contorno.

El objetivo planteado para el desarrollo del trabajo es obtener la segmentación eficiente de imágenes médicas aplicando un modelo deformable, en este caso conjuntos de nivel de banda angosta. Se implementó un algoritmo que aplica el método especificado, se validó la efectividad del prototipo obtenido, realizando comparaciones de desempeño con el método de conjuntos de nivel tradicional, obteniendo mejores resultados en todos los casos. Se demostró la validez del método y la eficacia de su aplicación en imágenes médicas.

Capítulo 2

Marco Teórico

2.1. Imágenes formato DICOM

Las imágenes médicas se generan en un formato específico para ser leídas por especialistas del área de la salud y dar un diagnóstico. Dado que es necesario generar, transmitir, presentar e interpretar estas imágenes en diferentes centros y por diferentes especialistas, se ha creado un formato de estandarización de imágenes médicas llamado DICOM (*Digital Imaging and Communications on Medicine*).

El propósito principal del estándar es garantizar la igualdad de condiciones desde el momento de la adquisición de un estudio imagenológico hasta el momento de ser desplegado en pantalla, después de un posible procesamiento de las imágenes.

En DICOM, es importante resaltar la importancia que tienen las intensidades de grises ya que estas deben ser las mismas sin importar el medio de visualización de la imagen, permitiendo que cualquier especialista observe lo mismo en cualquier tipo de dispositivo de diagnóstico. En la actualidad existen algunas librerías y plataformas de desarrollo que insertan partes esenciales del estándar, facilitando la creación y la implementación de algoritmos para el postprocesamiento de las imágenes médicas según la aplicación que se requiera. Sin embargo, la dificultad que representa el entendimiento del estándar obliga a la mayoría de los investigadores a confiar en los desarrolladores de dichas librerías, permaneciendo atados a las limitaciones que estas puedan presentar en cuanto a tiempo de ejecución y a la calidad de los resultados; incluyendo el hecho que son herramientas para un uso general Figura 2.1 [9].

Con DICOM es posible realizar la integración de escáneres, servidores, estaciones de trabajo, impresoras y hardware de red de diferentes fabricantes en un archivo de imágenes y comunicación (PACS). Estos dispositivos vienen con diferentes estados de conformidad DICOM, indicando claramente las clases DICOM que apoyan. DICOM ha sido ampliamente adoptado por los hospitales [1].




Figura 2.1: Ejemplo de imagen DICOM [1].

2.2. Tomografía Axial Computada

La tomografía axial computada (TAC) es un método imagenológico de diagnóstico médico, que permite observar el interior del cuerpo humano a través de cortes milimétricos transversales al eje cefalo-caudal, mediante la utilización de rayos X. Las imágenes obtenidas por un tomógrafo se presentan de una forma determinada al médico, quien al visualizar el corte lo debe interpretar como si estuviera mirando al paciente desde los pies Figura 2.2.

Este método de diagnóstico permite detectar patologías como: anomalías del cerebro y médula espinal, tumores cerebrales y accidentes cerebro vasculares, sinusitis, aneurisma de




Figura 2.2: TAC de abdomen, en la cual se señala una masa tumoral en la cabeza del páncreas [2].

aorta, infecciones torácicas, enfermedades de órganos como el hígado, los riñones y los nódulos linfáticos del abdomen y muchos otros más.

No debe confundirse la TAC con la radiología convencional de rayos X (placa simple), que igualmente permite una visualización en dos dimensiones, pero con mucho menor detalle, debido a que se superponen las diferentes estructuras del organismo sobre una misma imagen, porque la radiación es emitida de una forma difusa. En cambio, para la TAC se utiliza un haz muy bien dirigido y con un grosor determinado, que depende del tamaño de la estructura a estudiar, pudiendo variarlo desde los 0.5 mm hasta los 20 mm. Adicionalmente en la placa simple las estructuras se ven radiolúcidas (en negro, por ejemplo pulmón) y radiopaco (en blanco, por ejemplo hueso), no pudiéndose diferenciar otro tipo de densidad, mientras que en la TAC, se pueden distinguir distintas densidades, pudiendo así reconocer los múltiples tejidos; además se logran visualizar detalles de hasta 1 mm o 2 mm (cosa no factible en la placa simple) dejando muy pocas estructuras fuera de observación. Esta resolución es una ventaja fundamental para el diagnóstico precoz de procesos tumorales [6].

La Tomografía Axial Computada ha sido un gran avance técnico en el campo médico de nuestros días. Gracias a ella, los médicos pueden acceder a diagnósticos más exactos y evidenciar la existencia de nuevas patologías. El rápido avance de la tecnología nos ha permitido evolucionar hacia el tomógrafo helicoidal, el cual permite la visualización tridimensional del cuerpo humano [6].

2.3. Segmentación

La segmentación subdivide una imagen en sus regiones constituyentes u objetos. El nivel al que la subdivisión se realiza depende del problema a resolver, es decir, la segmentación debe detenerse cuando los objetos de interés en una aplicación han sido aislados. El interés radica en el análisis de imágenes con el objetivo de determinar la presencia o ausencia de anomalías específicas, como los componentes faltantes o caminos de conexión rotos, para verificar su calidad no tiene sentido en la realización de segmentación ir más allá del nivel de detalle necesario para identificar los elementos.

Los algoritmos de segmentación de imágenes monocromáticas generalmente se basan en una de las dos propiedades básicas de los valores de intensidad de la imagen: discontinuidad y similitud. En la primera categoría el enfoque es dividir una imagen basada en los cambios bruscos de la intensidad, tales como los bordes de una imagen. Los enfoques principales de la segunda categoría se basan en la partición de una imagen en regiones que son similares de acuerdo a un conjunto de criterios predefinidos.

La detección de bordes, en particular, ha sido un elemento básico de los algoritmos de segmentación por muchos años. En este proyecto trataremos la segmentación de imágenes utilizando la técnica de banda angosta [10]. La Figura 2.3 muestra un ejemplo de segmentación con este método.

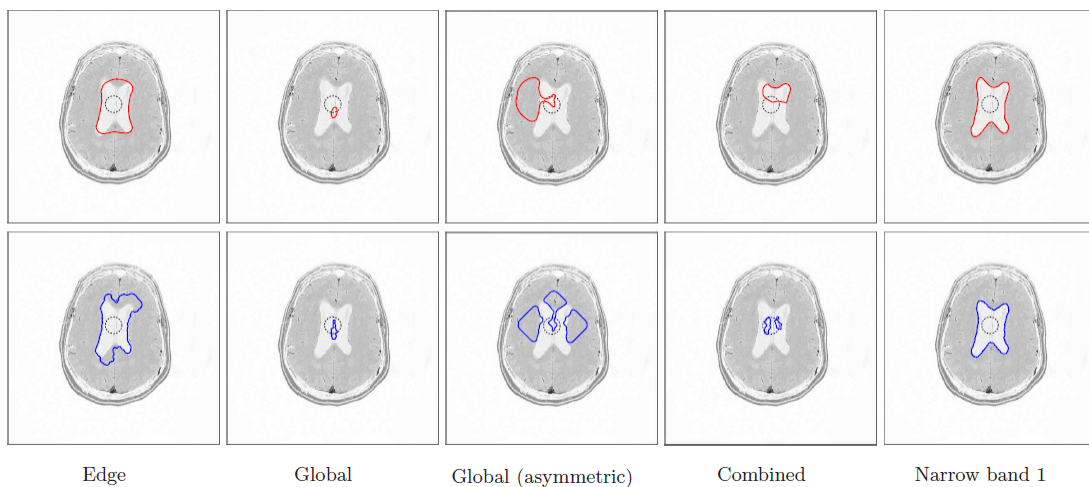


Figura 2.3: Ventrículo del cerebro en 2D vista axial de MRI. Comparación de diferentes métodos de segmentación de imágenes con el método conjuntos de nivel de banda angosta [3].

2.4. Métodos de conjuntos de nivel (*Level Sets*)

La detección de fronteras es una de las técnicas más utilizadas en la segmentación de imágenes, dentro de ella se encuentran las técnicas basadas en los modelos deformables, conocidos en la literatura como *snakes*, contornos activos, contornos deformables, curvas minimizantes, etc [11]. Uno de los modelos deformables desarrollados en la actualidad es el conocido conjuntos de nivel, propuesto por Stanley Osher y James Sethian [8]. Es un método para rastrear interfaces y formas, que permite realizar cálculos numéricos referentes a curvas y superficies en una cuadrícula cartesiana, sin necesidad de parametrizar estos objetos [11]. El método conjuntos de nivel es una versión relativamente sencilla que puede ser fácilmente programado. Sin embargo, no es especialmente rápido, ni hace uso eficiente de las estructuras de datos y recursos computacionales. Consideraremos las versiones más sofisticadas del esquema básico.

El enfoque directo del método conjuntos de nivel es resolver el valor inicial de la ecuación en derivadas parciales de ϕ (que es una función de las curvas de nivel de la imagen). El "método de la matriz total" determina las curvas de nivel de la imagen establecido en todo el dominio de la imagen, ya que se actualiza todo el conjunto de niveles, no solo el nivel cero que corresponda a su propio frente. La ventaja de este enfoque es que las estructuras de datos y las operaciones son muy claras y son un buen punto de partida para establecer la construcción de los algoritmos de conjuntos de nivel. Igualmente si todos los conjuntos de nivel son importantes, entonces se requiere el cálculo sobre todo el dominio.

2.5. Métodos rápidos (conjuntos de nivel de banda angosta)

Cuando se está interesado en un frente específico, hay varias desventajas con el método matricial completo (conjuntos de nivel). Cuando se formula, cada punto de la cuadrícula contiene el valor de la función conjuntos de nivel en ese punto, y por tanto existe una familia entera de contornos, de los cuales solamente uno es el conjunto de nivel cero (Figura 2.4). El método de conjuntos de nivel se posiciona en cada punto de la cuadrícula y actualiza su valor para corresponder al movimiento de la superficie. Esto produce un valor nuevo del contorno en ese punto de la cuadrícula. Un enfoque más eficaz es trabajar sólo cerca del frente de interés [4]. A continuación se describen algunos motivos para buscar una implementación más eficiente.




Figura 2.4: Ejemplo de conjuntos de nivel, la línea oscura corresponde al frente de nivel cero [4].

2.5.1. Velocidad

La realización de cálculos en todo el dominio computacional requiere operaciones en el orden $O(N^2)$ por paso de tiempo en dos dimensiones, y $O(N^3)$ para las operaciones en tres dimensiones, donde N es el número de puntos de malla a lo largo de un lado de la curva. Como alternativa, una modificación eficaz para realizar el trabajo sólo en un conjunto de nivel cero se conoce como banda angosta [4].

2.5.2. Paso de tiempo

El método de matriz completa requiere un paso de tiempo que satisfaga una condición de frontera en consideración de la velocidad máxima sobre el dominio entero, no simplemente en respuesta a la velocidad del frente mismo. En una implementación de la banda angosta, el paso del tiempo puede ser adaptativamente seleccionado como respuesta al campo de velocidad máximo logrado en el algoritmo. Esto es ventajoso cuando la velocidad del frente cambia al moverse (como en el flujo de curvatura). En algunos casos, la restricción de frontera en el campo de velocidad para todos los conjuntos de nivel puede ser mucho más estricta que aquellos campos dentro de la banda angosta (ver Figura 2.5).

El método de conjuntos de nivel de banda angosta (*Narrow Band Level Sets*) fue introducido por Chopp [7], para la recuperación de las formas de las imágenes por Malladi, Sethian y Vemuri [5], y analizado ampliamente por Adalsteinsson y Sethian [12]. La idea se puede




Figura 2.5: Ejemplo de conjuntos de nivel de banda angosta, los puntos cuadrículados en el área oscura son miembros de la banda angosta [4].

entender por medio de dos figuras. La Figura 2.5 muestra la colocación de la banda estrecha alrededor de un frente inicial. La cuadrícula completa de dos dimensiones de datos se almacena en un arreglo cuadrado. Luego, un arreglo unidimensional se utiliza para hacer un seguimiento de los puntos en esta banda estrecha (las celdas cuadrículadas sombreadas en la Figura 2.5 se encuentran alrededor de la parte delantera de un ancho de banda definido por el usuario), ver Figura 2.6. Durante la evolución del frente sólo los valores de ϕ en la banda angosta se actualizan, mientras los valores de ϕ en los puntos de la red en el límite se congelan. Cuando el frente se mueve próximo al borde del límite de la banda, el cálculo se detiene, y una banda nueva se construye con el límite de la interfaz del conjunto de nivel cero en el centro. Este proceso de reconstrucción se conoce como reinicialización. Debido a que el frente no se mueve hasta el límite, estas condiciones del límite no afectan negativamente el movimiento del conjunto de nivel cero.




Figura 2.6: Representación unidimensional de la banda, los puntos interiores indican el arreglo y los puntos del límite la banda angosta [4].

El método de la banda angosta consta del siguiente ciclo:

- I. Marcar los puntos iniciales de la banda, o puntos vivos.
- II. Crear Minas Territoriales para indicar el borde cercano, que no son más que puntos que rodean a los puntos vivos.
- III. Inicializar los puntos alejados fuera del banda angosta con valores positivos (o negativos) grandes si los valores están fuera (o dentro) del frente mismo.
- IV. Solucionar la ecuación de conjuntos de nivel hasta encontrar las Minas Territoriales.
- V. Reconstrucción y reinicio del ciclo.

El uso de la banda angosta conduce a algoritmos de avance del frente de los conjuntos de nivel que son equivalentes en términos de complejidad a los métodos tradicionales de marcadores y a las técnicas de celda planteadas por Osher y Sethian [4].

Capítulo 3

Método conjuntos de nivel de banda angosta (*Narrow Band Level Sets*)

El método de conjuntos de nivel de banda angosta desarrolla un contorno (en dos dimensiones) implícitamente mediante la manipulación de una función de mayor dimensión, llamada función conjuntos nivel $\phi(x, y, t)$. La evolución del contorno puede ser extraída a partir del nivel cero $C(t) = (x, y) : \phi(x, y, t) = 0$. El método de conjuntos de nivel, desde su introducción por Osher y Sethian en [8], ha visto amplia aplicación en el procesamiento de imágenes y gráficos por ordenador (reconstrucciones de superficie).

La evolución de la ecuación de conjuntos de nivel ϕ puede ser escrita en forma general por:

$$\frac{\partial \phi}{\partial t} + |\nabla \phi| \cdot F = 0 \tag{3.1}$$

En la ecuación (3.1) de conjuntos de nivel [8], F es el término que describe la velocidad de la evolución de la banda angosta. Mediante la manipulación de F se puede guiar a los conjuntos de nivel a diferentes áreas o formas, dando una particular inicialización de la función de conjuntos de nivel.

3.1. Formulación de energía del método conjuntos de nivel

Con $\phi : \Omega \rightarrow \mathbb{R}$ siendo una función de conjuntos de nivel definida en el dominio Ω , donde Ω representa el plano entero de la imagen, se define la energía funcional $\epsilon(\phi)$ por:

$$\epsilon(\phi) = \mu R_p(\phi) + \epsilon_{ext}(\phi) \quad (3.2)$$

donde:

$R_p(\phi)$: energía interna de ϕ que caracteriza el crecimiento de la función de conjuntos de nivel.

$\mu > 0$: constante que determina el peso del término interno de energía.

$\epsilon_{ext}(\phi)$: La energía externa que conduce el movimiento de la curva de nivel cero de ϕ .

El término de energía interna $R_p(\phi)$ está definido como:

$$R_p(\phi) \cong \int_{\Omega} p(|\nabla\phi|) dx \quad (3.3)$$

donde p es la función de densidad de energía $p : [0, \infty) \rightarrow \mathbb{R}$. La energía externa $\epsilon_{ext}(\phi)$ está diseñada de tal forma que alcance un mínimo cuando el conjunto de nivel cero de la función conjuntos de nivel ϕ esté localizado en la posición deseada, en nuestro caso en los límites de los objetos que se van a segmentar.

3.2. Formulación del método conjuntos de nivel

En la segmentación de imágenes, los conjuntos de nivel son curvas dinámicas que se mueven hacia los bordes del objeto. Para lograr este objetivo, se define explícitamente una energía externa que puede mover la curva de nivel cero hacia los bordes del objeto. Sea I una imagen en un dominio Ω . Se define una función g indicador de borde por [12]:

$$g \cong \frac{1}{1 + |\nabla G_\sigma * I|^2} \quad (3.4)$$

donde ∇G_σ es un filtro gaussiano con una desviación estandar σ . La convolución en (3.4) se utiliza para suavizar la imagen, reduciendo el ruido. Esta función g por lo general toma los valores más pequeños en los bordes de los objetos que en otros lugares.

Para la función conjuntos de nivel de banda angosta $\phi: \Omega \rightarrow R$, se define una energía externa funcional por [12]:

$$\epsilon_{ext}(\phi) = \lambda L_g(\phi) + \alpha A_g(\phi) \quad (3.5)$$

donde $\lambda > 0$ y $\alpha \in R$ son los coeficientes de la energía funcional L_g y A_g .

La energía $L_g(\phi)$ calcula la integral de línea de la función g a lo largo del contorno del nivel cero de ϕ . En la parametrización del nivel cero de ϕ como un contorno de $C: [0, 1] \rightarrow \Omega$. La energía $L_g(\phi)$ se minimiza cuando el contorno del nivel cero de ϕ se encuentra dentro de los límites del objeto.

La energía funcional $A_g(\phi)$ calcula un área ponderada de la región $\Omega_\phi^- \cong \{(x, y) : \phi(x, y) < 0\}$. Esta energía $A_g(\phi)$ se introduce para acelerar el movimiento del contorno de nivel cero en el proceso de evolución del conjunto de nivel, lo cual es necesario cuando el contorno inicial se coloca lejos de los límites de los objetos deseados. Para la función conjuntos de nivel se tienen valores negativos en el interior del contorno de nivel cero y valores positivos fuera del contorno.

En este caso, si el contorno inicial se coloca fuera del objeto, el coeficiente α en el término área de ponderación debe ser positivo, de modo que el contorno de nivel cero se pueda reducir en la evolución del conjunto de nivel.

Si el contorno inicial se coloca dentro del objeto, el coeficiente α debe tener un valor negativo para expandir su contorno. Desde la evolución del conjunto de nivel dado en (3.8), podemos ver que el papel de g en el término de energía $A_g(\phi)$ es reducir la velocidad de la contracción o expansión del contorno de nivel cero cuando llega a los bordes del objeto donde g toma valores más pequeños.

3.3. Algoritmo de Conjuntos de Nivel de Banda Angosta

La función delta Dirac δ en los funcionales $L_g(\phi)$ y $A_g(\phi)$ está aproximada por la siguiente función de suavidad δ_ϵ [12]

$$\delta_\epsilon = \begin{cases} \frac{1}{2\epsilon} [1 + \cos(\frac{\pi x}{\epsilon})], & |x| \leq \epsilon \\ 0, & |x| > \epsilon. \end{cases} \quad (3.6)$$

La razón por la cual se usa la función de suavidad delta Dirac es que el cambio de 0 a 1 (o viceversa) es leve por lo cual el resultado no sufrirá posibles inestabilidades.

Con la función delta Dirac δ en 3.6 siendo reemplazada por δ_ϵ , la energía funcional $\epsilon(\phi)$ se aproxima a:

$$\epsilon_\epsilon(\phi) = \mu \int_{\Omega} p(|\nabla\phi|) dx + \lambda \int_{\Omega} g\delta_\epsilon(\phi)(|\nabla\phi|) dx + \alpha \int_{\Omega} g\delta'_\epsilon(-\phi) dx \quad (3.7)$$

Esta energía funcional 3.7 puede minimizarse mediante la solución del siguiente gradiente de flujo:

$$\frac{\partial\phi}{\partial t} = \mu(d_p(|\nabla\phi|)\nabla\phi) + \lambda\delta_\epsilon(\phi)(g\frac{\nabla\phi}{|\nabla\phi|}) + \alpha g\delta'_\epsilon(\phi) \quad (3.8)$$

Dada una función conjuntos de nivel inicial $\phi(x,0) = \phi_0(x)$, el primer término del lado derecho en (3.8) está asociado con la distancia de regularización de la energía $R_p(\phi)$, mientras el segundo y el tercer término están asociados con los términos de energía $L_g(\phi)$ y $A_g(\phi)$, respectivamente. La ecuación (3.8) es un modelo geométrico de contorno activo basado en bordes, el cual es una aplicación del método de conjuntos de nivel.

En nuestro caso se incluye el método de conjuntos de nivel de banda angosta, el cual restringe el cálculo de actualización del conjunto de nivel a una banda delgada de píxeles activos que están dentro o cerca del contorno implícito del conjunto de nivel. Esto acelera el cálculo, ya que es muy poca la necesidad de actualizar el conjunto de nivel para píxeles muy lejanos del contorno.

3.4. Esquema de diferencias finitas

En este caso se puede utilizar un esquema de diferencias finitas simple, debido al término de regularización de distancia, lo cual ahorra un gran costo computacional en comparación a los métodos clásicos de conjuntos de nivel.

En la implementación numérica, todas las derivadas parciales espaciales son aproximadas por la diferencia central y la derivada parcial temporal $\frac{\partial \phi}{\partial t}$ es aproximada por la diferencia anticipada, luego la ecuación de evolución del conjunto de nivel es discretizada como la siguiente ecuación diferencial:

$$\frac{\phi_{i,j}^{k+1} - \phi_{i,j}^k}{\tau} = L(\phi_{i,j}^k) \quad (3.9)$$

Donde $L(\phi_{i,j}^k)$ es la aproximación del lado derecho en la ecuación de la evolución del conjunto de nivel por el esquema de diferencias finitas, τ es el paso temporal para controlar la evolución de la curva. La ecuación diferencial (3.9) puede ser expresada como la siguiente ecuación de actualización de la función de conjuntos de nivel:

$$\phi_{i,j}^{k+1} = \phi_{i,j}^k + \tau L(\phi_{i,j}^k) \quad (3.10)$$

La implementación del método de conjuntos de nivel de banda angosta hará al nivel cero más libre de iteración con otros conjuntos de nivel que se encuentren por fuera de la banda angosta. De esta forma se aumentará la velocidad de evolución de la curva, ya que solo existe interacción entre los conjuntos de nivel que se encuentran dentro de la banda. En contraste, en una implementación de conjuntos de nivel existe interacción entre todos los conjuntos de nivel que se encuentren en el dominio de la imagen, lo cual retarda el progreso del conjunto de nivel cero.

En el algoritmo conjuntos de nivel de banda angosta, un pixel $P(i,j)$ es un pixel que cruza por el cero de una función ϕ en la cuadrícula, si cualquiera $\phi_{i-1,j}$ y $\phi_{i+1,j}$ son de signos opuestos ó $\phi_{i,j-1}$ y $\phi_{i,j+1}$ son de signos opuestos.

En la Figura 3.1 se muestra una parte del contorno de nivel cero en la mitad de la banda angosta. Se observa que la banda angosta pasa aproximadamente a lo largo de los píxeles de cruce por cero, donde el valor de la función ϕ es mayor para los píxeles más claros. La banda angosta se compone de píxeles etiquetados con algunos símbolos (+, -, \oplus , \ominus) que son propios de valores positivos y negativos respectivamente, los cuales son asumidos por la función ϕ . Por su parte los píxeles de cruce por cero en la banda angosta son mostrados con los símbolos (\oplus , \ominus). El contorno del nivel cero se muestra como una línea llena pasando a lo largo de los píxeles de cruce por cero. Los píxeles designados con - y + pertenecen a la banda angosta pero no son píxeles de cruce por cero y los píxeles etiquetados -d y +d son puntos fuera de la banda.




Figura 3.1: Porción de una imagen etiquetada, definiendo la banda angosta, esta tiene píxeles etiquetados con los símbolos: +, -, \oplus , \ominus [4].

Capítulo 4

Implementación

4.1. Descripción del algoritmo conjuntos de nivel de banda angosta

En la Figura 4.1 se presenta el diagrama de flujo del algoritmo de conjuntos de nivel de banda angosta.




Figura 4.1: Diagrama de flujo del algoritmo conjuntos de nivel de banda angosta fuente: Autor.

Teniendo en cuenta previamente la región a segmentar se eligen los parámetros adecuados, los cuales se deben seleccionar en el rango que se muestra en la Tabla 4.1 para obtener una segmentación adecuada, luego de seleccionar los parámetros se carga la imagen a segmentar.

4.1.1. Selección de parámetros

El rango de los parámetros adecuados para una segmentación que satisfaga un tiempo de cómputo adecuado y un porcentaje de error pequeño, se muestra a continuación para cada uno de los parámetros utilizados:

El paso temporal (Δt), el cual indica la velocidad de la evolución de la curva, se selecciona $\Delta t \geq 1$, pero si este parámetro es muy grande, hace inestable la evolución de la curva y puede ocasionar un desbordamiento haciendo que se salga de los límites del contorno de la imagen a segmentar. Después de varias pruebas se eligió un rango adecuado entre $1 \leq \Delta t \leq 10$. Para mantener la estabilidad de la evolución de la curva $\mu\Delta t \geq (1/4)$ [1], por lo cual el valor de μ debe ser relativamente pequeño para satisfacer esta condición.

Si el contorno inicial está por fuera del objeto a segmentar, el parámetro α debe ser positivo. Si por el contrario, este contorno inicial está dentro de la región a segmentar α debe tener un valor negativo, para que el contorno inicie su evolución. En las aplicaciones de la presente implementación, el contorno inicial siempre estará dentro del objeto a segmentar, por lo cual α siempre tendrá valores negativos. El rango de valores que debe tener α , el cual es una fuerza adicional externa para impulsar el movimiento del contorno, es $-8 \leq \alpha \leq -1$. El parámetro α necesita ser ajustado para diferentes imágenes. En las imágenes a segmentar cuyos bordes son débiles, un valor grande de α puede provocar desbordamiento del contorno. Por lo tanto, para imágenes con bordes débiles, el valor de α debe ser elegido con un valor relativamente pequeño para evitar el desbordamiento del contorno en los límites del objeto.

El parámetro λ , el cual es el coeficiente externo que indentifica los bordes de la imagen, debe estar en un rango entre $1 \leq \lambda \leq 8$. Por su parte, el parámetro ϵ , que especifica el ancho de la función Delta Dirac, debe ser mayor que cero para que la ecuación sea estable, sin un crecimiento desbordado. Para esta aplicación se realizaron varios experimentos encontrando que el valor más apropiado de ϵ está alrededor de 1.5, mostrando más rapidez de convergencia sin volverse inestable.

Para reducir el ruido de las imágenes se utilizó un filtro Gaussiano, el cual, dependiendo del valor que tenga el parámetro σ los bordes de la imagen van a resaltar mejor, detectando puntos frontera (negro), o puntos pertenecientes a cada superficie (blanco), el rango para éste parámetro es: $0,5 \leq \sigma \leq 2,5$.

A continuación se muestra el rango de valores de los parámetros utilizados en el algoritmo de conjuntos de nivel de banda angosta:

Tabla 4.1: Rango de valores de los parámetros del algoritmo de conjuntos de nivel de banda angosta

Símbolo	Nombre	Rango de parámetro
Δt	Paso temporal	$1 \leq \Delta t \leq 10$
α	Fuerza externa que impulsa el movimiento del contorno	$-8 \leq \alpha \leq -1$
λ	Parámetro externo para identificar bordes de la imagen	$1 \leq \lambda \leq 8$
ϵ	Ancho delta Dirac	1.5
σ	Coefficiente de suavizado	$0,5 \leq \sigma \leq 2,5$
C_0	Distancia de frente de la banda	$C_0 \geq 1$

Luego de la selección de los parámetros, a la imagen a segmentar se le aplica un suavizado previo, el cual se realiza con un filtro Gaussiano, como muestra la ecuación (3.4). Este filtrado depende de la varianza que se quiera ajustar dentro de la imagen, haciendo que la tonalidad de la imagen exponga cambios significativos de tal modo que la delimitación de bordes sea más definida.

4.1.2. Inicialización de la función conjuntos de nivel de banda angosta y establecimiento de la banda

Para eliminar la necesidad de reinicialización, la energía de regularización de distancia tiene un gran beneficio, dado que permite el uso de un esquema más general de inicialización de conjuntos de nivel. Por medio de esta formulación, la función conjuntos de nivel ϕ_0 ya no requiere ser inicializada como una función de distancia determinada. Dada una región R arbitraria en el dominio de la imagen, la función inicial de conjuntos de nivel ϕ_0 está definida por:

$$\phi_0(x, y) = \begin{cases} -C_0, & \text{si } x, y \in R \\ C_0, & \text{si } x, y \notin R \end{cases} \quad (4.1)$$

Siendo $C_0 > 0$ una constante definiendo la distancia al frente del borde de la banda y R una región en el dominio de Ω que es especificada por el usuario, ver Figura 4.2. Con este esquema, ϕ_0 puede ser calculada tomando la función de distancia con el número de píxeles dentro de la banda.

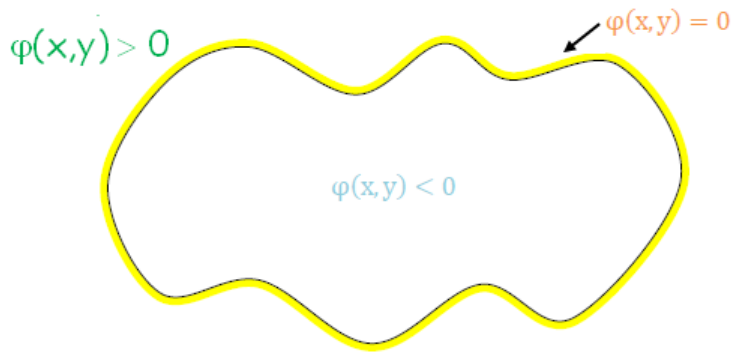


Figura 4.2: Condición inicial para el delineamiento de la función conjuntos de nivel [5].

Se propone utilizar una función de paso binario en (4.1) como la función conjuntos de nivel inicial, ya que puede generar una eficiencia mejor. Por otra parte, la región R en (4.1) algunas veces se puede obtener por una visualización adecuada de la imagen a segmentar, buscando que R esté más cercano a la región que será segmentada. Por lo tanto, solo un pequeño número de iteraciones se requiere para mover el conjunto de nivel cero a partir del límite de R hasta el límite del objeto deseado.

En la práctica, el dominio de la imagen es una rejilla discreta, y la distancia de la banda debe tener al menos un punto de la rejilla a cada lado del contorno del nivel cero. Por lo tanto se sugiere que C_0 se elija desde un rango $C_0 \geq 1$. En este proyecto se estableció experimentalmente

el valor de $C_0 = 4$ para la definición del paso binario en (4.1) como la función conjuntos de nivel inicial. El ancho de la banda angosta es controlado por la constante C_0 , porque la función de conjuntos de nivel se desarrolla a partir de la función de paso binario a una función de distancia aproximada dentro de la banda angosta. Estos valores varían entre $-C_0$ y C_0 a través de la banda como se muestra en la Figura 4.3. Esto implica que el ancho de la banda es aproximadamente $2C_0$.

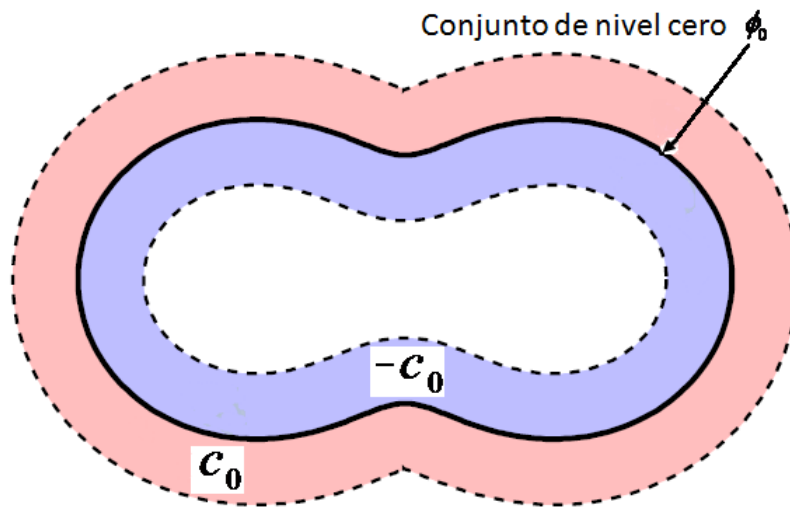


Figura 4.3: Interior y exterior de la banda angosta alrededor del conjunto de nivel cero [3].

4.1.3. Aplicación de la función conjuntos de nivel de banda angosta

El costo computacional del método de conjuntos de nivel puede reducirse considerablemente aplicando el método de conjuntos de nivel de banda angosta para confinar el cálculo en una banda estrecha alrededor del conjunto de nivel cero, como se demostrará en el análisis de resultados. En el método de banda angosta la evolución de la curva puede generarse más rápido, ya que el conjunto de nivel cero se aproximará a la frontera periódicamente. Para el desarrollo de los conjuntos de nivel de la banda angosta se desea introducir un modelo de evolución, ecuación 3.6, en el cual cada actualización de la función conjunto de nivel no sólo conduzca el nivel cero hacia los límites del objetivo, sino también mantenga la función conjunto de nivel como una función aproximada de distancia. Lo anterior se ejemplifica en la Figura 4.4, donde se aprecian los valores de cada pixel que determinan la forma de la curva del nivel cero ϕ_0 , todo confinado en la banda angosta.




Figura 4.4: Movimiento del contorno del nivel cero confinado en una banda angosta [3].

La actualización de la función conjunto de nivel debe buscar dos objetivos simultáneamente: manejar la evolución del nivel cero y mantener adaptativamente un perfil aproximado de una función de distancia determinada. Para la implementación de la banda angosta este modelo de evolución del conjunto de nivel es altamente beneficioso para un cálculo más eficiente. Al mismo tiempo que se actualiza el nivel cero, se actualiza la banda estrecha asignándose nuevos valores a los conjuntos de nivel que se encuentran dentro de la banda estrecha hasta que el movimiento del contorno encuentre los bordes del objeto de interés.

Finalmente, después de realizar el proceso completo de la segmentación de la imagen se visualiza una segmentación adecuada de la zona de interés y se verifica que el tiempo de segmentación sea satisfactorio. De lo contrario, si la segmentación no es adecuada o el tiempo del proceso no es satisfactorio, se modifican los parámetros para obtener una mejor segmentación.

Capítulo 5

Resultados experimentales

Esta sección muestra los resultados del método de conjuntos de nivel de banda angosta, haciendo una comparación en los tiempos de cómputo con el método de conjuntos de nivel tradicional. Para obtener una comparación adecuada se establecerán los siguientes preliminares: En primer lugar, todas las pruebas se llevaron a cabo en un PC con procesador Intel Core i3-370M, sistema operativo de 64 bits, Memoria RAM de 3GB, windows 7. La herramienta que se utilizó para desarrollar y correr el algoritmo fue *Matlab 7.6.0* lo cual brinda una serie de funcionalidades dirigidas al procesamiento de imágenes y su visualización.

En esta sección se muestran algunos ejemplos de imágenes con bordes bien definidos, con un buen contraste y con poco ruido, que llamaremos imágenes secillas, las cuales fueron segmentadas por el algoritmo conjuntos de nivel de banda angosta que permiten observar la influencia de los parámetros necesarios para realizar una correcta segmentación (ver Figura 5.1) y se realizará una comparación con el algoritmo de conjuntos de nivel tradicional.

Para el ejemplo *a* de la Figura 5.1 se utilizó una imagen con un buen contraste y con dimensiones de 59 x 77 pixeles. Se tomaron los siguientes parámetros: $\lambda = 5$, $\mu = 0,04$, $\Delta t = 5$, $\sigma = 0,8$. Se puede observar que el borde del objeto a segmentar es visible y por esta razón podemos utilizar un α relativamente grande sin que se genere un desbordamiento del contorno; en este caso especial se utilizó un $\alpha = -10$. El tiempo y el número de iteraciones necesario para obtener una segmentación adecuada con los algoritmos de conjuntos de nivel tradicional desarrollado por C. A. Niño [13] y de conjuntos de nivel de banda angosta, se muestran en la Tabla 5.1.




Figura 5.1: Segmentación de imágenes sencillas utilizando el método de conjuntos de nivel de banda angosta. Izquierda: Contorno inicial. Centro: Curva en evolución. Derecha: Segmentación finalizada fuente: Autor.

La velocidad de ejecución del método de la banda angosta comparado con el de conjuntos de nivel tradicional para la imagen del ejemplo *a* es aproximadamente 13 veces más rápido, como se muestra en los resultados del ejemplo *a* de la Tabla 5.1. Para este primer ejemplo, la efectividad del algoritmo de conjuntos de nivel de banda angosta es mejor en términos de rapidez respecto al algoritmo de conjuntos de nivel tradicional.

De igual forma, para la imagen *b* de la Figura 5.1 se utilizó una figura sencilla con un contraste un poco más pobre que en el primer caso y con unas dimensiones de la imagen de 96×127 píxeles, se tomaron $\lambda = 5$, $\mu = 0,04$, y $\Delta t = 5$, $\sigma = 0,8$. Se observa que a diferencia del primer caso el borde del objeto a segmentar es un poco más difuso y por esta razón el valor de α debe ser un poco más pequeño para que no haya un desbordamiento del contorno; se utilizó un $\alpha = -3$.

Tabla 5.1: Comparación en la rutina de los algoritmos - Ejemplos de segmentación en imágenes sencillas en 2D

Ejemplo	Técnica	Iteraciones	Tiempo (s)
a	Banda angosta	25	2,9
a	Conjuntos de nivel tradicional	100	37.72
b	Banda angosta	80	10.6
b	Conjuntos de nivel tradicional	90	190.1
c	Banda angosta	30	3.6
c	Conjuntos de nivel tradicional	85	83.42

El rendimiento de velocidad de segmentación alcanzado en esta imagen por el método de la banda angosta es de 18 veces más rápido que por el método de los conjuntos de nivel tradicional, por lo tanto se observa que en la imagen cuyas dimensiones son más grandes, el rendimiento del algoritmo de conjuntos de nivel de banda angosta es más notable como se muestra en el ejemplo *b* de la Tabla 5.1. Esto motiva a la exploración de los efectos de velocidad del algoritmo para imágenes de diferentes tamaños.

Para la segmentación de la imagen *c* de la Figura 5.1 con dimensiones de 75 x 79 píxeles y con un contraste relativamente pobre, se tomaron los siguientes parámetros: $\lambda = 5$, $\mu = 0,04$, $\Delta t = 5$, $\sigma = 0,8$. En esta imagen se observa que el borde del objeto elegido es poco difuso y por esta razón podemos utilizar un α relativamente grande sin que pueda existir un desbordamiento del contorno, en este caso especial se utilizó un $\alpha = -6$. En la tabla 5.1 se observa el número de iteraciones y el tiempo de cómputo utilizado por el algoritmo de conjuntos de nivel de banda angosta para obtener una segmentación óptima y su comparación con el método de conjuntos de nivel tradicional.

La velocidad de segmentación alcanzada en esta imagen por el método de conjuntos de nivel de banda angosta es 23 veces mayor que por el método de los conjuntos de nivel tradicional como se muestra en el ejemplo *c* de la Tabla 5.1.

A continuación se va a presentar el resultado del algoritmo conjuntos de nivel de banda angosta aplicado para las imágenes DICOM, teniendo en cuenta la variación de los parámetros para cada caso y su rapidez en la respuesta.




Figura 5.2: Ejemplo 1 de segmentación de imagen tipo DICOM utilizando el método de conjuntos de nivel de banda angosta fuente: Autor.

En la imagen de la Figura 5.2 se muestra el cerebro en un plano sagital. Esta imagen tiene un contraste relativamente pobre y tiene unas dimensiones de 512×512 pixeles. Esto hace que la imagen tenga una segmentación computacionalmente exigente (ya que tiene unas dimensiones relativamente grandes). Se utilizaron los siguientes parámetros: $\lambda = 5$, $\mu = 0,067$, $\Delta t = 3$, $\alpha = -5$, $\sigma = 0,8$. Se puede observar que estos varían un poco respecto a las imágenes sencillas ya que los bordes del objeto a segmentar son muy difusos y la curva de crecimiento no detalla de una manera adecuada los bordes reales del objeto a segmentar.

Tabla 5.2: Comparación en la rutina de los algoritmos - Ejemplo 1 de segmentación imagen DICOM en 2D

Técnica	Iteraciones	Tiempo (s)
Banda angosta	120	66.47
Conjuntos de nivel tradicional	160	821.27

Según la Tabla 5.2 se observa que la velocidad en la segmentación de la imagen es mayor con el método de conjuntos de nivel de banda angosta que por el método de conjuntos de nivel tradicional, aproximadamente 12 veces más rápido. Esto ejemplifica que el método de conjuntos de nivel de banda angosta también es más eficiente en términos de tiempo de segmentación en imágenes tipo DICOM comparado con el método de conjuntos de nivel tradicional.




Figura 5.3: Ejemplo 2 de segmentación de imagen tipo DICOM utilizando el método de conjuntos de nivel de banda angosta fuente: Autor.

En un segundo ejemplo se confirma la efectividad del algoritmo de conjuntos de nivel de banda angosta en la segmentación de zonas de interés de una imagen tipo DICOM. En la Figura 5.3 se presenta un corte del cerebro en un plano sagital con dimensiones de la imagen anterior (512 x 512) y un contraste de la imagen relativamente pobre, lo que dificulta su segmentación. Para una segmentación adecuada se utilizaron los siguientes parámetros: $\lambda = 6$, $\mu = 0,1$, $\Delta t = 2$, $\alpha = -2,3$, $\sigma = 1,8$.

Tabla 5.3: Comparación en la rutina de los algoritmos - Ejemplo 2 de segmentación imagen DICOM en 2D

Técnica	Iteraciones	Tiempo (s)
Banda angosta	160	88.87
Conjuntos de nivel tradicional	160	1226.98

Se observa de nuevo la efectividad del método de conjuntos de nivel de banda angosta en la Tabla 5.3, en el cual la velocidad en la segmentación de la imagen es aproximadamente 13 veces mayor con el método de la banda angosta que por el método de conjuntos de nivel tradicional.

Para un tercer ejemplo se tiene otro corte sagital del cerebro en la imagen de la Figura 5.4 para realizar la segmentación de una zona de interés. Esta imagen tiene las mismas dimensiones




Figura 5.4: Ejemplo 3 de segmentación de imagen tipo DICOM utilizando el método de conjuntos de nivel de banda angosta fuente: Autor.

de la imágenes anteriores (512 x 512). Se utilizaron los siguientes parámetros: $\lambda = 5$, $\mu = 0,1$, $\Delta t = 2$, $\alpha = -7$, $\sigma = 0,8$. Se observa el crecimiento del contorno utilizando el método de conjuntos de nivel de banda angosta en una imagen con bordes un poco difusos, lo que dificulta la segmentación de la zona de interés, pero como se puede observar se obtuvo una segmentación adecuada en la imagen de la Figura 5.4.

Tabla 5.4: Comparación en la rutina de los algoritmos - Ejemplo 3 de segmentación imagen DICOM en 2D

Técnica	Iteraciones	Tiempo (s)
Banda angosta	70	42.07
Conjuntos de nivel tradicional	100	700.24

En este caso la efectividad del método de conjuntos de nivel de banda angosta también es mayor que con el método de conjuntos de nivel tradicional. En la Tabla 5.4, se observa que la velocidad en la segmentación de la imagen es aproximadamente 16 veces mayor que utilizando el método de conjuntos de nivel tradicional. Con los resultados obtenidos en los anteriores ejemplos se corrobora que en terminos de velocidad el método de conjuntos de nivel de banda angosta es más eficiente que el método de conjuntos de nivel tradicional en imágenes tipo DICOM.

En la Figura 5.5 se puede observar el resultado final de la segmentación del objeto de interés tanto con el algoritmo de la banda angosta como con el de conjuntos de nivel, para así

comparar la exactitud en el contorno final de cada uno de los dos algoritmos entre ellos mismos, además se muestra la imagen original para realizar la comparación del contorno segmentado con cada método y analizar la precisión respecto a la forma ideal de la segmentación.




Figura 5.5: Comparación segmentación final de los dos métodos en imágenes sencillas fuente: Autor.

En cada uno de los casos de segmentación en imágenes sencillas, se puede observar que con los parámetros utilizados para cada imagen la segmentación final tiene una precisión alta respecto al objeto a segmentar, identificando de manera adecuada los bordes de la imagen. En cuanto a la comparación de exactitud entre los diferentes métodos, se observa una mayor precisión en el contorno final con el método de conjuntos de nivel de banda angosta, esto se muestra en cada uno de los tres ejemplos en la identificación de los bordes de imagen. Teniendo en cuenta la rapidez del método de conjuntos de nivel de banda angosta respecto al método de conjuntos de nivel y a la precisión en la identificación de la zona a segmentar, se puede decir que el algoritmo de la banda angosta es un método adecuado en la segmentación de imágenes sencillas.

Para observar la exactitud en la segmentación del objeto de interés en la imágenes tipo DICOM, se hizo de manera similar que para la imágenes sencillas. Se muestra la segmentación final para diferentes imágenes tipo DICOM, utilizando tanto el algoritmo de la banda angosta como con el de conjuntos de nivel para así comparar la exactitud del contorno final. Además, para analizar de una mejor manera el segmentado del objeto de interés se muestra la imagen original y así observar de manera adecuada los bordes donde debería estar el contorno final, como se muestra en la Figura 5.6.

Se observa que en la imágenes tipo DICOM la segmentación final del contorno de interés es un poco menos precisa que en las imágenes sencillas. Esto sucede por el alto nivel de ruido que presentan las imágenes tipo DICOM, lo cual dificulta un poco la identificación del borde de interés. Sin embargo, comparando la precisión del contorno final de los dos algoritmos, se observa una mayor exactitud en la segmentación final del algoritmo de banda angosta respecto al de conjuntos de nivel tradicional, como se muestra en cada uno de los ejemplos de la Figura 5.6. Con el análisis anterior se comprueba que el algoritmo de banda angosta es adecuado en la segmentación de zonas de interés en imágenes tipo DICOM, ya que es un método que reduce significativamente el tiempo de segmentación con un nivel de precisión adecuado.




Figura 5.6: Comparación segmentación final de los dos métodos en imágenes DICOM fuente: Autor.

Capítulo 6

Proyección en 3D

6.1. Descripción del algoritmo de visualización en 3D

En la Figura 6.1 se presenta el diagrama de flujo del algoritmo para la reconstrucción en 3D de la segmentación de imágenes tipo DICOM.

Para mejorar la visualización de la región que se desea segmentar, se diseñó un algoritmo que permite proyectar en 3D la segmentación realizada en la imagen DICOM. Esta proyección se realizó de la siguiente forma: dentro del algoritmo que realiza la segmentación, se carga la carpeta de un paciente, para poder segmentar la imagen DICOM a diferentes cortes. En este paso se segmentaron al menos 15 imágenes, las cuales toman un papel importante en la profundidad de la proyección. Las imágenes ya segmentadas se guardaron en una carpeta diferente; seguidamente esta carpeta se cargó con otro algoritmo, para crear una hipermatriz conteniendo todas las imágenes segmentadas. Luego de obtener la hipermatriz, el código de proyección realizó el trabajo de unir las imágenes segmentadas y mostrar la imagen en 3D.

Se debe tener en cuenta que cada imagen varía de forma poco significativa, por lo tanto se van a usar parámetros estándares que se lograron establecer de forma experimental para cada conjunto de imágenes.

La Figura 6.2 muestra un ejemplo típico de la representación en 3D. En la parte a se muestra la segmentación corte "a" corte de la zona de interés; en la parte "b" se reconstruye a partir de las segmentaciones por corte de la zona segmentada. En este ejemplo, la reconstrucción 3D fue realizada sobre un conjunto de 15 cortes, los cuales fueron suficientes para lograr una adecuada representación. Se utilizaron los siguientes parámetros $\lambda = 5$, $\mu = 0,04$, $\Delta t = 5$, $\sigma = 0,8$ y un α de -5 para la segmentación de cada uno de los cortes. Con este valor de parámetros se obtiene una relativa buena velocidad en la segmentación de cada corte y una buena exactitud.




Figura 6.1: Diagrama de flujo del algoritmo Banda Angosta fuente: Autor.

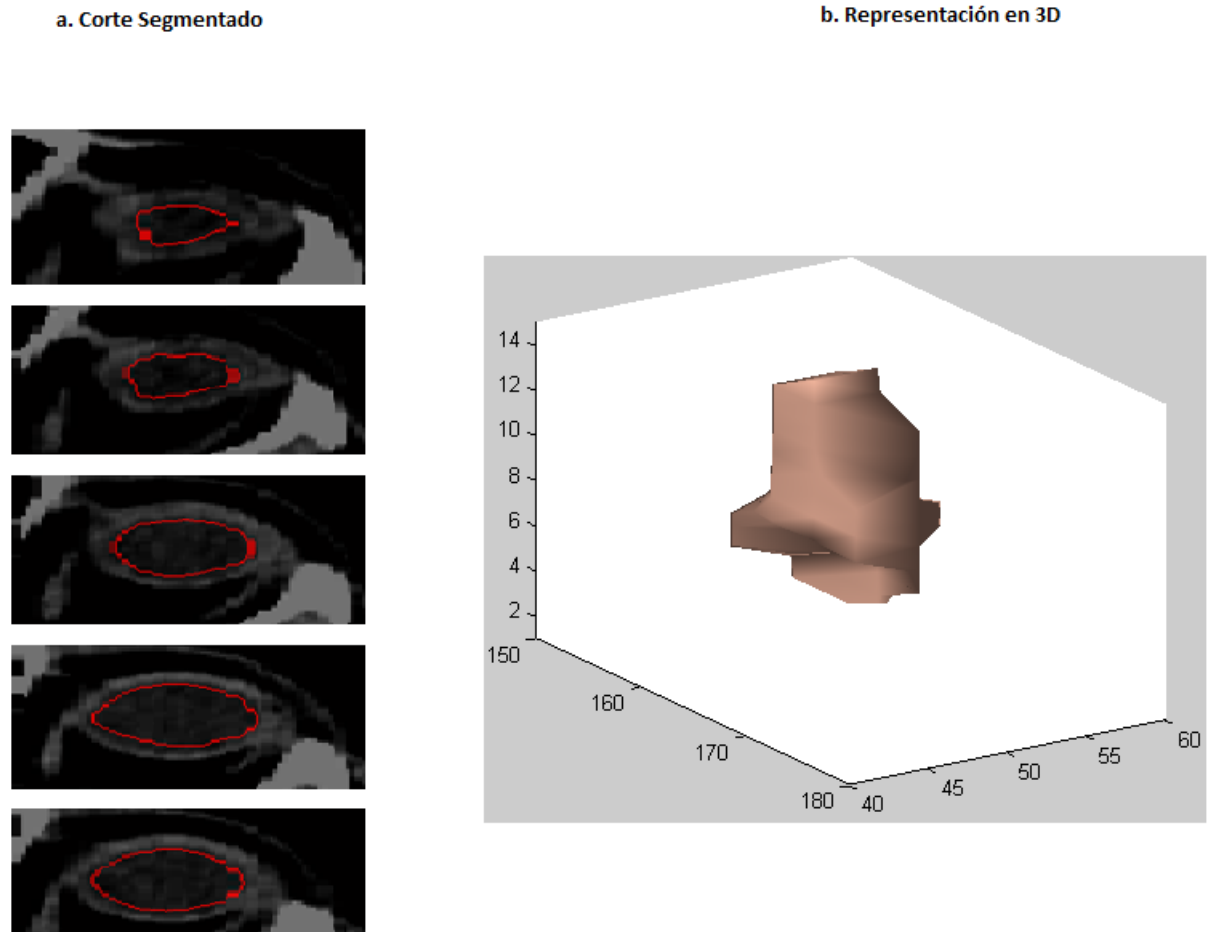


Figura 6.2: Imagen reconstrucción de la región segmentada fuente: Autor.

Los resultados obtenidos son satisfactorios porque al reconstruir una estructura definida por la segmentación en forma precisa podrá ser usado para el reconocimiento de estructuras anatómicas o lesiones cerebrales. De igual forma facilitará la visualización de la región que se desee segmentar, lo que permitirá hacer análisis mas confiables respecto a la región de interés. Se debe tener en cuenta que este algoritmo puede ser mejorado, de tal forma que sea más automático en el momento de segmentar cada corte y guardar cada imagen segmentada en una carpeta diferente de las imágenes DICOM.

Capítulo 7

Conclusiones y Recomendaciones

7.1. Conclusiones

Durante el desarrollo de este proyecto se ha presentado el método de conjuntos de nivel llamado conjuntos de nivel banda angosta. El algoritmo de conjuntos de nivel banda angosta tiene la capacidad intrínseca de mantener la regularidad de la función de ajuste de nivel, lo que asegura cálculo exacto y la evolución estable, con un mejor tiempo de cómputo respecto al método de conjuntos de nivel tradicional.

El método de conjuntos de nivel de banda angosta puede ser implementado por un sistema más sencillo y más eficiente que los métodos convencionales de segmentación, de igual forma, también permite una inicialización más flexible y eficiente que el método de conjuntos de nivel tradicional. Como un ejemplo, se ha aplicado el método de banda angosta a una serie de imágenes tipo DICOM para la segmentación de lesiones cerebrales, lo cual proporciona una aplicación de banda angosta simple y eficiente en este modelo.

Se validó la efectividad del algoritmo de banda angosta, realizando comparaciones de desempeño con el método de segmentación de conjuntos de nivel. Se obtuvieron en las pruebas realizadas resultados satisfactorios, demostrándose la validez del método y la eficacia de su aplicación en imágenes médicas, incluso cuando las mismas tienen alto contenido de ruido.

7.2. Recomendaciones

Considerando que la modificación de los parámetros del algoritmo son parte fundamental para una segmentación adecuada y un mejor tiempo de cómputo, se recomienda hacer más pruebas experimentales que lleven a establecer parámetros adecuados que permitan obtener una segmentación más rápida y precisa, para cada tipo de imagen, teniendo en cuenta sus características de contraste, suavidad, color, etc.

Un trabajo futuro se puede centrar en realizar la segmentación de las imágenes por medio del método de conjuntos de nivel de banda angosta directamente en su proyección de tres dimensiones, lo cual va a permitir numerosas aplicaciones en las imágenes médicas.

Bibliografía

- [1] A. Smith, “Medical break through DICOM viewer,” *Niche Project*, 2011.
- [2] F. Rozman, *Medicina Interna*, Elsevier, Ed., 2008.
- [3] J. Mille, P. Makris, and H. Cardot, “2D and 3D deformable models with narrowband region energy,” in *International Conference on Image Processing*, 2007, pp. 57–60.
- [4] J. A. Sethian, *Levelset Methods And Fast Marching Methods in Computational Geometry, Fluid Mechanics, Computer Vision, and Materials Science*. The Press Syndicate of the University of Cambridge, 1996.
- [5] R. Malladi, S. J.A., and B. Vemuri, “Evolutionary fronts for topology-independent shape modeling and recovery,” *Lecture Notes in Computer Science*, vol. 800, pp. 3,13, 1994.
- [6] D. C. Pereira, “Tomografía axial computada,” *XIII Seminario de Ingeniería biomédica*, 2004.
- [7] D. Chopp, “Computing minimal surfaces via level set curvature flow.” *Jour. of Comp. Phys*, vol. 106, pp. 77–91, 1993.
- [8] S. Osher and J. A. Sethian, “Fronts propagating with curvature-dependent speed: Algorithms based on hamilton-jacobi formulations,” *Journal Of Computational Physics*, vol. 79, pp. 12–49, 1988.
- [9] W. S. Serna and J. P. Trujillo, “Descripción del estándar DICOM para un acceso confiable a la información de las imágenes médicas.” *Scientia et Technica Año XVI. ISSN 0122-1701*, vol. 45, 2010.
- [10] R. C. Gonzalez, *Digital Image Processing Using Matlab*. Rafael C. Gonzalez, 2001.
- [11] M. E. Nicot and S. H. García, “Segmentación de imágenes médicas aplicando levelsets,” *VII Congreso Internacional de Informatica en la Salud*, 2005.
- [12] D. Adalsteinsson and J. Sethian, “A fast level set method for propagating interfaces,” *Comp. Phys.*, vol. 118,2, pp. 269–277, 1995.

- [13] C. A. Niño, *Sistema de procesamiento y análisis de la señal cardiaca como indicador del balance del sistema nerviosos autónomo y su correlacion con datos tomograficos en pacientes con accidente cerebrovascular. Tesis de Maestria en Ingeniería Electrónica.* Universidad Industrial de Santander, 2010.