

UNIVERSIDAD AUTÓNOMA METROPOLITANA-IZTAPALAPA

CIENCIAS BÁSICAS E INGENIERÍA

**SEGMENTACIÓN ECOCARDIOGRÁFICA
3D UTILIZANDO EL ALGORITMO
DE CORRIMIENTO DE MEDIA Y
UN MODELO DE SUPERFICIE ACTIVA**

NAZARIO FÉLIX GONZÁLEZ

**TESIS PARA OBTENER EL GRADO DE
MAESTRO EN CIENCIAS (INGENIERÍA BIOMÉDICA)**

DICIEMBRE, 2006

ASESORA: DRA. RAQUEL VALDÉS CRISTERNA

SINODALES:

**DR. FERNANDO ARAMBULA COSÍO
DR. ANGEL TOMAS ALJAMA CORRALES
DRA. RAQUEL VALDÉS CRISTERNA**

AGRADECIMIENTOS

A DIOS por darme la vida y el invaluable regalo de la sabiduría y el conocimiento. Gracias por amarme y cuidarme cada día de mi existencia.

A mis padres y a mis hermanos por su apoyo y confianza en la realización de este proyecto. Gracias por apoyarme en todo momento y por nunca dejar de creer en mí.

A una mujer que ha compartido esta etapa de mi vida y que me ha motivado a ser alguien mejor cada día. Gracias Ruth por tu amor y comprensión.

A la Dra. Raquel Valdés por otorgarme el privilegio de trabajar y aprender de ella. Gracias por orientarme y dirigirme en este trabajo de investigación, pero sobre todo, gracias por darme la confianza de creer en mi mismo.

A mis amigos y compañeros en esta aventura tan maravillosa que es la vida. Gracias por hacerme reír en los momentos difíciles y permitirme darme cuenta que no todo en la vida es el estudio y el trabajo.

A mis sinodales por sus observaciones que han enriquecido enormemente este trabajo de investigación.

A mis profesores del posgrado de ingeniería biomédica de la UAM por su paciencia y dedicación en las clases que me impartieron.

A mis alumnos de la UVM por su tolerancia y apoyo cuando no los pude atender por realizar alguna actividad de este trabajo de investigación.

Al Consejo Nacional de Ciencia y Tecnología por su apoyo y financiamiento para realizar mis estudios de posgrado.

INDICE

| | |
|---|--------|
| ÍNDICE DE TABLAS Y FIGURAS..... | - 5 - |
| RESUMEN | - 6 - |
| INTRODUCCIÓN..... | - 7 - |
| OBJETIVOS..... | - 9 - |
| Capítulo 1 INTRODUCCIÓN A LA ANATOMÍA CARDIACA Y AL ULTRASONIDO EN CARDIOLOGÍA..... | - 10 - |
| Capítulo 2 SEGMENTACIÓN DE IMÁGENES ECOCARDIOGRÁFICAS..... | - 13 - |
| Capítulo 3 METODOLOGÍA..... | - 17 - |
| 3.1 IMÁGENES | - 17 - |
| 3.2 FILTRADO POR CORRIMIENTO DE MEDIA (MEAN-SHIFT)..... | - 18 - |
| 3.2.1 ESTIMADO DEL GRADIENTE DE LA FUNCION DE DENSIDAD.... | - 18 - |
| 3.2.2 IMPLEMENTACION EN IMÁGENES BIOMEDICAS..... | - 21 - |
| 3.3 MAPA TRIDIMENSIONAL DE BORDES..... | - 21 - |
| 3.4 CÁLCULO DE LA ENTROPIA DEL MAPA DE BORDES..... | - 22 - |
| 3.5 MAPA TRIDIMENSIONAL DE CONFIANZA..... | - 23 - |
| 3.6 PRESEGMENTACIÓN POR CORRIMIENTO DE MEDIA..... | - 25 - |
| 3.7 ANÁLISIS DE REGIONES ADYACENTES..... | - 26 - |
| 3.7.1 ETIQUETADO..... | - 26 - |
| 3.7.2 CERRADURA TRANSITIVA..... | - 26 - |
| 3.7.3 PODADO DE REGIONES..... | - 26 - |
| 3.8 MODELO DE SUPERFICIES ACTIVAS (MSA)..... | - 27 - |
| 3.9 DESEMPEÑO DEL PROCEDIMIENTO..... | - 27 - |
| Capítulo 4 RESULTADOS Y DISCUSIÓN | - 28 - |
| 4.1 FILTRADO | - 28 - |
| 4.2. MAPA DE ENTROPIA OBTENIDA DEL MAPA TRIDIMENSIONAL DE BORDES..... | - 29 - |
| 4.3. MAPA DE CONFIANZA 3D..... | - 29 - |
| 4.4. PRESEGMENTACIÓN POR CORRIMIENTO DE MEDIA | - 31 - |
| 4.5. ANALISIS DE REGIONES ADYACENTES..... | - 32 - |
| 4.6 MODELO DE SUPERFICIES ACTIVAS (MSA)..... | - 34 - |
| 4.7. DESEMPEÑO DEL PROCEDIMIENTO..... | - 37 - |
| CONCLUSIONES..... | - 38 - |
| REFERENCIAS | - 40 - |
| APENDICE A Tabla de valores de parámetros en cada una de las etapas de la Metodología Propuesta..... | - 42 - |

APENDICE B Artículo publicado en: Medical Imaging 2006. 11-16 February 2006. San Diego, California, USA. Organizado por: The International Society for Optical Engineering (SPIE). - 43 -

ÍNDICE DE TABLAS Y FIGURAS

| | |
|--|--------|
| Tabla 3-1 Estudios ecocardiográficos en 4D..... | - 17 - |
| Figura 1.1 Esquema del flujo sanguíneo a través de las cámaras cardiacas, los pulmones y el cuerpo. | - 10 - |
| Figura 1.2 Ubicación de las válvulas atrioventriculares (válvulas mitral y tricúspide), válvulas semilunares (válvulas aórtica y pulmonar), y el aparato subvalvular para las válvulas atrioventriculares..... | - 11 - |
| Figura 2.1 Diferentes características de textura en una imagen de Ultrasonido de la espina fetal..... | - 15 - |
| Figura 3.1 Metodología propuesta para la segmentación..... | - 17 - |
| Figura 3.2 Vistas bidimensionales de un volumen del Estudio 1 y del Estudio 2..... | - 18 - |
| Figura 3.3 Cálculo sucesivo del corrimiento de media..... | - 20 - |
| Figura 3.4 Imagen en intensidades del eco que muestran el proceso de filtrado por corrimiento de media..... | - 21 - |
| Figura 3.5 Imagen cuantificada en 3 niveles de gris, muestreada en 5x5 píxeles y su matriz de co-ocurrencia para la dirección = 0° y distancia =1 | - 22 - |
| Figura 3.6 Ventana de muestreo del mapa de bordes tridimensional de tamaño 5x5x5 . | - 23 - |
| Figura 3.7 Cálculo del mapa de confianza en tres dimensiones..... | - 24 - |
| Figura 4.1 Cortes longitudinales de los resultados obtenidos con el proceso de filtrado para tres estudios diferentes..... | - 28 - |
| Figura 4.2 Corte longitudinal del mapa tridimensional de entropía obtenido del mapa de bordes.. | - 30 - |
| Figura 4.3 Corte longitudinal del mapa de confianza 3D para los tres estudios presentados en la figura 4.1..... | - 31 - |
| Figura 4.4 Resultado del proceso de presegmentación.. | - 31 - |
| Figura 4.5 Resultado de la presegmentación..... | - 32 - |
| Figura 4.6 Regiones etiquetadas, resultado del análisis de regiones adyacentes..... | - 33 - |
| Figura 4.7 Contorno inicial y final sobre un corte longitudinal del volumen..... | - 34 - |
| Figura 4.8 Contorno final sobre un corte longitudinal del volumen segmentado manualmente por el experto clínico en diferentes etapas del ciclo cardiaco..... | - 35 - |
| Figura 4.9 Superficie final sobre el volumen de la ecocardiografía sin procesar..... | - 36 - |
| Figura 4.10 Generación de bordes o estructuras falsas efecto de la retrodispersión..... | - 37 - |

RESUMEN

La información anatómica y funcional de las cavidades cardiacas obtenida de las imágenes de ultrasonido permite realizar un análisis cualitativo y cuantitativo de la salud del paciente; y detectar posibles patologías. Varias técnicas para la segmentación semiautomática o completamente automática han sido propuestas. La presegmentación basada en las características de textura combinada con un modelo de contorno activo ha demostrado ser una vía prometedora para extraer las estructuras cardiacas de las imágenes ecocardiográficas. En este trabajo se introduce un método novedoso para la segmentación de imágenes cardiacas en 3D. Una etapa robusta de preprocesamiento que reduce el ruido de moteado y extrae la frontera inicial de las estructuras cardiacas es combinada con un Modelo de Superficie Activa para obtener la segmentación final en 3D. El preprocesamiento es realizado con el algoritmo de Corrimiento de Media que integra la información de confianza del mapa de bordes 3D e incluye la entropía, la intensidad de los ecos y la información espacial como características de entrada. Este procedimiento localiza adecuadamente regiones homogéneas en las imágenes ecocardiográficas 3D. Los términos de energía externa incluidos en el Modelo de Superficie Activa son el mapa de confianza de los bordes en 3D y la componente de entropía obtenida del resultado de la presegmentación. Los resultados demuestran que el procesamiento provee una buena frontera inicial entre la sangre y el miocardio. El Modelo de Superficie Activa ajusta la superficie inicial calculada por el algoritmo de Corrimiento de Media al borde de las cavidades cardiacas. Finalmente, los resultados obtenidos son comparados con la segmentación manual del experto clínico y se calcula el índice de Tanimoto entre la segmentación manual y la segmentación del método propuesto.

INTRODUCCIÓN

En el dominio de la medicina, la imagenología se ha expandido considerablemente en los últimos años. La extracción de información anatómica o funcional de los órganos o estructuras de interés obtenida a través de diferentes modalidades de imagenología médica como el ultrasonido (US), la medicina nuclear, la tomografía axial computarizada (TAC) y la resonancia magnética nuclear (RMN); permiten la reconstrucción de imágenes tridimensionales. Dentro del campo de la imagenología médica, la evaluación de la función cardíaca ha sido una de las áreas de mayor interés.

Un análisis cualitativo y cuantitativo de estas imágenes permite determinar la salud cardíaca del paciente y posibles patologías en su organismo. La falla en alguna de las cavidades cardíacas puede tener consecuencias inmediatas; además, los cambios de volumen o de forma en el comportamiento ventricular o auricular durante el ciclo cardíaco pueden ser indicadores de alguna enfermedad grave. Algunos parámetros importantes como el volumen expulsado (cantidad de sangre expulsada en un ciclo cardíaco) o la fracción de eyección (proporción del volumen de la cavidad que es expulsado en cada latido) están directamente definidos por el volumen ventricular. Un delineado preciso de estas estructuras y la estimación de sus volúmenes se vuelven de gran importancia para un cálculo exacto de estos parámetros [1].

Entre las técnicas de imagenología médica, el ultrasonido es la más empleada para observar el movimiento y la deformación cardíaca, debido a que es una técnica no invasiva, no produce una radiación ionizante, permite la observación dinámica de las cavidades cardíacas en tiempo real y es de bajo costo. Además de lo anterior, el ultrasonido es compatible con los instrumentales y equipo médico metálico, lo cual no es posible con la RMN ni con la TAC [2].

A pesar de ser la técnica más usada, el ultrasonido presenta algunos inconvenientes que dificultan la interpretación de las imágenes médicas, como el ruido de moteado (speckle) y la detección de falsos bordes. Aunado a lo anterior, la relación entre la intensidad de un píxel y alguna característica física del tejido no es directa; los diferentes tejidos sólo se diferencian por un pequeño cambio en la textura y no por variaciones en la intensidad de los píxeles. Estas desventajas originan que la extracción de las estructuras cardíacas de las ecografías sea un proceso difícil de implementar [3].

El método clásico aplicado a la resolución de este problema consiste en la implementación de diferentes etapas de análisis y procesamiento. Después de adquirir las imágenes en el formato digital es necesario realizar un preprocesamiento para reducir los efectos del ruido de moteado, característico del ultrasonido. Posteriormente, las imágenes preprocesadas son sujetas a una operación de segmentación, en la que se localizan las fronteras de las estructuras. El último paso del método clásico consiste en un algoritmo de identificación y extracción de los bordes de las estructuras o regiones de interés de las imágenes segmentadas [4].

Para obtener una representación más precisa de las cavidades cardíacas, es necesario que el proceso de segmentación localice adecuadamente los puntos de frontera. Debido a la dependencia que existe entre esta etapa y el algoritmo de identificación y extracción de

bordes, la segmentación de la imagen es uno de los pasos más importante del método clásico para la extracción de las estructuras cardiacas [1].

Entre los métodos semiautomáticos de segmentación, las técnicas basadas en características de textura de la imagen prometen una adecuada segmentación de las cavidades cardiacas. Uno de estos algoritmos semiautomático es el de “Corrimiento de Media” (Mean-Shift) que ha presentado un buen desempeño al implementarse con otras técnicas de imagenología médica (RMN); y algunos de los resultados preliminares obtenidos en imágenes de ultrasonido han sido alentadores [1,5]. Con base en estas ideas, se planteó un proyecto de investigación en convenio con la UTC (Université de Technologie de Compiègne, Francia) y la UAM-I (Universidad Autónoma Metropolitana- Iztapalapa, México) para desarrollar un sistema de segmentación (basado en el algoritmo de corrimiento de media), extracción de bordes (contornos activos), y reconstrucción de las cavidades cardiacas empleando ecografía en tres dimensiones.

OBJETIVOS

El objetivo general de este proyecto de tesis fue lograr la segmentación de cavidades cardíacas en volúmenes ecográficos.

Para lograrlo se plantearon los siguientes objetivos específicos:

- Adecuar el método no paramétrico de corrimiento de media (Mean-Shift) para lograr una pre-segmentación de los volúmenes ecocardiográficos.
- Analizar los resultados parciales del método de presegmentación.
- Determinar la combinación óptima de términos de energía para el modelo de las superficies activas.
- Segmentar los volúmenes ecocardiográficos.
- Validar los resultados respecto a un experto clínico.

Capítulo 1 INTRODUCCIÓN A LA ANATOMÍA CARDIACA Y AL ULTRASONIDO EN CARDIOLOGÍA.

El corazón normal consta de cuatro cámaras, dos atrios (aurículas) y dos ventrículos. Los atrios están localizados por arriba de su respectivo ventrículo, y funcionan como conducto para proveer la sangre necesaria a las principales cámaras del corazón, los ventrículos. La función del ventrículo izquierdo y derecho es liberar la sangre al sistema circulatorio (el cuerpo) y al sistema pulmonar, respectivamente. La sangre del sistema venoso se colecta en el atrio izquierdo y luego se bombea al ventrículo izquierdo. El ventrículo derecho bombea la sangre a los pulmones a través de las arterias pulmonares para permitir el intercambio de gases. La sangre oxigenada deja los pulmones por medio de las venas pulmonares y viaja al atrio derecho y posteriormente al ventrículo derecho. El ventrículo derecho es la cámara más importante del corazón porque debe generar la presión necesaria para bombear la sangre a todo el cuerpo (Figura 1.1).

Las válvulas cardiacas están localizadas entre los atrios y los ventrículos (válvulas atrioventriculares), y en la dirección del flujo de la sangre en los ventrículos (válvulas semilunares). La función principal de las válvulas es asegurar la dirección del flujo sanguíneo, y por lo mismo hacer mas eficiente la función del corazón como bomba. Las válvulas atrioventriculares son la mitral (entre el atrio y el ventrículo izquierdo) y la tricúspide (entre el atrio y el ventrículo derecho) (Figura 1.2).

Las válvulas semilunares son las válvulas aórtica y pulmonar (Figura 1.2). La válvula aórtica está localizada a la salida del flujo sanguíneo del ventrículo izquierdo. La válvula pulmonar esta ubicada a la salida del flujo sanguíneo del ventrículo derecho.




Figura 1.1 Esquema del flujo sanguíneo a través de las cámaras cardiacas, los pulmones y el cuerpo. Abreviaciones: AI: atrio izquierdo; VI: ventrículo izquierdo; AP: arteria pulmonar; AD: atrio derecho; VD: ventrículo derecho [6].

Debido a su funcionamiento como bomba, el tejido cardiaco está formado principalmente por músculo (el miocardio). Un ciclo cardiaco consiste en el llenado pasivo de los dos atrios, la contracción de los atrios para llenar los ventrículos, y la contracción de los

ventrículos para propulsar la sangre hacia los pulmones (circulación pulmonar) y al cuerpo (circulación sistémica).

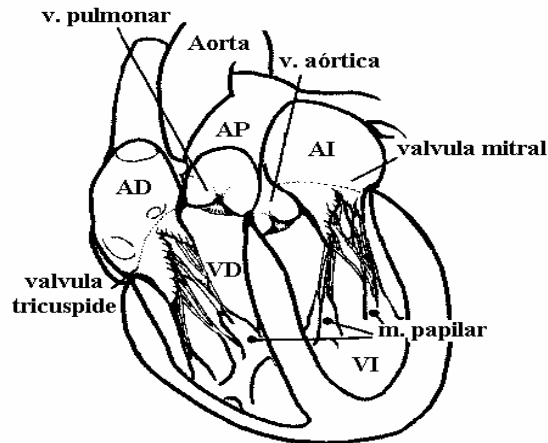


Figura 1.2 Ubicación de las válvulas atrioventriculares (válvulas mitral y tricúspide), válvulas semilunares (válvulas aórtica y pulmonar), y el aparato subvalvular para las válvulas atrioventriculares. Abreviaciones como en la Fig. 1.1 [6].

Durante la contracción ventricular, conocida como sístole, las válvulas semilunares se abren y la sangre es bombeada del ventrículo derecho a los pulmones y del ventrículo izquierdo al cuerpo entero. Mientras los atrios se llenan con sangre, las válvulas atrioventriculares se cierran. Durante la relajación ventricular, conocida como diástole, las válvulas atrioventriculares se abren y la sangre llena los ventrículos. Las válvulas semilunares ahora se cierran para permitir que la sangre recién eyectada viaje hacia los pulmones y el cuerpo; y para preparar a los ventrículos para la siguiente contracción.

Algunas técnicas de imagenología médica se han desarrollado para obtener un mejor diagnóstico de las cavidades cardiacas y como guía en procedimientos quirúrgicos. Entre estas técnicas se encuentra la resonancia magnética nuclear (RMN) que provee imágenes de alta calidad, en las cuales se pueden detectar pequeñas diferencias entre los tejidos; la tomografía axial computarizada (TAC) que permite, al igual que la resonancia magnética nuclear, la adquisición de cortes (rebanadas) del tórax, de las que se pueden extraer con precisión las cavidades cardiacas; y el ultrasonido (US) entre otras. Cada una de las técnicas anteriores es útil en diferentes situaciones clínicas debido a sus ventajas y desventajas asociadas. Por ejemplo, la resonancia magnética nuclear permite resaltar pequeñas variaciones en los tejidos a través de la manipulación de los parámetros generadores de pulsos, pero son adquiridas a un precio considerablemente alto para los hospitales, debido a su elevado costo de adquisición y mantenimiento [1,2].

El ultrasonido resulta ser la técnica mayormente empleada para la observación de las estructuras cardiacas. Las imágenes de ecografía poseen propiedades únicas que las distinguen de las imágenes médicas obtenidas mediante otras técnicas. En primer lugar, es posible visualizar estructuras en tejidos blandos, lo cual permite la identificación de los diferentes órganos, así como el diagnóstico de estados patológicos focalizados o difusos. Aunado a las propiedades anteriores es de menor costo en comparación con otras técnicas y permite monitorear cambios en la anatomía cardíaca en tiempo real [3].

A pesar de ser la técnica mayormente empleada en cardiología, el ultrasonido presenta algunas desventajas respecto a otras técnicas de imagenología. Las imágenes se forman al medir la reflexión del sonido y su dispersión en el tejido, cuyas interferencias dan un patrón característico (speckle) [6]. La información del eco depende de la posición del cono del ultrasonido, de la profundidad y ángulo de incidencia con el tejido y de los parámetros definidos por el usuario. Estos factores ocasionan que la imagen de ultrasonido obtenida sea altamente anisotrópica (propiedades físicas desiguales a lo largo de diferentes ejes) y con una relación señal a ruido variable en el espacio. Por otra parte, el ultrasonido no se propaga a través de una interfase aire – tejido; es decir, no se pueden obtener imágenes ecocardiográficas cuando el tejido pulmonar se encuentra entre el transductor y el corazón. Por lo anterior, las imágenes de ecocardiografía se obtienen mediante ciertas ventanas acústicas (el transductor se coloca en diferentes ubicaciones en el pecho del paciente, donde se puede alcanzar al corazón sin intervención del tejido pulmonar), debido a la limitación de estas ventanas se introducen fácilmente algunos artefactos [1,6], como la detección de falsos bordes en las estructuras cardiacas [7].

Dentro de la comunidad científica han sido realizados grandes esfuerzos para desarrollar nuevas tecnología de ecocardiografía 3-D durante la pasada década. En la primera generación de sistemas de ecografía en 3-D (3D Freescan), se incorporó un localizador espacial en el cono del ultrasonido para la reconstrucción tridimensional de la representación del corazón. Un dispositivo emisor de sonidos o de señales magnéticas posicionado en un transductor ultrasónico del tipo *manos- libres*, permitía el registro de la posición de cualquier plano 2-D por medio de un localizador externo para la reconstrucción posterior de la imagen. Para la reconstrucción se requerían de cinco a diez planos a través del corazón en cada ciclo cardiaco, lo cual limitaba el equipo a imágenes tridimensionales estáticas [8].

La segunda generación de sistemas de imagenología 3-D, desarrollado originalmente por Hewlet – Packard, utilizó un transductor que rotaba alrededor de un eje definido o se movía a lo largo de una ruta predefinida, obteniendo imágenes del corazón a intervalos regularmente espaciados. Las imágenes 2-D eran reconstruidas posteriormente para formar volúmenes en 3-D. Al obtener las imágenes 2-D en diferentes etapas del ciclo cardiaco, la reconstrucción posterior podía mostrar el movimiento del corazón. Sin embargo, la adquisición continuó siendo difícil de implementar y la reconstrucción consumía demasiado tiempo, y fuera de línea. Debido a estas limitaciones inherentes, este sistema no se aplicó clínicamente [8].

La tercera generación de imagenología volumétrica fue desarrollada con la introducción del ultrasonido 3-D en tiempo real (RT3D). Esta modalidad es principalmente diferente a las generaciones anteriores debido a que adquiere volúmenes reales, en vez de realizar una suma o interpolación de planos 2-D. Este sistema utiliza una matriz de transductores de 2.5MHz que consiste en arreglos bidimensionales que ofrecen guiar el curso del cono ultrasónico tanto en la elevación como en el azimut, permitiendo la adquisición de volúmenes piramidales a través del cuerpo [8].

Capítulo 2 SEGMENTACIÓN DE IMÁGENES ECOCARDIOGRÁFICAS.

Las imágenes segmentadas por computadora continúan siendo utilizadas rutinariamente en el campo de la medicina en una gran variedad de aplicaciones, como la cuantificación de volúmenes de tejido, diagnóstico, localización de patologías, estudios estructurales anatómicos y movimientos y deformaciones de las estructuras en el tiempo. Debido a las características intrínsecas de las imágenes de ecografía, la segmentación semiautomática de las cavidades cardiacas continúa siendo un gran reto. La presencia de ruido, artefactos producidos por la retrodispersión como la detección de falsos bordes; y la presencia de estructuras dentro de las cavidades como los músculos papilares y el aparato de la válvula mitral, que crean una gran cantidad de bordes no deseados en las imágenes ecocardiográficas; producen considerables dificultades cuando se aplican técnicas clásicas de segmentación como la detección de fronteras y la umbralización. Como resultado, estas técnicas fallan completamente o requieren alguna clase de etapa de post-procesamiento para remover objetos inválidos o falsos bordes en los resultados de la segmentación [6].

Para sortear estas dificultades, los modelos deformables han sido estudiados extensivamente y usados ampliamente en la segmentación médica de imágenes, con resultados prometedores. Algunos de los trabajos desarrollados sugieren métodos de segmentación de imágenes basados en el conocimiento previo de los bordes de las estructuras que se desean extraer, esta técnica se le conoce como los “Modelos de Apariencia Activa”. Los Modelos de Apariencia Activa (AAM) fueron propuestos por Cootes *et al.*[8] como una extensión de la técnica de los Modelos de Forma Activa (ASM), utilizada ampliamente en algunas otras técnicas de imagenología médica como la RMN.

Un AAM puede ser aplicado en la segmentación de imágenes a través del análisis por síntesis, minimizando la diferencia entre un modelo generado sintéticamente y la imagen real de la ecocardiografía utilizando parámetros estadísticamente ajustables. Un AAM modela la apariencia completa del objeto, incluyendo los artefactos típicos locales dependientes de la posición como los puntos espurios de las paredes laterales [3]. Como las imágenes de US son adquiridas generalmente en secciones cruzadas estandarizadas, los problemas típicos (estructuras falsas o bordes falsos) ocurren, en la mayoría de los casos, en la misma región de la imagen. Una técnica como los AAM pueden modelar estos efectos típicos locales. Además, los efectos del ruido son suprimidos por la promediación espacial y el análisis de los componentes principales (PCA). El método consiste de tres etapas: la generación de un modelo estadístico que describa la forma y la apariencia sobre un conjunto de imágenes con marcas normalizadas realizadas a mano; la determinación de la relación entre las pequeñas perturbaciones en los parámetros del modelo y el error resultante entre la imagen sintetizada y la real; y el establecimiento de un procedimiento para aplicar el modelo de apariencia a una imagen desconocida, y el ajuste iterativo de los parámetros del modelo a aquellos que mejor se ajusten a la imagen bajo investigación [3, 7, 9, 10]. La mayor limitación de los Modelos de Apariencia Activa es el requerimiento de la segmentación manual del conjunto de entrenamiento por un experto clínico. Este procedimiento es laborioso para imágenes bidimensionales y se vuelve más demandante en volúmenes tridimensionales [6].

Los contornos activos (víboras o snakes) fueron propuestos originalmente por M. Kass *et al.* [11] como un paso de regularización en los algoritmos de detección de bordes. Varias de

las técnicas presentes en la literatura están basadas en el uso de los contornos o superficies activas para la extracción de los bordes de las estructuras cardiacas [6,12]. Un contorno o superficie activa es un conjunto ordenado de puntos definidos en el dominio de la imagen que se pueden mover bajo la influencia de fuerzas internas y fuerzas externas, que son calculadas con la información de la imagen a segmentar [6]. El contorno o superficie inicial está posicionado de tal forma que minimiza una función de energía específica, en la que la energía externa atrae la víbora o el contorno a las características sobresalientes de la imagen; mientras que la energía interna suaviza la curva del contorno o víbora. El uso de esta técnica convierte a la extracción de bordes en un problema de minimización de energía [11].

El proceso de minimización de energía en los contornos o superficies activas para extracción de los bordes en ecocardiografías se implementa como una búsqueda iterativa del borde óptimo de la cavidad de interés. Para este propósito, se utiliza un algoritmo de descenso por gradiente. Es bien conocido que este tipo de algoritmo es altamente sensitivo a las condiciones iniciales, por lo que se requiere de puntos adecuados de inicialización. Si la curva no está lo suficientemente cerca de un contorno, no será atraída hacia éste; o su movimiento puede ser detenido por una región con ruido de alto gradiente. La convergencia del modelo de contorno o superficie activa al borde deseado en la imagen de US depende de varios factores como el conjunto de puntos iniciales, el nivel de ruido y la estrategia de optimización elegida. Para un desempeño óptimo del contorno o superficie activa es necesario un método de pre-segmentación que provea un contorno inicial cercano al borde de la estructura de interés [12].

La calidad de la imagen y los artefactos generados en la adquisición afectan directamente el proceso de presegmentación. La reducción del ruido resulta ser una tarea difícil de implementar, debido a su dependencia con las imágenes médicas. El problema consiste en remover el ruido sin perder información valiosa de la imagen. La presegmentación es usualmente precedida por alguna clase de operación de filtrado pasa-bajas para reducir la magnitud del ruido. Varios algoritmos se han propuesto para este propósito [4, 13].

La operación de filtrado mas comúnmente usada es el suavizado espacial en el dominio original de la imagen. En este proceso, cada píxel se reemplaza por una combinación lineal de sus vecinos espaciales y del píxel bajo estudio. Estos métodos de suavizado lineal tienen el efecto de suavizar tanto el ruido como los bordes de la imagen de US. Por esta razón, se han implementado varios algoritmos adaptivos y de suavizado no lineal, que han demostrado tener una mayor supresión de las características del ruido para ciertos tipos de ruido. En particular, un filtro de mediana elegido adecuadamente tiene la habilidad de remover el ruido impulsivo mientras preserva las transiciones en los bordes. El filtrado de mediana es frecuentemente aplicado en ecocardiografía, basado en la suposición que el ruido de moteado puede ser modelado como ruido impulsivo. Al igual que en el suavizado lineal, el suavizado por mediana se ha implementado usando ventanas de diferentes tamaños. A pesar de lo anterior, el ruido de moteado no tiene las características del ruido impulsivo, de hecho, se ha demostrado que este tipo de ruido sigue una distribución de Rayleigh, por lo que la utilidad del filtrado de mediana en imágenes de US es cuestionable [4].

La meta básica de la segmentación en ecocardiografía es encontrar los puntos de frontera entre la sangre y el tejido del miocardio [4]. Los algoritmos basados en el gradiente de intensidad entre píxeles no son adecuados para esta técnica de imagenología médica, debido a que las fronteras entre los diferentes tejidos son difusas. Los algoritmos de segmentación regional son los utilizados con mayor frecuencia en ecocardiografía. En este tipo de algoritmos de segmentación, la imagen es clasificada en regiones diferentes, como sangre y miocardio; y los puntos de frontera se definen por los bordes entre las regiones. Algunos trabajos previos han demostrado que los métodos de segmentación basados en características de textura de la imagen prometen una adecuada segmentación de las cavidades en las imágenes ecocardiográficas [1, 5, 14]. El análisis de la textura está basado en la suposición de que la estructura microscópica de diferentes tejidos define diferentes texturas en una imagen. En este contexto, “textura” se refiere a las propiedades estadísticas de la distribución de los niveles de gris de la imagen. Existe una gran posibilidad de medidas de textura, como las corridas estadísticas de los niveles de gris (corridas de gris), estadística de las diferencias entre los niveles de gris, y otras más. El enfoque general consiste en determinar experimentalmente un vector de características que mejor separen las estructuras de interés, luego se utiliza este vector para discriminar entre un tipo de tejido y otro [4]. La figura 2.1 muestra diferentes características de textura para una imagen de US de la médula espinal de un feto [5].




Figura 2.1 Diferentes características de textura en una imagen de Ultrasonido de la espina fetal [5].

Una vez que se generó el vector de características, el problema consiste en diseñar un clasificador que discrimine entre las diferentes regiones en la imagen de US. La clasificación o agrupamiento por medio del método de K-medias (K-means clustering) agrupa las regiones por medio de un proceso iterativo. En este procedimiento, los puntos de la imagen son clasificados de acuerdo a la mínima distancia Euclidiana entre cada uno de estos puntos y el centro de cada clase en el espacio de características de la imagen. Primero se determinan los puntos de siembra seleccionando los vectores de características correspondientes, que se localizan en el centro de las regiones divididas por igual en el espacio de características de la imagen; el número de semillas depende de las regiones en las que se desee clasificar la ecografía. Se toman los puntos de siembra actuales para clasificar todos los píxeles de acuerdo a la menor distancia Euclidiana entre sus vectores de característica y las semillas. Los puntos de siembra se recalculan después como el valor medio de todos los píxeles en la misma clase. Este proceso se repite hasta que el corrimiento de todas las medias es menor al de un umbral entre las iteraciones. La desventaja de este método consiste en la necesidad de fijar el número de regiones en las que se agruparán los datos, además de la necesidad de fijar los puntos de siembra iniciales [5].

Las Redes Neuronales Artificiales (ANN) son utilizadas como clasificadores para incrementar el desempeño de la clasificación [14]. La información a ser analizada se introduce a la red, que genera posteriormente alguna forma de decisión de salida. La red

incluye un gran número de coeficientes internos, que determinan el comportamiento actual de la red en cuanto a la toma de decisiones. Los valores de los coeficientes son determinados con el entrenamiento de la red, alimentándola con un conjunto de entrenamiento, y modificando iterativamente los coeficientes hasta obtener el mínimo error de clasificación. Las Redes Neuronales Artificiales tienen la capacidad de aproximar una función de mapeo mediante el aprendizaje a través de un conjunto de entrenamiento [4]. Su principal desventaja consiste en la elaboración del conjunto de entrenamiento, que consiste en un conjunto de imágenes de ecocardiografía segmentadas manualmente por un experto clínico, que implica un análisis laborioso y subjetivo; además de la necesidad de determinar las regiones en las que se desea particionar la imagen de US; todo lo anterior implica una gran interacción entre el usuario y el algoritmo de segmentación.

Anteriormente se propuso una técnica de segmentación basada en el pre-procesamiento de la imagen bidimensional mediante el filtrado de corrimiento de media, seguido por un modelo de contorno activo para el delineado final. En este trabajo se incluyeron las características de textura de la imagen como una etapa adicional en el pre-procesamiento [1]. El método de corrimiento de media, basado en un procedimiento de estimación por ventanas, es una técnica no paramétrica que calcula la función de densidad de probabilidad de un conjunto de datos. Las modas pueden ser calculadas moviendo iterativamente la información por medio de un vector de corrimiento de media, que apunta en la dirección del gradiente de la función de densidad, hasta que la magnitud de los corrimientos es menor a un umbral determinado. La calidad de la segmentación se controla por el ancho de la ventana tomando en cuenta el radio espacial, el radio de intensidad del eco y el radio de la característica de textura. Los resultados preliminares demuestran un buen delineado del contorno inicial, además de segmentar la ecocardiografía en regiones homogéneas con una alta correlación con las estructuras anatómicas [1].

Capítulo 3 METODOLOGÍA

Para lograr la segmentación de las cavidades cardiacas en los volúmenes ecográficos se propuso la siguiente metodología.

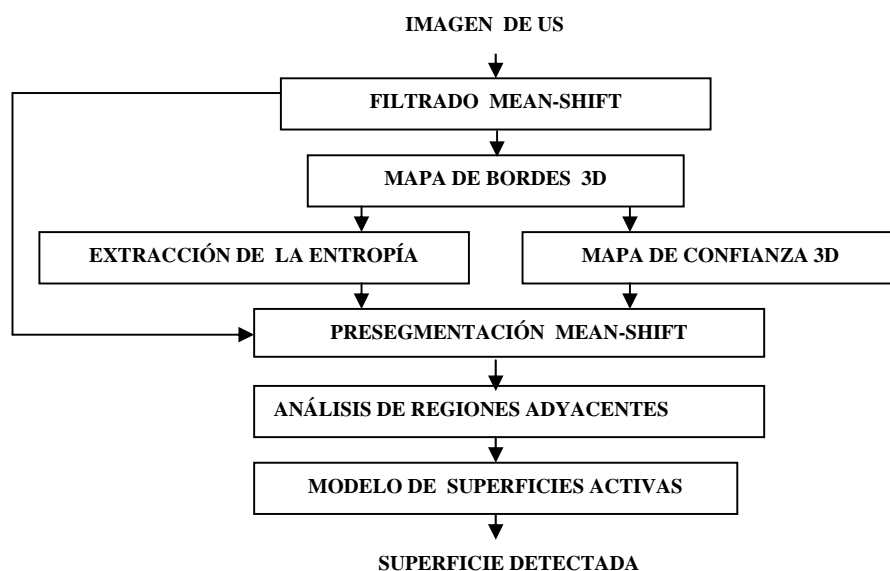


Figura 3.1 Metodología propuesta para la segmentación.

El proceso de filtrado, como ya se mencionó anteriormente, tiene la meta principal de reducir el ruido de moteado presente en las imágenes de ultrasonido. El mapa de bordes junto con la entropía y el mapa de confianza son las características de entrada para el proceso de presegmentación, que identifica regiones homogéneas en el espacio conjunto de intensidad del eco y de entropía. El análisis de regiones adyacentes fusiona las regiones que tienen características similares y como resultado se obtiene una superficie inicial que alimenta al Modelo de Superficies Activas, que ajusta la superficie inicial al borde real de la cavidad.

3.1 IMÁGENES

Para el presente proyecto se utilizó una muestra de 25 volúmenes ecocardiográficos 4D de tres estudios de pacientes diferentes, proporcionados por la UTC-Hospital de Amiens, Francia, estos volúmenes se adquirieron con un ultrasonido 4D del modelo SONOS 7500 manufacturado por Philips Medical Systems. La tabla 3.1 muestra las características de los estudios. Estas imágenes se obtuvieron en un formato binario.

| Propiedad | Estudio 1 | Estudio 2 | Estudio 3 |
|--|---------------------------|-------------------------|-----------------------|
| Tamaño del Volumen [X Y Z]. | 208x80x80 | 208x48x128 | 144x160x208 |
| Resolución Espacial [m]. | 0.00070x 0.00073x 0.00050 | 0.00048x0.00061x0.00040 | 0.0010x0.0010x0.00065 |
| No. de volúmenes del estudio. | 11 | 46 | 15 |
| Resolución Temporal (Periodo Adquisición) [s]. | 54.00x10 ⁻³ | 37.37x10 ⁻³ | 50.00 ⁻³ |
| No. de volúmenes segmentados. | 6 | 12 | 7 |

Tabla 3.1 Estudios ecocardiográficos en 4D.

La figura 3.2 muestra diferentes vistas bidimensionales de 2 volúmenes correspondientes al Estudio 1 y al Estudio 2, respectivamente.




Figura 3.2 Vistas bidimensionales de un volumen del Estudio 1 y del Estudio 2.

Se utilizaron los volúmenes 1 y 3 del estudio 1 para calibrar los parámetros de las diferentes etapas de la metodología propuesta. Los volúmenes restantes se utilizaron para validar la metodología.

3.2 FILTRADO POR CORRIMIENTO DE MEDIA (MEAN-SHIFT).

Corrimiento de Media (Mean-Shift) es un algoritmo que estima el gradiente de la función de densidad de probabilidad local para vóxeles similares. Este estimado de gradiente se usa junto con un procedimiento iterativo para encontrar los puntos máximos o modas de la función de densidad de probabilidad local. Todos los vóxeles que convergen al mismo máximo son entonces considerados como miembros del mismo segmento [15,16].

3.2.1 ESTIMADO DEL GRADIENTE DE LA FUNCION DE DENSIDAD DE PROBABILIDAD.

Sea $\{\bar{X}_i\}_{i=1..n}$ un conjunto arbitrario de n observaciones en el espacio Euclidiano d -dimensional R^d , pertenecientes a una función de densidad de probabilidad desconocida f . De acuerdo al conocimiento *a priori* de f se puede construir un estimado de la función de densidad de probabilidad \hat{f} basado en una estrategia no paramétrica.

El espacio de características en una imagen frecuentemente se caracteriza por grupos de datos muy irregulares cuyo número y forma no se encuentran disponibles. Lo anterior sugiere fuertemente la necesidad de emplear un método no paramétrico, que provea una detección consistente de los máximos locales de la función de densidad, para el análisis de las imágenes. La estimación de densidad de kernel es un método de estimación simple y consistente [21] que localiza los máximos locales de la función de densidad de probabilidad.

El *estimado multivariado de la función de densidad del kernel* obtenido con el kernel K y una ventana de radio h (también llamada ancho de banda), calculado en el punto \bar{x} d -dimensional, está definido por:

$$\hat{f}(\bar{x}) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{\bar{x} - \bar{X}_i}{h}\right) \quad (\text{Ec. 3.1})$$

donde \bar{x} es un vector de características que incluye la información espacial en X, Y, y Z; y la intensidad de los ecos (niveles de gris).

La calidad del estimado de densidad del kernel se mide con el error cuadrático medio entre la función de densidad de probabilidad y su estimado, integrado sobre el dominio de definición [17].

El kernel óptimo que minimiza este error es el kernel Epanechnikov [16, 17] dado por:

$$K_E(\bar{x}) = \begin{cases} \frac{1}{2} c_d^{-1} (d+2) (1 - \bar{x}^T \bar{x}) \rightarrow \text{si } \bar{x}^T \bar{x} < 1 \\ \text{cero} \rightarrow \text{en otro caso} \end{cases} \quad (\text{Ec. 3.2})$$

donde c_d es el volumen contenido en una esfera unitaria d -dimensional.

El uso de un kernel diferenciable permite definir el estimado del gradiente de la función de densidad como el gradiente del estimado de la función de densidad del kernel [17]

$$\hat{\nabla} f(\bar{x}) \equiv \nabla \hat{f}(\bar{x}) = \frac{1}{nh^d} \sum_{i=1}^n \nabla K\left(\frac{\bar{x} - \bar{X}_i}{h}\right) \quad (\text{Ec. 3.3})$$

Para el kernel de Epanechnikov el estimado del gradiente de la función de densidad está definido por [17,21]:

$$\begin{aligned} \hat{\nabla} f(\bar{x}) &= \frac{1}{n(h^d c_d)} \frac{d+2}{h^2} \sum_{\bar{X}_i \in S_h(\bar{x})} [\bar{X}_i - \bar{x}] \\ &= \frac{n_x}{n(h^d c_d)} \frac{d+2}{h^2} \left(\frac{1}{n_{\bar{x}}} \sum_{\bar{X}_i \in S_h(\bar{x})} [\bar{X}_i - \bar{x}] \right) \end{aligned} \quad (\text{Ec. 3.4})$$

donde la región $S_h(\bar{x})$ es una hipersfera de radio h y contiene un volumen $h^d c_d$, centrada en \bar{x} y contiene $n_{\bar{x}}$ puntos de información. El último termino de la ecuación 3.4

$$M_h(\bar{x}) \equiv \frac{1}{n_x} \sum_{\bar{X}_i \in S_h(\bar{x})} [\bar{X}_i - \bar{x}] = \frac{1}{n_x} \sum_{\bar{X}_i \in S_h(\bar{x})} \bar{X}_i - \bar{x} \quad (\text{Ec. 3.5})$$

se denomina *vector de corrimiento de media* [16,17,21].

La cantidad $\frac{n_x}{n(h^d c_d)}$ es el estimado de densidad del kernel $\hat{f}(\bar{x})$ calculado con la hiperesfera $S_h(\bar{x})$, por lo que la ecuación del estimado del gradiente de la función de densidad (Ec. 3.4) puede escribirse como:

$$\hat{\nabla}f(\bar{x}) = \hat{f}(\bar{x}) \frac{d+2}{h^2} M_h(\bar{x}) \quad (\text{Ec. 3.6})$$

por lo que el vector de corrimiento de media (Ec. 3.5) es:

$$M_h(\bar{x}) = \frac{h^2}{d+2} \frac{\hat{\nabla}f(\bar{x})}{\hat{f}(\bar{x})} \quad (\text{Ec. 3.7})$$

la expresión anterior demuestra que un estimado del gradiente normalizado se puede obtener calculando el vector de corrimiento de media en un kernel uniforme centrado en \bar{x} . El vector de corrimiento de media tiene la dirección del gradiente del estimado de la función de densidad en \bar{x} cuando este estimado se obtiene con el kernel Epanechnikov [16,17].

Como el vector de corrimiento de media siempre apunta hacia la dirección de máximo incremento en la densidad, se puede definir una ruta a un máximo local de la función de densidad, por ejemplo, a una moda de la función de densidad de probabilidad (figura 3.3).

En la siguiente figura se observa el vector de corrimiento de media que sigue una ruta hacia un punto estacionario en la función de densidad de probabilidad (máximo local de la FDP).




Figura 3.3 Cálculo sucesivo del corrimiento de media que define una ruta hacia un máximo local de la función de densidad [16].

El procedimiento de corrimiento de media, obtenido por el cálculo sucesivo del vector de corrimiento $M_h(\bar{x})$ y la translación de la ventana $S_h(\bar{x})$ en la dirección de $M_h(\bar{x})$ tiene garantizada la convergencia [16, 17].

3.2.2 IMPLEMENTACION EN IMÁGENES BIOMEDICAS.

La aplicación del procedimiento de corrimiento de media para imágenes biomédicas consiste de dos etapas. La primera etapa es definir una ventana cúbica de influencia para cada vóxel \bar{x}_i . Esta ventana define una medida de distancia intuitiva entre vóxeles. La segunda etapa iterativa del procedimiento asigna a cada conjunto de vóxeles un *vector de corrimiento de media* $M_h(\bar{x}_i)$, inicializado para que coincida con el vóxel. Estos *vectores de corrimiento de media* se modifican iterativamente de forma ascendente hacia el gradiente de intensidad de la función definida por la suma de todos los vóxeles hasta alcanzar un punto estacionario [16, 17].

Los vóxeles asociados al conjunto de *puntos de corrimiento de media* que migran al mismo punto estacionario son considerados como miembros del mismo segmento, es decir con la misma moda. La figura 3.4 muestra el resultado de este proceso, se puede observar en la parte plana de la figura derecha una de las modas a la que convergieron los vóxeles.

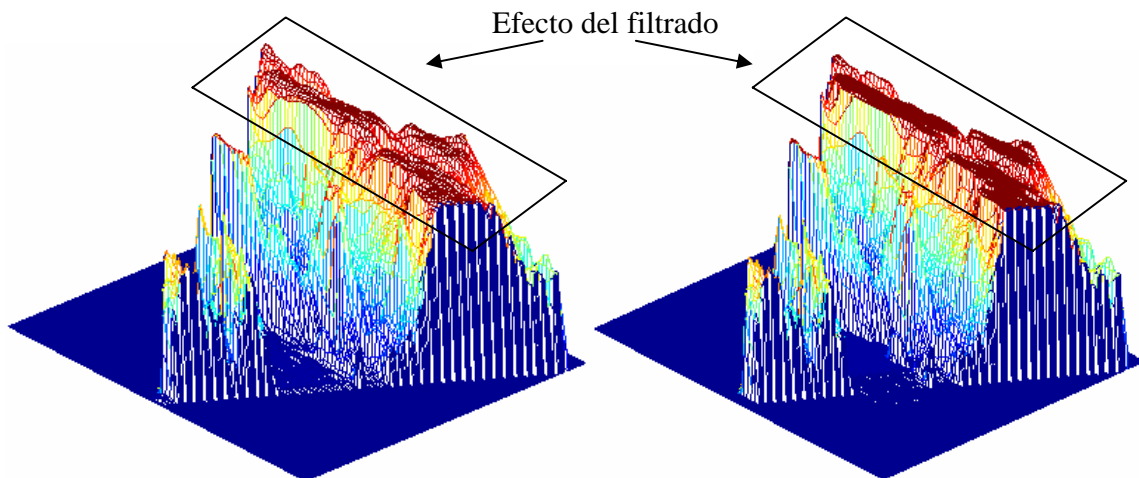


Figura 3.4 Imagen en intensidades del eco que muestran el proceso de filtrado por corrimiento de media (Izq. Imagen original, Der. Imagen filtrada). Se observan las regiones homogéneas a las que convergieron los datos.

El proceso de filtrado reduce el ruido de moteado en las imágenes de Ultrasonido, conservando los bordes de las estructuras cardíacas. La calidad del filtrado está determinada por el radio espacial y el radio de intensidad de la ventana, definido por (h) en la ecuación 3.7.

3.3 MAPA TRIDIMENSIONAL DE BORDES.

El cálculo del mapa tridimensional de bordes se realiza al convolucionar la imagen con un operador derivativo de la gaussiana, conocido también como Filtrado Óptimo de

Canny [18]. El valor de la magnitud del gradiente y su orientación se calculan utilizando una máscara tridimensional para cada una de las tres direcciones X, Y, y Z.

El kernel o máscara de convolución se calcula por medio de la primera derivada de una función gaussiana, los parámetros que definen la máscara son el tamaño de la ventana, que en el caso tridimensional es un cubo; y la varianza de la gaussiana. La varianza permite controlar las características de localización y la relación señal/ruido del filtro: un incremento de la varianza aumenta la relación señal/ruido, pero disminuye la capacidad de localización de los bordes y viceversa [18].

El mapa tridimensional de bordes se construye a partir del gradiente en las direcciones X, Y, y Z, calculando la magnitud del mismo en cada vóxel, es decir:

$$\text{magnitud_gradiente} = \sqrt{(\text{gradiente_X})^2 + (\text{gradiente_Y})^2 + (\text{gradiente_Z})^2}$$

3.4 CÁLCULO DE LA ENTROPIA DEL MAPA DE BORDES.

La textura de una región en una imagen está determinada por la forma en que los niveles de gris están distribuidos sobre los píxeles en esta región. Los valores de los píxeles son usados para construir estructuras numéricas que son asociadas al patrón de textura de la imagen. Este patrón está basado principalmente en la interrelación entre un píxel y sus vecinos.

Generalmente, el problema de la discriminación por textura basado en métodos estadísticos consiste en el análisis de un conjunto de matrices de co-ocurrencia. En estas matrices, los índices de las filas y las columnas representan el rango dado de los niveles de gris de la imagen, y el valor $P(i, j)$ almacenado en la posición (i, j) es la frecuencia de la ocurrencia de los niveles de gris i y j , a una distancia dada y en una dirección dada. Por ejemplo, supongamos que se tiene la imagen representada por sus niveles de gris mostrada en la figura 3.5. Tomando la dirección 0° y la distancia 1, se obtiene la matriz de co-ocurrencia mostrada a la derecha de la figura. Para este ejemplo, el valor de la co-ocurrencia $P(0,1) = 8$ fue calculado por la exploración de los niveles de gris de la matriz y, para cada píxel con un valor de cero, su vecino izquierdo y derecho más cercano fue revisado y $P(0,1)$ se incrementa cuando un valor de uno fue hallado [19].




Figura 3.5 Imagen cuantificada en 3 niveles de gris, muestreada en 5x5 píxeles y su matriz de co-ocurrencia para la dirección = 0° y distancia = 1 [19].

Una vez que se tiene la matriz de co-ocurrencia, se pueden obtener diferentes propiedades de la distribución de los píxeles aplicando operaciones matemáticas sobre los valores de la matriz. Estas operaciones son llamadas descriptores. Cada descriptor está relacionado con alguna característica visual en particular sobre la textura.

La entropía es un descriptor que define la suavidad de la imagen y se calcula con la siguiente operación matemática [19]:

$$\text{Entropía} = -\sum_i \sum_j P(i, j) \log P(i, j)$$

Para el cálculo de la entropía del mapa de bordes, se calcula la matriz de co-ocurrencia de distancia uno para un muestreo de la imagen del mapa de bordes tridimensional de tamaño 5x5x5. La matriz de co-ocurrencia se calcula para las direcciones X, Y, y Z; como se muestra en la figura 3.6.




Figura 3.6 Ventana de muestreo del mapa de bordes tridimensional de tamaño 5x5x5 donde se indican las direcciones en las que se calculó la matriz de co-ocurrencia para una distancia de 1.

Una vez que se calculó la matriz de co-ocurrencia para las diferentes direcciones, se realizó el cálculo de la entropía para cada uno de las muestras en las que se dividió el mapa de bordes tridimensional. Posteriormente se interpolaron linealmente los datos para obtener una imagen de las dimensiones del volumen original.

3.5 MAPA TRIDIMENSIONAL DE CONFIANZA.

La información que provee la magnitud del gradiente es inherentemente ambigua debido al producto de dos factores: la influencia del patrón de los datos y el tamaño del borde (discontinuidad). La ambigüedad puede ser reducida significativamente si la similitud entre el patrón de los datos y un modelo de borde ideal es calculada usando información no empleada en el cálculo de la magnitud del gradiente [20] (figura 3.7).

Para el cálculo del mapa de confianza se utiliza un estimado de la orientación del gradiente del vóxel analizado, para generar una máscara de borde ideal (**t**) de 5x5x5 vóxeles (figura 3.7 (c)), y centrada en el vóxel bajo estudio (**d**) (figura 3.7(a)). Esta ventana cúbica se correlaciona con los datos del mapa de bordes (figura 3.7 (b)) para computar una medida de confianza (η) [20].

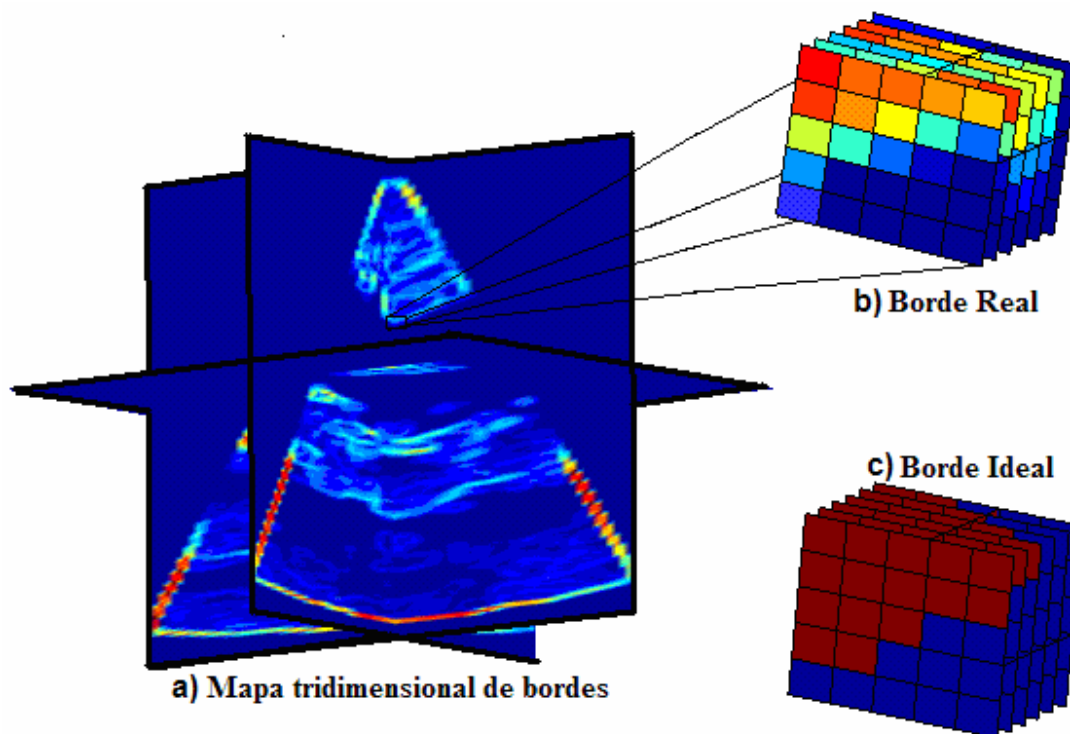


Figura 3.7 Cálculo del mapa de confianza en tres dimensiones. a) Mapa de bordes 3D, b) borde real centrado en el vóxel, c) borde ideal calculado a partir de la orientación del gradiente del vóxel.

La medida de confianza (η) para la presencia de un borde en el vóxel analizado, puede ser definida como el valor absoluto del coeficiente de correlación entre los datos normalizados (\mathbf{d}) y el modelo ideal de borde (\mathbf{t}).

$$\eta = |\mathbf{t}^T \mathbf{d}|$$

La medida de confianza incorpora información, tanto de los datos como del modelo de borde ideal; información que no se encuentra presente en el subespacio del gradiente, por lo que η provee un estimado independiente de la presencia del borde asumido por el modelo en la ventana de procesamiento. Esta medida de confianza tiene la ventaja de ser independiente de la magnitud del gradiente [20].

Para el cálculo de la medida de confianza se realiza un ventaneo centrado en el vóxel bajo estudio del mapa de bordes tridimensional. Los datos dentro de la ventana cúbica son normalizados teniendo una media cero y una norma uno de Frobenius. Después se obtiene la medida de confianza para el vóxel.

La medida de confianza asume que el borde pasa por el centro de la ventana y que el modelo de borde ideal es generado bajo la misma suposición. Para calcular la dirección del borde ideal se utiliza un estimado de la orientación del gradiente del vóxel analizado. Este cálculo se realiza en cada vóxel de la imagen, exceptuando en los extremos del volumen. Un vóxel tiene una medida de confianza solo cuando la magnitud normalizada del gradiente asociada es mayor al de un umbral fijo.

El mapa de confianza (MC) en tres dimensiones se calcula para cada vóxel, como una combinación lineal de la magnitud normalizada del gradiente (ρ) y la medida de confianza del borde:

$$MC = \beta\rho + (\beta - 1)\eta \quad (\text{Ec. 3.8})$$

donde β es una constante entre 0 y 1 que controla la mezcla entre la magnitud del gradiente ρ y la información del patrón local η [21].

3.6 PRESEGMENTACIÓN POR CORRIMIENTO DE MEDIA.

Para la presegmentación por corrimiento de media, se utilizó un algoritmo modificado del corrimiento de media, similar al empleado en la etapa de filtrado. En el caso del filtrado, el vector de características está formado únicamente por la intensidad del eco (nivel de gris) y la información espacial; para la presegmentación se incluyeron los mismos parámetros, además de la información proporcionada por la entropía del mapa de bordes 3D. El vector de características para la presegmentación es:

$$\text{vector_de_características} = \begin{bmatrix} x \\ y \\ z \\ \text{entropía_mapa_de_bordes} \\ \text{nivel_de_gris_imagen_filtrada} \end{bmatrix}$$

Este nuevo estimado del corrimiento de media se obtiene al ponderar cada vóxel dentro de la región con una función de su nivel de confianza (MC), los voxels que se encuentran cerca de un borde (confianza del borde ≈ 1) son menos influyentes para la determinación del nuevo centro de la ventana [21]. Este procedimiento de corrimiento de media ponderado se aplica en el dominio conjunto (espacial, intensidad del eco y de entropía).

Al igual que el filtrado por corrimiento de media, en la presegmentación se calculan las modas de los máximos locales, definidos por el nivel de gris y la entropía del mapa de bordes. La calidad de la presegmentación está controlada por un radio espacial h_s , un radio de intensidad h_i , y un radio de entropía h_e , que corresponden a los parámetros de resolución del estimado del kernel en el dominio rango-espacial. Esta etapa provee regiones homogéneas en una imagen presegmentada [1].

El vector de corrimiento de media ponderado es:

$$M_h(\bar{x}) \equiv \frac{1}{\sum 1 - w_i} \sum_{\bar{x}_i \in S_h(\bar{x})} [1 - w_i] \bar{X}_i - \bar{x}$$

donde w_i representa la medida de confianza de cada vóxel, que se calculó al construir el mapa de confianza (Ec. 3.6) y \bar{x} es el vector de características [1].

El resultado de este proceso es un volumen con dos componentes asociadas para cada vóxel; una componente con la información de la intensidad del eco y la otra con la información de la entropía.

3.7 ANÁLISIS DE REGIONES ADYACENTES.

El delineado de las regiones obtenidas en la presegmentación puede ser refinado incorporando un Grafo de Regiones Adyacentes (GRA) que es simplificado posteriormente con un algoritmo de *búsqueda-fusión* como se describe a continuación.

3.7.1 ETIQUETADO

Una vez que se obtiene una imagen presegmentada se agrupan todas las regiones que se encuentran cercanas en el espacio de características, es decir, todos los vóxeles que convergieron al mismo punto son fusionadas y etiquetadas.

3.7.2 CERRADURA TRANSITIVA

La forma mas sencilla de representar un grafo es la llamada matriz de adyacencia, en la que se establecen valores booleanos para indicar si existe un borde entre las regiones. Para construir la matriz de adyacencia, cada etiqueta de la imagen presegmentada se considera como un vértice y se le asigna un valor de 1 a las etiquetas adyacentes y un valor de cero en otro caso [21].

Para fusionar regiones adyacentes homogéneas que han sido separadas por el proceso de presegmentación se utiliza una operación de cerradura transitiva sobre el GRA. Esta operación liga regiones que: tienen modas asociadas dentro de una distancia no mayor de $h/2$ y $h_e/2$ y satisfacen la condición de tener un borde débil entre ellas. La medida de fortaleza del borde se obtiene directamente del mapa de confianza sumando los valores de confianza de los vóxeles que se encuentran sobre el borde que separa las regiones. Cuando esta medida es menor a un umbral determinado (ϵ) las regiones son fusionadas finalmente. Se aplica un procedimiento de *búsqueda-fusión* sobre el GRA para encontrar las etiquetas conectadas en el grafo. Este procedimiento de cerradura transitiva y búsqueda-fusión se aplica iterativamente hasta que el número de regiones entre iteración permanece sin cambio [21].

3.7.3 PODADO DE REGIONES

Una vez que se obtuvo la imagen fusionada, se aplica un proceso de podado para remover todas las regiones cuyo volumen es menor a un tamaño mínimo establecido (ϕ). Para realizar esta remoción, se unen las regiones cuyo volumen es menor a ϕ con una

región adyacente con una distancia mínima entre sus modas, o con una región que sea la única adyacente y con un volumen mayor al del umbral. El proceso de podado se repite iterativamente hasta que el número de regiones permanece sin cambio, o un número dado de iteraciones es alcanzado [21].

Las regiones obtenidas se usan para definir la superficie inicial para el delineado final de la cavidad cardiaca de interés que se obtiene en la siguiente etapa de procesamiento.

3.8 MODELO DE SUPERFICIES ACTIVAS (MSA).

La superficie obtenida se alimenta a un modelo de superficie activa como información inicial. Este modelo incluye una interpolación cúbica splines que encuentra la superficie óptima iterativamente con un procedimiento de descenso por gradiente. Los términos de energía externa usados en esta etapa son el mapa de confianza 3D (MC) y la componente de entropía (CE) de la presegmentación por corrimiento de media. El término de energía esta definido como:

$$E_{MSA}(v) = E_{int} + E_{ext} = \sum_v (\alpha \|v\|^2 + \beta \|v'\|^2 + \gamma E_{MC}(v) + \delta E_{CE}(v))$$

donde $\alpha \|v\|^2 + \beta \|v'\|^2$ son los términos que describen la energía interna, que está definida por las características deseadas de elasticidad y rigidez del modelo y la formulación explícita de la superficie en términos de una interpolación con splines cúbicos [1, 12]; $E_{MC}(v)$ y $E_{CE}(v)$ son los termino de energía externa, definidos por el mapa de confianza y la componente de entropía respectivamente. α , β , γ , y δ son los pesos asignados a cada una de las componentes de modelo.

3.9 DESEMPEÑO DEL PROCEDIMIENTO

El desempeño del procedimiento completo se calculó por medio del Índice de Tanimoto (TI) [22] comparando los resultados de la segmentación con un delineado manual realizado por un experto clínico. Este parámetro se calculó de la siguiente forma:

$$TI = \frac{\|BCI \cap BRI\|}{\|BCI \cup BRI\|}$$

donde BCI es una Imagen Binaria Calculada al rellenar la superficie final obtenida con el procedimiento y BRI es una Imagen Binaria de Referencia segmentada por el experto clínico.

Capítulo 4 RESULTADOS Y DISCUSIÓN

4.1 FILTRADO

En el proceso de filtrado los parámetros que se ajustaron fueron el radio espacial y el radio de intensidad del eco o nivel de gris, los cuales fueron de 5 y 10 respectivamente. A continuación se muestran los resultados obtenidos para diferentes volúmenes de los tres estudios que se procesaron con los mismos parámetros. Para propósitos de visualización solo se muestra una vista bidimensional de un corte longitudinal.




Figura 4.1 Cortes longitudinales de los resultados obtenidos con el proceso de filtrado para tres estudios diferentes. A la izquierda se observan los volúmenes sin procesar y a la derecha los resultados obtenidos con el proceso de filtrado.

El proceso de filtrado reduce el ruido de moteado como se observa en la figura 4.1 (b), (d), (f). En las imágenes que presentan un nivel bajo de ruido (figura 4.1 (a), (e)), el efecto de esta etapa no se percibe en los resultados (figura 4.1 (b), (f)), en el caso de imágenes con un nivel alto de ruido, éste se reduce en gran medida al aplicar el filtrado por corrimiento de media (figura 4.1 (c), (d)). La mayor ventaja de este tipo de filtrado es la preservación de los bordes en la imagen, que mejora los resultados obtenidos en las siguientes etapas de procesamiento. En esta etapa de pre-procesamiento existe una relación directa entre el tiempo de procesamiento y el radio espacial y de intensidad del eco.

4.2. MAPA DE ENTROPIA OBTENIDA DEL MAPA TRIDIMENSIONAL DE BORDES.

El mapa tridimensional de bordes de los volúmenes preprocesados se obtuvo con un filtrado espacial de Canny, utilizando una ventana cúbica de $3 \times 3 \times 3$ y una varianza de $\sigma^2=0.5$, este tipo de filtrado también se conoce como filtro derivativo de la gaussiana. Como se menciona en la metodología, el mapa de entropía se calculó a partir de las matrices de co-ocurrencia en las direcciones X, Y, y Z para una distancia de uno, utilizando un ventaneo de $5 \times 5 \times 5$ sobre el mapa de bordes.

La figura 4.2 muestra el mapa de entropía para tres estudios diferentes, los volúmenes son los mismos a los presentados en la figura 4.1. Se observa en las imágenes con poco ruido de moteado (figura 4.1 (a), (e)), que las cavidades se distinguen sobre las demás estructuras cardiacas (figura 4.2 (a), (b), (e), (f)). En la figura 4.2 (a) se observa el efecto del ventaneo en la sombra del cono ultrasónico.

En la figura 4.2 (c) y (d) difícilmente se distingue alguna estructura cardiaca en el mapa de entropía. Los valores altos de entropía predominan en la mayor parte de la imagen. Lo anterior se debe a que las fronteras entre la sangre y el miocardio son difusas, además de que la imagen sin procesar presenta un nivel alto de ruido de moteado (figura 4.1(c)).

4.3. MAPA DE CONFIANZA 3D.

El mapa de confianza 3D se calculó utilizando un factor de mezcla (β) de 0.35. Como se observa en la figura 4.3, los niveles de confianza se encuentran entre cero y uno, donde un valor cercano a cero indica la ausencia de algún borde y un valor cercano a uno la presencia de un borde fuerte en la región.

Como sucede en el mapa de entropía las imágenes con poco ruido de moteado presentan un mapa de confianza 3D con los bordes de las cavidades bien definidos (figura 4.3 (a), (c)). La figura 4.3 (b) muestra un mapa con bordes difusos y discontinuos debido a la presencia de ruido en la imagen preprocesada (figura 4.1 (d)), se observa que los bordes debidos al ruido son débiles, mientras que las fronteras entre la sangre y el miocardio presentan bordes con mayor fortaleza. En la figura 4.3 (c), los bordes que rodean las cavidades se distinguen con facilidad; aunque en algunos casos, estos bordes no son continuos o son muy débiles.

La fortaleza o debilidad de un borde en las cavidades cardiacas es el factor más importante en alguna de las etapas posteriores, como en el análisis de regiones adyacentes donde las regiones con fronteras débiles son fusionadas.

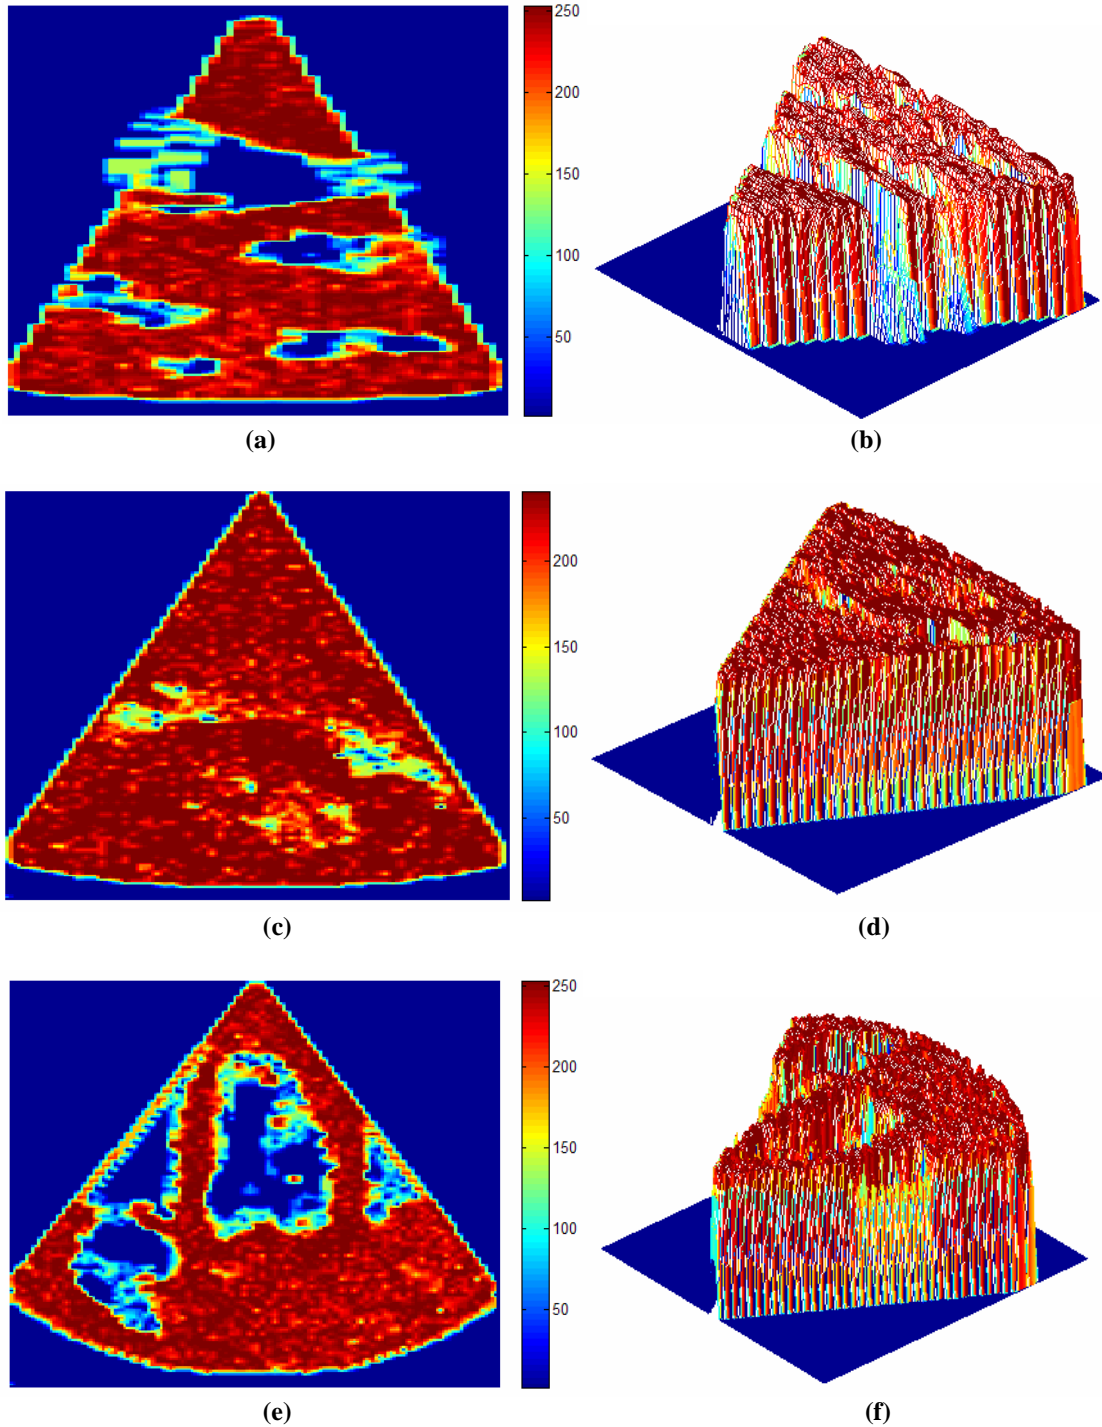


Figura 4.2 Corte longitudinal del mapa tridimensional de entropía obtenido del mapa de bordes. Se presenta el mapa de entropía de los tres estudios presentados en la figura 4.1. (a), (c) y (e) presentan el mapa de entropía. (b), (d) y (f) muestran los niveles de entropía.




Figura 4.3 Corte longitudinal del mapa de confianza 3D para los tres estudios presentados en la figura 4.1.

4.4. PRESEGMENTACIÓN POR CORRIMIENTO DE MEDIA

En la figura 4.4 (a) se observa un corte longitudinal que corresponde al estudio presentado en la figura 4.1(a) y la componente de intensidad del eco resultado de la presegmentación por corrimiento de media (figura 4.4 (b)). En esta figura se observan algunas regiones homogéneas, estas regiones son conjuntos de datos o vóxeles que convergieron a la misma moda por lo que se puede decir que pertenecen al mismo segmento. Cada vóxel tiene asociado una componente de intensidad y una componente de entropía, resultado del proceso de presegmentación al incorporar la información espacial, la de intensidad del eco y de la entropía en el vector de características.




Figura 4.4 Resultado del proceso de presegmentación. (a) Intensidad del eco en la imagen sin procesar, (b) componente de intensidad resultado del corrimiento de media que muestra regiones homogéneas a las que convergieron los datos (modas locales).

En la figura 4.5 se observan las dos componentes asociadas al resultado de la presegmentación para un volumen de cada uno de los estudios presentados en la figura 4.1. El proceso de presegmentación entrega un resultado vectorial, donde cada dato se representa por un vector bidimensional; un valor representa la moda local de intensidad y el segundo representa la moda de entropía a la que convergieron los datos.

Para esta etapa los parámetros a controlar son el radio espacial, de intensidad y de entropía que fueron de 10, 15 y 190 respectivamente. Los parámetros se calibraron con dos volúmenes del estudio uno. Una vez calibrados estos parámetros, se utilizaron sin modificar para el resto de los volúmenes.




Figura 4.5 Resultado de la presegmentación. Izquierda, componente de intensidad del eco. Derecha, componente de entropía.

4.5. ANALISIS DE REGIONES ADYACENTES.

El análisis de regiones adyacentes se realizó en tres etapas. El etiquetado consiste en agrupar las regiones que convergieron a la misma moda en entropía y en intensidad y

asignar una etiqueta a cada región. En esta etapa, el número de regiones que se encontraron en todos los estudios fueron arriba de 100,000.

Después de etiquetar las regiones se realizó una operación de cerradura transitiva que fusiona regiones con modas dentro de un radio de intensidad y de entropía definido; y con un borde entre ellas menor al de un umbral fijo. Para los tres estudios se utilizó un radio de intensidad de 10 y un radio de entropía de 30. El parámetro más importante en esta etapa es el umbral del borde para fusionar regiones, que se debe de ajustar a las características de cada estudio ecocardiográfico. De hecho, la fortaleza del borde es el parámetro más sensible en el análisis de regiones adyacentes, ya que si el borde es muy débil y el umbral es grande se corre el riesgo de fusionar las cavidades con el tejido del miocardio o con otra cavidad como se observa en la figura 4.6 (d).

Finalmente, el podado se utiliza para fusionar regiones con un número de vóxeles menor a un umbral fijo. La siguiente figura muestra las regiones etiquetadas del análisis de regiones adyacentes coloreadas con una paleta aleatoria para poder distinguir las etiquetas de las diferentes regiones.

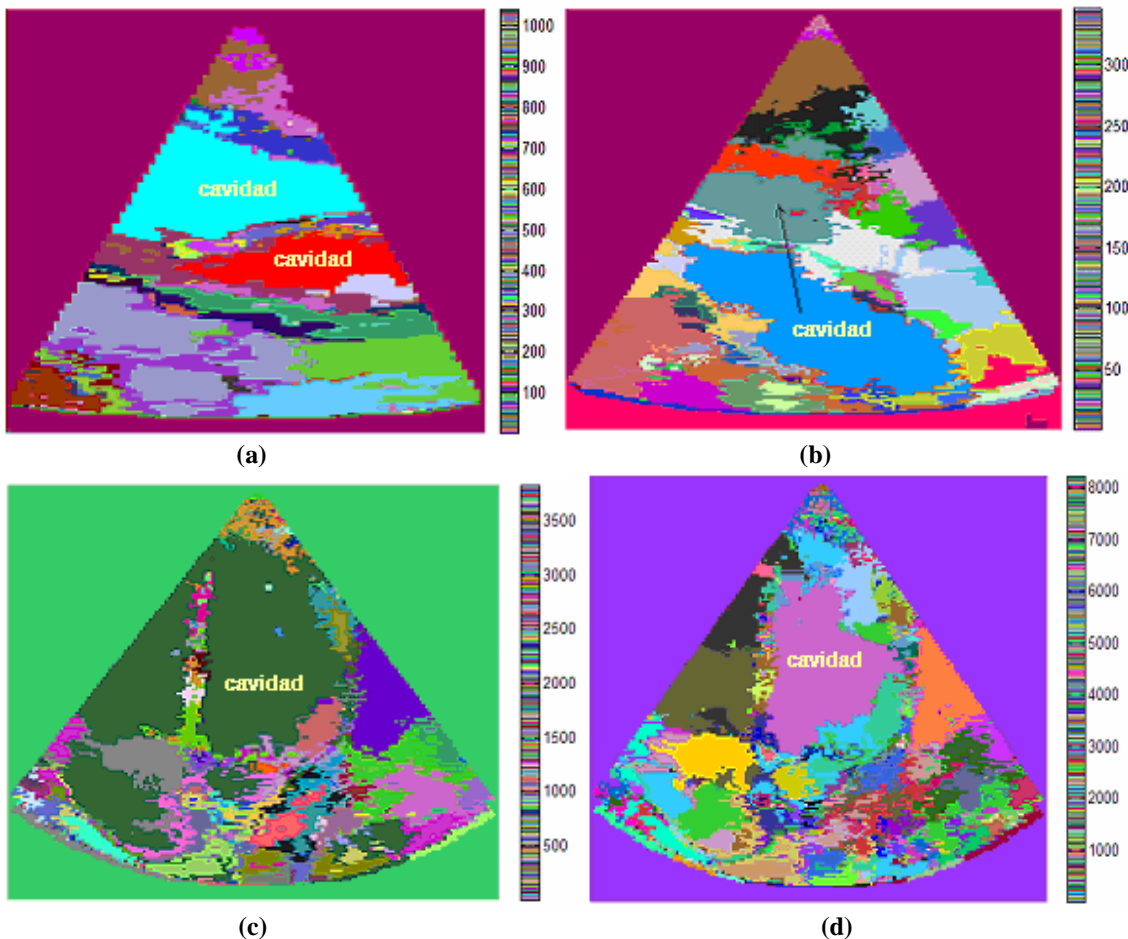


Figura 4.6 Regiones etiquetadas, resultado del análisis de regiones adyacentes. Las imágenes se colorearon con una paleta aleatoria para poder distinguir las diferentes regiones. Se observan las cavidades definidas por una etiqueta única.

Para el estudio uno y dos (figura 4.6 (a), (b)) los parámetros utilizados en esta etapa fueron los mismos, siendo el umbral para fusionar regiones (confianza del borde entre las regiones) de 0.8. Al aplicar los mismos parámetros a un volumen del estudio tres, las cavidades se fusionaron con otras estructuras cardiacas, o entre estas mismas (fig. 4.6 (c)). Este efecto se debe a que el borde entre las diferentes regiones es muy débil o se encuentra discontinuo, como se mencionó al obtener el mapa de confianza 3D. Para obtener el resultado de la figura 4.6 (d), el umbral para fusionar regiones se ajustó a un valor de 0.5. Se observa en los resultados (fig. 4.6 (a), (b) y (d)) que las cavidades se encuentran bien definidas, además de que el número de regiones se redujo en forma considerable, de más de 100,000 a menos de 10,000.

4.6 MODELO DE SUPERFICIES ACTIVAS (MSA).

La superficie inicial para el MSA se obtiene de los bordes de las regiones etiquetadas en la etapa anterior. En el MSA el término de energía está definido como:

$$E_{MSA}(v) = E_{int} + E_{ext} = \sum_v (\alpha \|v\|^2 + \beta \|v'\|^2 + \gamma E_{MC}(v) + \delta E_{CE}(v))$$

donde los parámetros a controlar son α , β , γ , δ ; y el paso de descenso de gradiente μ .

Los términos de energía externa que se evaluaron en esta etapa, fueron: la componente de intensidad resultado de la presegmentación, la componente de entropía resultado de la presegmentación y el mapa de confianza, siendo la componente de entropía y el mapa de confianza los que presentaron mejor desempeño en el MSA. Estos parámetros ajustaron más suavemente y adhirieron mejor la superficie al borde de la cavidad.

Estos parámetros se eligieron debido a que el mapa de confianza tiene valores máximos en los bordes de las cavidades lo que obliga al modelo a adherirse a estos bordes, de igual forma la componente de entropía resultado de la presegmentación permite al MSA ajustarse al borde de la cavidad.

Los parámetros utilizados en esta etapa se muestran en le apéndice A.




Figura 4.7 Contorno inicial (rojo) y final (amarillo) sobre un corte longitudinal del volumen sin procesar. Los contornos pertenecen a una rebanada de la superficie inicial y final.

La figura 4.7 muestra el contorno inicial (rojo) y el contorno final (amarillo) sobre una rebanada del volumen sin procesar. Los contornos se obtuvieron al particionar una rebanada de la superficie inicial y final.




Figura 4.8 Contorno final sobre un corte longitudinal del volumen segmentado manualmente por el experto clínico en diferentes etapas del ciclo cardiaco.. a) y b) pertenecen al estudio 1. c) y d) pertenecen al estudio 2. e) y f) pertenecen al estudio 3. Los contornos pertenecen a una rebanada de la superficie final.

Los resultados obtenidos muestran que el MSA suaviza los contornos de la superficie inicial. En el caso de que la superficie inicial sobreestime la cavidad (figura 4.7 (c)), el MSA ajusta la superficie al contorno de la cavidad.

La figura 4.8 muestra el contorno final, resultado del proceso completo de la segmentación, sobre la imagen segmentada manualmente por el experto clínico. Los resultados demuestran que la superficie final obtenida se aproxima al borde detectado por el experto clínico figura 4.8 (a) y 4.8 (c).

Cuando las válvulas se abren durante el ciclo cardiaco (figura 4.8 (b), (d) y (f)), la superficie calculada por el procedimiento difiere de la calculada por el experto clínico, excepto en el estudio 3 (figura 4.8 (f)). En el caso del estudio 1 la superficie se subestima, mientras que en el caso del estudio dos, se sobreestima al superficie final. Lo anterior debido al efecto de las válvulas sobre el procesamiento de los volúmenes.




Figura 4.9 Superficie final sobre el volumen de la ecocardiografía sin procesar.

La figura 4.9 muestra la superficie final obtenida con el proceso completo de segmentación sobre el volumen sin procesar. En la figura 4.9 (a) y (b) se observa el resultado obtenido para el estudio uno en diferentes etapas del ciclo cardiaco. La superficie final se ajustó al contorno del ventrículo en las diferentes etapas. En la figura 4.9 se muestra la superficie final obtenida para un volumen de los estudios 2 y 3. En el caso del estudio 3 (figura 4.9 (d)) el ruido presente en la ecocardiografía afectó el resultado del delineado final de la cavidad.

4.7. DESEMPEÑO DEL PROCEDIMIENTO

Para medir el desempeño del procedimiento propuesto se calculó el Índice de Tanimoto (TI) contra las imágenes segmentadas manualmente por un experto clínico. Para el estudio uno el promedio del IT fue de 0.656 ± 0.109 , para el estudio dos el promedio del IT fue de 0.581 ± 0.101 y para el estudio tres el promedio del IT fue de 0.573 ± 0.105 .

Al medir el desempeño del procedimiento de segmentación, algunos de los volúmenes presentaron un IT de 0.85, mientras que otros volúmenes presentaron un IT muy bajo, del orden 0.37. Una de las razones por las que el IT fue muy bajo en algunos volúmenes es la presencia de ruido en las imágenes ecocardiográficas. La superficie inicial generada por la presegmentación difícilmente se aproxima al borde detectado por la segmentación manual del experto clínico en la presencia de regiones con un nivel alto de ruido de moteado, o regiones muy grandes que presenten este fenómeno.

Recordemos que parte del efecto de la retrodispersión es la generación de bordes o estructuras falsas en las imágenes médicas (figura 4.10). Estos bordes o estructuras que no pertenecen a las estructuras cardiacas, continúan presentes en todas las etapas del proceso de segmentación y detección de bordes, por lo que el resultado del proceso entrega un IT muy por debajo en comparación con otros volúmenes que no presentan estas características.




Figura 4.10 Generación de bordes o estructuras falsas efecto de la retrodispersión. a) Superficie final sobre el volumen sin procesar donde se observa una estructura falsa efecto de la retrodispersión. b) Superficie final sobre la segmentación manual del experto clínico.

CONCLUSIONES

En el presente trabajo se propuso una nueva metodología para la segmentación de las cavidades cardíacas en volúmenes ecocardiográficos. La metodología consistió de una etapa robusta de presegmentación con el algoritmo de corrimiento de media, combinado con un Modelo de Superficies Activas para obtener un delineado final de las cavidades.

Los resultados obtenidos demostraron que la etapa de pre-procesamiento provee una buena frontera inicial entre la sangre y el tejido del miocardio. El método de corrimiento de media localiza adecuadamente regiones homogéneas en los volúmenes ecocardiográficos. La superficie inicial que se obtiene en esta etapa, se encuentra muy cercana a la superficie real detectada por la segmentación manual del experto clínico.

El Modelo de Superficies Activas suaviza la superficie inicial obtenida con la presegmentación, además de ajustar la superficie final al borde de la cavidad. Los resultados demuestran que el Modelo de Superficie Activa modifica muy poco la superficie inicial generada en la etapa anterior.

Para evaluar el desempeño de la metodología se utilizó el Índice de Tanimoto, en algunos de los volúmenes este parámetro se acercó al 0.85 computado sobre la segmentación manual del experto clínico, que es un indicador del buen desempeño del procedimiento para estos volúmenes. En algunos casos el Índice de Tanimoto estuvo cercana al 0.35, debido a que en algunos momentos del ciclo cardíaco, cuando las válvulas se abren, la superficie final obtenida por el procedimiento difiere en gran medida la superficie real de las cavidades, obtenida por la segmentación del experto clínico, debido principalmente al efecto de las válvulas sobre los volúmenes ecocardiográficos.

Uno de los aspectos más importantes de este trabajo de investigación fue que una vez calibrados los 20 parámetros que aparecen en el apéndice A, estos se aplicaron sin modificar a los volúmenes de los diferentes estudios realizados. Cabe señalar que los estudios presentan características muy diferentes, por lo que se puede decir, que el procedimiento es aplicable a cualquier tipo de estudios ecocardiográficos sin necesidad de la calibración del procedimiento. El único parámetro que se modificó en el estudio tres, fue el umbral para fusionar regiones en el análisis de regiones adyacentes, por lo que este parámetro es el único dato a calibrar en caso de que esta etapa de la metodología fusione las cavidades con otros tejidos o entre las cavidades mismas.

Para evitar la calibración del umbral para fusionar regiones en la etapa del análisis de regiones adyacentes, se podría incorporar una etapa previa de análisis de continuidad y forma de los bordes, con la finalidad de unir los contornos débiles o discontinuos que rodean una cavidad.

En el Modelo de Superficies Activas, se necesitaría incorporar información a priori sobre las cavidades de interés, para evitar que la superficie final obtenida con la metodología, sobreestimara o subestimara la cavidad en el momento del ciclo cardíaco en el que las válvulas se abren. Fue en esta etapa del ciclo cardíaco cuando el Índice de Tanimoto tuvo los valores más bajos calculándolo contra la segmentación manual del experto.

El desempeño del procedimiento podría mejorarse utilizando un protocolo único de adquisición de las imágenes ecocardiográficas. Con este protocolo único, el umbral para fusionar regiones en el análisis de regiones adyacentes estaría exento de la calibración. Por lo que el proceso sería completamente automático. La intervención del usuario se limitaría únicamente a la selección de la cavidad a segmentar, una vez que se tiene la imagen etiquetada después de la presegmentación.

La principal desventaja de la metodología propuesta para la segmentación de imágenes ecocardiográficas es el tiempo de procesamiento, que consume demasiados recursos computacionales. El tiempo promedio de procesamiento por cada uno de los volúmenes segmentados fue de 7 horas. Este tiempo de procesamiento está en función del radio espacial, radio de intensidad, y en su caso del radio de entropía en las etapas de filtrado y presegmentación por corrimiento de media. Otro de los parámetros que influyen directamente en el tiempo de procesamiento es el umbral para fusionar regiones en el análisis de regiones adyacentes. Una de las posibles soluciones es optimizar el algoritmo de corrimiento de media y de análisis de regiones adyacentes. Otra solución para reducir el tiempo de procesamiento es utilizar las superficies detectadas en instantes previos para alimentar el modelo de superficies activas, por lo que se requeriría presegmentar solo algunos volúmenes del ciclo cardíaco, con la desventaja de tener la necesidad de modificar el término de energía externa que incluye la información del resultado de la presegmentación.

REFERENCIAS

- [1] R. Valdes-Cristerna, J.R. Jimenez, O. Yanez-Suarez, J.F. Larallut, V. Medina, *Texture-based Echocardiographic Segmentation Using a Non-parametric Estimator and an Active Contour Model*, 26th Annual International Conference of the Engineering in Medicine and Biology Society, 2004. EMBC 2004. Conference Proceedings. Volume 1, 1-5 Sept. 2004. Pages: 1806 – 1809.
- [2] J. N. Welch, J.A. Johnson, M. R. Bax, R. Badr, *Real-time freehand 3D ultrasound system for image-guided surgery*, Ultrasonics Symposium, 2000 IEEE. Volume 2, 22-25 Oct. 2000. Pages: 1601 – 1604.
- [3] J.G. Bosch, S.C. Mitchell, P.F. Lelieveldt, F. Nijland, O. Kamo, M. Sonka, H.C. Reiber, *Automatic Segmentation of Echocardiographic Sequences by Active Appearance Motion Models*, Transactions on Medical Imaging, IEEE. Volume 21, Issue 11, Nov. 2002. Pages: 1374 – 1383.
- [4] A. Hammoude, *Endocardial border identification in two-dimensional echocardiographic images: review of methods*, Computerized Medical Imaging and Graphics, Volume 22, Issue 3. 1998. Pages: 181-193.
- [5] J. Ching-Fen, *Autosegmentation of ultrasonic images by the genetic algorithm*, Medical Imaging 2001: Image Processing, Milan Sonka; Kenneth M. Hanson; Editors. Proc. SPIE. Vol. 4322 (2001). Pages: 151-157.
- [6] M. Sonka, J.M. Fitzpatrick, *Handbook of Medical Imaging Vol.II Medical Image Processing and Analysis*, USA. SPIE Press.2000.Chapter 3: Image Segmentation Using Deformable Models. Pages:131-173. Chapter 11: Echocardiography. Pages: 609-674.
- [7] H. Bosch, S. Mitchell, B. Lelieveldt, F. Nijland, O. Kamp, M. Sonka, J. Reiber, *Active Appearance-Motion Models for endocardial contour detection in time sequences of echocardiograms*. Medical Imaging 2001: Image Processing, Milan Sonka; Kenneth M. Hanson; Editors. Proc. SPIE. Volume 4322. Pages: 257-68.
- [8] T. F. Cootes, C. Beeston, G. J. Edwards, C. J. Taylor, *A unified framework for atlas matching using active appearance models*, in “Information Processing in Medical Imaging”, A. Kuba and M. Samal, Eds. Berlin, Germany: Springer-Verlag, 1999, Lecture Notes in Computer Science, pp. 322–333.
- [9] I. Shin, P. Kelly, H. Derin, K. Lee, D. Tighe, *Template and active contour matching for automated left ventricular boundary detection*, Medical Imaging 2001: Ultrasonic Imaging and Signal Processing, Michael F. Insana; K. Kirk Shung; Editors. Proc. SPIE. Volume 4325, May 2001. Pages: 400-409.
- [10] S.Mitchell, J. Bosch, B. Lelieveldt, R. Geest, J. Reiber, M. Sonka, *3-D Active Appearance Models: Segmentation of Cardiac MR and Ultrasound Images*, IEEE Transactions on Medical Imaging. Volume 21, Issue 9, Sept. 2002. Pages: 1167 - 1178

- [11] M. Kass, A. Witkin, D. Terzopoulos, *Snakes: Active Contour Model*, International Journal of Computer Vision, Kluwer Academic Publishers, 1987. Pages: 321-331.
- [12] R. Valdes-Cristerna, O. Yañez-Suarez, *Active contours and surfaces with cubic splines for semiautomatic tracheal segmentation*, Journal of Electronic Imaging, Volume 12, January 2003. Pages: 81-96.
- [13] G. Stippel, I. Duskunovic, Wilfried Philips, A. Zecic, P. Govaert, I. Lemahieu, *A New Method For Ultrasound Images Incorporating Prior Statistics Concerning Medical Features*. International Conference on Image Processing, 2001. Proceedings. Volume 2, 7-10 Oct. 2001. Pages: 821 – 824.
- [14] S. Pavlapoulos, E. Kyriacou, D. Koutsouris, K. Blekas, A. Stafylopatis, P. Zoumpolis, *Fuzzy Neural Network – Based Texture Analysis of Ultrasonic Images*, Engineering in Medicine and Biology Magazine, IEEE. Volume 19, Issue 1, Jan.-Feb. 2000. Pages: 39 – 47.
- [15] J. Wang, B. Thiesson, Y. Xu, M. Cohen, *Image and Video Segmentation by Anisotropic Kernel Mean Shift*. In Proc. European Conference on Computer Vision, 2004.
- [16] D. Comaniciu, P. Meer, *Mean Shift Analysis and Applications*, The Proceedings of the Seventh IEEE International Conference on Computer Vision, 1999. Volume 2, 20-27 Sept. 1999. Pages: 1197 – 1203.
- [17] D. Comaniciu, P. Meer, *Mean Shift: A Robust Approach toward Feature Space Analysis*, IEEE Transactions on Pattern Analysis and Machine Intelligence. Volume 24, Issue 5, May 2002. Pages: 603 – 619.
- [18] J. Azpiroz, V. Medina, J. F. Lerallut, *Procesamiento de imágenes biomédicas*, Universidad Autónoma Metropolitana, Mexico, 2000.
- [19] J. Cesar-Felipe, J.M. Traina, *Retrieval by Content of Medical Images Using Texture for Tissue Identification*, Proceedings of the 16 IEEE Symposium on Computer-Based Medical Systems (CBMS'03). 2003.
- [20] P. Meer, B. Georgescu, *Edge Detection with Embedded Confidence*, IEEE Transactions on Medical Imaging, Volume 23, Issue 12, December 2001. Pages: 1351-1360.
- [21] J. R. Jimenez-Alanis, V. Medina-Bañuelos, O. Yañez-Suarez, *Data-Driven Brain MRI Segmentation Supported on Edge Confidence and A Priori Tissue Information*, IEEE Transactions on Medical Imaging, Volume 25, Issue 1, January 2006. Pages: 74-83.
- [22] S. Theodoridis, K. Koutroumbas, *Pattern Recognition*, Academic Press, USA, 1999. Page: 366.

APENDICE A Tabla de valores de parámetros en cada una de las etapas de la Metodología Propuesta.

Filtrado por Corrimiento de Media

| | |
|-----------------------------|----|
| Radio espacial | 5 |
| Radio de Intensidad del eco | 10 |

Mapa de Bordos

| | |
|--|-------|
| Tamaño de la ventana del filtro derivativo de la Gaussiana | 3x3x3 |
| Varianza | 0.5 |

Mapa de Confianza

| | |
|--|------|
| Tolerancia del Borde | 0.35 |
| Factor de la Mezcla lineal de la magnitud Normalizada del gradiente y la medida de confianza | 0.35 |

Presegmentación por Corrimiento de Media

| | |
|-----------------------------|-----|
| Radio Espacial | 10 |
| Radio de Intensidad del eco | 15 |
| Radio de Entropía | 190 |

Análisis de Regiones Adyacentes

| | |
|---|------|
| Radio de Intensidad para fusionar regiones | 10 |
| Radio de Entropía para fusionar regiones | 30 |
| Umbral del Borde para fusionar regiones | 0.8 |
| Mínimo de Vóxeles necesario para considerarse una región. | 2000 |

Modelo de Superficies Activas

| | |
|----------|--------|
| α | 50 |
| β | 50 |
| γ | 200 |
| δ | 200 |
| μ | 0.0001 |

APENDICE B Artículo publicado en: Medical Imaging 2006. 11-16 February 2006. San Diego, California, USA. Organizado por: The International Society for Optical Engineering (SPIE).

3D Echocardiographic segmentation using the mean-shift algorithm and an active surface model.

Nazario Felix-Gonzalez, Raquel Valdes-Cristerna
Neuroimaging Laboratory, Department of Electrical Engineering,
Universidad Autonoma Metropolitana-Iztapalapa, Mexico.

ABSTRACT

The anatomical and functional cardiac cavities information obtained by Ultrasound images allows a qualitative and quantitative analysis to determine patient's health and detect possible pathologies. Several approaches have been proposed for semiautomatic or fully automatic segmentation. Texture based presegmentation combined with an active contour model have proven to be a promising way to extract cardiac structures from echographic images. In this work a novel procedure for 3D cardiac image segmentation is introduced. A robust pre-processing step that reduces noise and extracts an initial frontier of cardiac structures is combined with an Active Surface Model to obtain final 3D segmentation. Preprocessing is performed by the Mean Shift algorithm that integrates 3D edge confidence map and includes entropy, echoes intensity and spatial information as input features. This procedure locates adequately homogeneous regions in 3D echocardiographic images. The external energy terms included in the Active Surface Model are the 3D edge confidence map and the entropy component obtained by the Mean Shift pre-segmentation. The results demonstrate that the pre-processing provides homogeneous regions and a good initial frontier between blood and myocardium. The Active Surface Model adjusts the initial surface computed by the mean-shift algorithm to the cardiac border. Finally, the obtained results are compared with the experts' manual segmentation and the Tanimoto index between these segmentations is calculated.

Keywords: 3D Echocardiographic Segmentation, Mean-Shift, Entropy, Edge Map, Active Surface.

1. INTRODUCTION

The anatomical and functional cardiac cavities information obtained by Ultrasound images allows a qualitative and quantitative analysis to determine a patient's health and detect possible pathologies. The correct delineation of those structures and estimation of their volume become very important for an accurate definition of several important indexes such as stroke volume or ejection fraction. To identify boundary points between blood and myocardium several approaches has been proposed for semiautomatic or fully automatic segmentation, but none of them is exempt of disadvantages. Due to ultrasound drawbacks, cardiac segmentation continues to be a challenging task¹.

Many approaches for endocardium segmentation have been proposed based on, among others, arc filters, fuzzy neural nets ², active shape models, simulated annealing, dynamic programming, active appearance motion models ³ and texture-feature based segmentation ⁴. The main disadvantage of some of these methods is the necessity of normalized and aligned hand-annotated examples to generate statistical models or data training sets, which represents a very time-consuming and tedious procedure; and high inter-observer variability.

Traditionally contour-based approaches seem to be more suitable for this application; however, these algorithms need a preprocessing step in order to reduce noise and provide a good initial frontier between blood and myocardium. Texture based pre-segmentation combined with an active contour model proposed by Valdes-Cristerna *et al* ⁵ has proven to be a promising way to extract cardiac structures from 2D echographics.

In this work a novel procedure for cardiac image segmentation in 3D is introduced. A robust pre-processing (step) that reduces noise and extracts an initial frontier of cardiac structures is combined with an active surface model to obtain a final 3D delineation. The obtained results are compared with the experts' manual segmentation and the Tanimoto index between these segmentations is calculated to evaluate the entire procedure.

2. METHODOLOGY

The proposed method consists on several steps; an overview of the entire algorithm is shown in Figure 1.

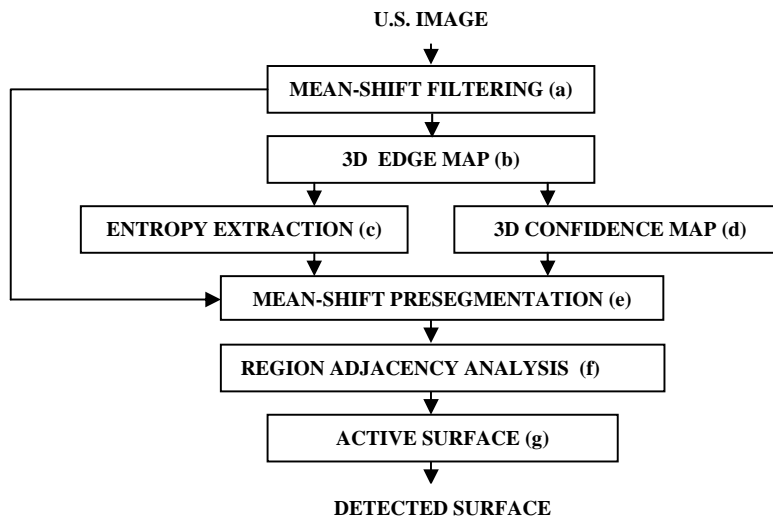


Figure 1 Overview of the proposed procedure.

a) Mean-Shift Filtering. The filtering is carried out by using a non-parametric estimator of the modes of the underlying probability density function (pdf) known as Mean-Shift algorithm ⁶; this procedure is based on a kernel estimator and provides homogeneous regions, reducing the noise into the image. The spatial information in three different directions (X, Y, Z) and the echo-intensity of each voxel (gray level) are the features included in this step.

b) Three-Dimensional Edge Map. A derivative of Gaussian filter (DoG) is used to define an edge map of the echocardiographic volume ⁵.

c) Entropy Extraction. The 3D edge map is windowed in 5x5x5 patches and the co-occurrence matrix for six directions (0°, 180° in X, Y, Z) at distance one for each patch is calculated. The second order entropy is obtained for the joint histogram as estimated from the co-occurrence matrix ⁷.

d) Three-Dimensional Confidence Map. By evaluating the similarity between the data pattern of the edge map and an ideal edge template, a 3D confidence map is computed. An estimation of the gradient orientation is used to generate an ideal 3D edge template with the equivalent orientation ⁸. The confidence map is formed by a linear combination of the normalized magnitude of the gradient and the confidence measure for each voxel of the echography.

e) Mean-Shift Segmentation. The pre-segmentation is performed by a weighted Mean-Shift version that preserves the edges of the ultrasound 3D image ⁵. The weights are taken from the confidence map calculation. The features considered in this step are: the edge map entropy (c), the echo intensity and the spatial information by voxel. The quality of this segmentation is controlled by the size of spatial kernel, and the entropy level and intensity bandwidths. As result in this step, a segmented volume is obtained.

f) Region Adjacency Graph (RAG). A graph of 3D-adjacent regions is defined with the pre-segmentation results. A boundary strength measure is computed from (d) and iteratively regions with weak borders are fused over the RAG; regions with size less than a minimum pre-defined are allocated to the nearest neighbor in the intensity-entropy joint space in order to obtain a labeled volume.

g) Active Surface Model (ASM). This model includes an intrinsic cubic splines interpolation for the active surface. The optimum surface is found iteratively in a gradient descent procedure. The regions obtained in (f) are used to define the initial surface for starting this procedure ⁹. The 3D confidence map (CM) and the entropy component (EC) of the Mean Shift pre-segmentation results are used as external energy terms. The energy term is defined as:

$$E_{ASM}(v) = E_{int} + E_{ext} = \sum_v (\alpha \|v\|^2 + \beta \|v'\|^2 + \gamma F_{CM}(v) + \delta F_{EC}(v))$$

2.1. Echocardiographic Images

A sample of eighteen volumes from two different 4D studies (STY1 and STY2) were acquired by a Sonos7500 imager Manufactured by Philips Medical Systems at the Pediatric Hospital in Amiens, France. The studies properties are shown on Table 1.

Table 1 Four-Dimensional Echocardiographic Studies.

| Property | STY1 | STY2 |
|-------------------------|-------------------|---------------------|
| Volume size | 208x48x128 | 208x80x80 |
| Spatial resolution [cm] | 0.048x0.061x0.040 | 0.070x 0.073x 0.050 |
| Frames | 46 | 11 |
| Time resolution [ms] | 37.37 | 54.00 |

2.2. Performance Validation

In order to compare the segmentation results with an expert manual delineation, the Tanimoto Index (TI) ¹⁰ was calculated for the segmented volumes. This parameter is calculated as follows:

$$TI = \frac{\|BCI \cap BRI\|}{\|BCI \cup BRI\|}$$

where BCI is a Binary Calculated Image by filling the final surface and BRI is the Binary Reference Image segmented by the expert.

3. RESULTS AND DISCUSSION

For visualization purposes 2D views of an echocardiographic volume for each study, are shown in Figure 2.




Figure 2 2D views of a volume of STY1 and STY2

Figure 3 shows the results from the different stages in the segmentation procedure for the study 1. For visualization purposes, only one longitudinal slice is shown. Finally the initial and final surface is presented.

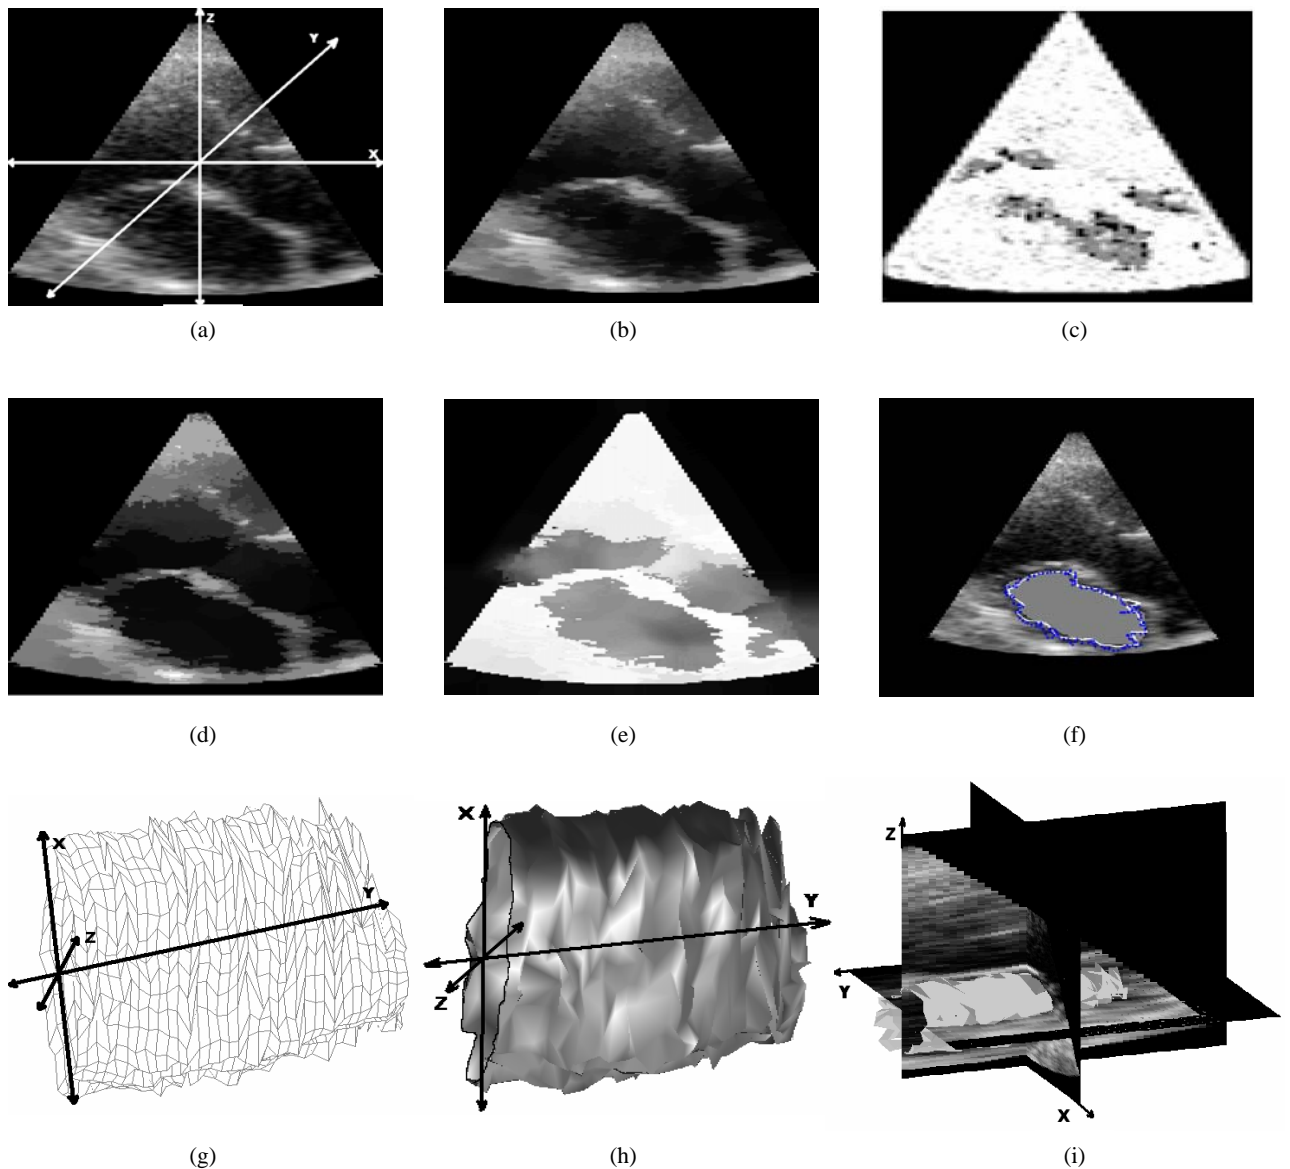


Figure 3 Different segmentation steps and initial and final surface results.

a) Mean-Shift Filtering. An intensity bandwidth of 10 was used. The spatial bandwidth of 5 was used for filtering the 18 volumes. The X, Y, and Z axis are shown on the original echographic image in Figure 3a. In (b) is shown a slice of the filtered volume. It can be observed that the filtering step reduces the speckle noise and preserves the edges of the image.

b) Three-Dimensional Edge Map. A Canny's filter of 3x3x3 voxels with $\sigma^2=0.5$ was used to build a 3D edge map.

c) Entropy Extraction. The 3D-Entropy image of the corresponding edge map is shown in Figure 3c.

d- e) Three-Dimensional Confidence Map and Weighted Mean-Shift. On Figure 3, (d) and (e) show the intensity and entropy components of the Weighted Mean Shift pre-segmentation result respectively. The parameters used in this step were: spatial radius of 10, intensity and entropy bandwidths of 15 and 190 respectively; and the weight of the

linear combination for the 3D edge confidence map was 0.35. These four parameters must be tuned according to the application and the quality of the images, but the spatial bandwidth is the most sensitive of them. It is important to note that there is a proportional ratio between this parameter and the computational time required for this procedure.

f) Region Adjacency Graph. For the boundary strength measure computed over the RAG, the border threshold, that determines if an edge exists between two adjacency regions, was tuned on 0.8.

g) Active Surface Model. The initial surface was robustly determined by the pre-processing procedure. The parameters of the ASM were: $\alpha=50$, $\beta=50$, $\gamma=200$ and $\delta=200$. The gradient descent step was $\mu= 0.0001$. The initial surface (points) and the final surface (white line) are shown over the region manually segmented by an expert on the original echography in Figure 3(f).

Results obtained show a good delineation for the initial surface to feed the ASM. It is very important to provide an adequate starting point to this step, due to the highly sensitive of the gradient descent method⁹. In Figure 3(g) and (h), the initial and final surfaces obtained from the border identification method are presented. This step adjusts the surface to the real cavity edge as shown in (f) and (i). Finally the result from the entire procedure is shown over the 3D original echocardiographic volume in (i).

The mean TI obtained for the sample of twelve volumes of STY1 is 0.656 ± 0.109 that indicates a good performance of the applied method evaluated with the expert's manual segmentation.

Figure 4 presents the resulting images obtained for the same study in different stages of the cardiac cycle (a, b, c, d). The resulting images for STY2 are shown in (e) to (h).




Figure 4 Segmentation results for different echocardiographic images.

The final surface are shown (points) over the region manually segmented by an expert on the original echocardiography in (a), (c), (e), and (g). In (b), (d), (f), and (h) the final cavity border identification result is displayed over the 3D US images. For the second study, consisting of a sample of 6 different volumes, the mean TI calculated was 0.581 ± 0.101 . The obtained results demonstrate that the entire procedure can be used for ventricle and auricle cavities delineation using the same features and parameters.

4. CONCLUSION

A robust pre-processing method for cardiac cavities segmentation combined with an Active Surface Model has been presented for the 3D delineation of cardiac structure. The results have demonstrated that the pre-processing stage provides a good initial frontier between blood and myocardium; the initial surface obtained is very close to the surface obtained by the manual experts' segmentation. The Mean Shift algorithm locates adequately homogeneous regions in echocardiographic images. The Active Surface Model adjusts the initial surface to the real cavity boundary. The computational resources are expensive, the procedure is very time consuming and increments as the spatial bandwidth increments in the mean-shift algorithm; other parameter that affects the processing time is the boundary strength measure computed over the RAG. The results obtained when the valve is open (Figure 3a) shows that the final surface overestimate the real cavity boundary, this drawback can be reduced if additional a priori information is included in the ASM. The obtained results can be used to evaluate both the ventricle and auricle deformation in the cardiac cycle using the same parameters in the entire procedure.

ACKNOWLEDGMENTS

The authors wish to thank Dr. Jean-Francois Lerallut, Université de Technologie de Compiègne, and Dr. Yves Maingourd, CHU Amiens, for their valuable help in providing the image data. This work was supported by the Franco-Mexican Laboratory on Informatics (LAFMI 2003) and by CONACyT (scholarship to N. Felix. Reg. 180890).

REFERENCES

1. M. Sonka, J.M. Fitzpatrick, *Handbook of Medical Imaging Vol.II Medical Image Processing and Analysis*. Chapter 3: Image Segmentation Using Deformable Models, pp.131-173. Chapter 11: Echocardiography, pp. 609-674. . USA, SPIE Press, 2000.
2. S. Pavlapoulos, E. Kyriacou, D. Koutsouris, K. Blekas, A. Stafylopatis, P. Zoumpolis, "Fuzzy Neural Network – Based Texture Analysis of Ultrasonic Images", *Engineering in Medicine and Biology Magazine, IEEE*. **Volume 19**, Issue 1, pp. 39 – 47, Jan-Feb 2000.
3. J. Ching-Fen, "Autosegmentation of ultrasonic images by the genetic algorithm", *Medical Imaging 2001: Image Processing*, **Vol. 4322**, pp. 151-157, Milan Sonka; Kenneth M. Hanson; Editors. Proc. SPIE. 2001.
4. J.G. Bosch, S.C. Mitchell, P.F. Lelieveldt, F. Nijland, O. Kamo, M. Sonka, H.C. Reiber, "Automatic Segmentation of Echocardiographic Sequences by Active Appearance Motion Models", *Transactions on Medical Imaging, IEEE*. **Volume 21**, Issue 11, pp. 1374 – 1383, Nov 2002.

5. R. Valdes-Cristerna, J.R. Jimenez, O. Yanez-Suarez, J.F. Larallut, V. Medina, "Texture-based Echocardiographic Segmentation Using a Non-parametric Estimator and an Active Contour Model", 26th Annual International Conference of the Engineering in Medicine and Biology Society, 2004. EMBC 2004, Conference Proceedings. **Volume 1**, pp. 1806 – 1809, 1-5 Sept. 2004.
6. D. Comaniciu, P. Meer, "Mean Shift Analysis and Applications", The Proceedings of the Seventh IEEE International Conference on Computer Vision, **Volume 2**, pp. 1197 – 1203, 20-27 Sept. 1999.
7. J. Cesar-Felipe, J.M. Traina, "Retrieval by Content of Medical Images Using Texture for Tissue Identification", Proceedings of the 16 IEEE Symposium on Computer-Based Medical Systems (CBMS'03). 2003.
8. P. Meer, B. Georgescu, "Edge Detection with Embedded Confidence", IEEE Transactions on Medical Imaging, **Volume 23**, Issue 12, pp. 1351-1360, December 2001.
9. R. Valdes-Cristerna, O. Yañez-Suarez, "Active contours and surfaces with cubic splines for semiautomatic tracheal segmentation", Journal of Electronic Imaging, **Volume 12**, pp. 81-96, January 2003.
10. S. Theodoridis, K. Koutroumbas, *Pattern Recognition*, pp. 366, Academic Press, USA, 1999..

UNIVERSIDAD AUTÓNOMA METROPOLITANA-IZTAPALAPA
CIENCIAS BÁSICAS E INGENIERÍA

**SEGMENTACIÓN ECOCARDIOGRÁFICA
3D UTILIZANDO EL ALGORITMO
DE CORRIMIENTO DE MEDIA Y
UN MODELO DE SUPERFICIE ACTIVA**

NAZARIO FÉLIX GONZÁLEZ

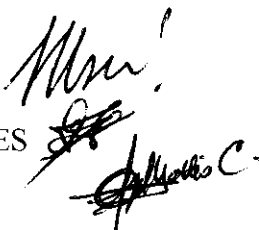
TESIS PARA OBTENER EL GRADO DE
MAESTRO EN CIENCIAS (INGENIERÍA BIOMÉDICA)

DICIEMBRE, 2006

ASESORA: DRA. RAQUEL VALDÉS CRISTERNA

SINODALES:

DR. FERNANDO ARAMBULA COSÍO
DR. ANGEL TOMAS ALJAMA CORRALES
DRA. RAQUEL VALDÉS CRISTERNA

Handwritten signatures of the sinodales members, including the name 'Raquel Valdés C.'.