



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
INGENIERÍA ELÉCTRICA – PROCESAMIENTO DIGITAL DE SEÑALES

SEGMENTACIÓN Y ESTIMACIÓN DE MOVIMIENTO EN ECOCARDIOGRAFÍA
FETAL USANDO UN MODELO DE APARIENCIA ACTIVA MULTI-TEXTURA Y LA
TRANSFORMADA DE HERMITE ROTADA

TESIS
QUE PARA OPTAR POR EL GRADO DE:
DOCTORA EN INGENIERÍA

PRESENTA:
M. EN I. LORENA PAOLA VARGAS QUINTERO

TUTOR PRINCIPAL
DR. BORIS ESCALANTE RAMÍREZ, FACULTAD DE INGENIERÍA
COMITÉ TUTOR
DRA. LUCIA MEDINA GÓMEZ, FACULTAD DE CIENCIAS
DR. FERNANDO ARÁMBULA COSÍO, CCADET

MÉXICO, D.F. DICIEMBRE DE 2016

JURADO ASIGNADO:

Presidente: DRA. LUCIA MEDINA GÓMEZ

Secretario: DR. PABLO ROBERTO PÉREZ ALCÁZAR

Vocal: DR. BORIS ESCALANTE RAMÍREZ

1^{er}. Suplente: DR. FERNANDO ARÁMBULA COSÍO

2^{do}. Suplente: DRA. VERÓNICA MEDINA BAÑUELOS

Lugar donde se realizó la tesis: FACULTAD DE INGENIERÍA, CU

TUTOR DE TESIS:

DR. BORIS ESCALANTE RAMÍREZ

FIRMA

DEDICATORIA

Este trabajo está dedicado a Dios quién está presente cada día en mi camino, bendiciéndome, amándome y dándome fuerzas para superar cada reto.

A mis padres quienes me han dado su amor y apoyo incondicional, me han enseñado grandes valores y son la luz de mi vida.

A mi hermana que ha sido un gran ejemplo a seguir y quien está ahí siempre que la necesito.

A Leiner quien me ha acompañado, apoyado y ayudado en todo momento.

AGRADECIMIENTOS

Quiero dar las gracias al Dr. Boris Escalante Ramírez mi director de tesis, por todo su apoyo a lo largo de estos años, por guiarme y darme valiosos consejos durante la realización y desarrollo de este proyecto.

Al Dr. Fernando Arámbula, a la Dra. Lucía Medina, a la Dr. Verónica Medina y al Dr. Pablo Pérez por sus comentarios y sugerencias en este trabajo, quienes siempre estuvieron dispuestos a brindarme su colaboración.

A la Universidad Nacional Autónoma de México y al Posgrado en Ingeniería por haber contribuido en mi formación académica.

A COLCIENCIAS Colombia y al Consejo Nacional de Ciencia y Tecnología (CONACYT) México, por el apoyo económico durante este proceso de formación. De igual forma, al Posgrado en Ingeniería por el apoyo para mi estancia doctoral y mi participación en congresos.

Quiero agradecer al Instituto Nacional de Perinatología de la Ciudad de México, a la Dra. Lisbeth Camargo, al Dr. Mario Guzmán y al Dr. Héctor Borboa quienes me brindaron todo el soporte y me suministraron todos los datos clínicos fundamentales en el desarrollo de este trabajo.

A Leiner quien durante estos años me ha acompañado, motivado, apoyado incondicionalmente, y quien, considerablemente, ha aportado con sus sugerencias a este proyecto. Agradecerle no solo toda la ayuda que me has dado sino todos los momentos compartidos.

A mis padres y hermana, por todo el amor, el respaldo y la confianza que han tenido en mí, y por contribuir día a día en mi desarrollo personal. Quisiera dar un agradecimiento al resto de mi familia que ha estado pendiente de mí, y que siempre me envían sus saludos y buenos deseos.

A todas aquellas personas que de una u otra forma fueron parte de este proceso y que haya olvidado mencionar.

Gracias a todos,

Autor
M. en I. Lorena Paola Vargas Quintero

Asesor de tesis
Dr. Boris Escalante Ramírez

Segmentación y estimación de movimiento en ecocardiografía fetal usando un modelo de apariencia activa multi-textura y la transformada de Hermite rotada

RESUMEN

En la actualidad, llevar a cabo un diagnóstico prenatal adecuado es fundamental para detectar algún tipo de malformación en el feto. La ecocardiografía fetal es un estudio muy importante para el diagnóstico de las anomalías cardíacas en una etapa temprana de gestación. Con este propósito, en este trabajo se desarrolló un método de segmentación aplicado al análisis de imágenes de ecocardiografía fetal. El algoritmo de segmentación es combinado con un esquema mejorado de estimación de movimiento. En este proyecto, se busca desarrollar una herramienta útil para la evaluación del corazón fetal. Para el método de segmentación se propone un modelo de apariencia activa (AAM) multi-textura basado en la transformada de Hermite rotada. En el método, básicamente se codifican diferentes tipos de características de textura a través de los coeficientes de Hermite rotados. Estos coeficientes son usados en el esquema AAM multi-textura desarrollado. Dado que los algoritmos basados en AAMs manejan información local, es necesario generar una buena inicialización en el proceso de segmentación. Para esto se diseñó un algoritmo de inicialización que consiste de un proceso de detección y localización de las estructuras cardíacas usando algoritmos de umbralización, morfología y correlación. Por otro lado, en la estimación de movimiento se propone una modificación del método de flujo óptico basado en la transformada de Hermite rotada desarrollado en [1]. En el nuevo esquema de estimación se utilizan restricciones de regiones homogéneas para evitar la estimación de vectores de movimiento en zonas donde no se presenta. Análogamente, los términos del funcional de estimación dependen de los coeficientes de Hermite rotados. Los métodos son evaluados en el análisis del ventrículo izquierdo usando estudios reales de ecocardiografía fetal y secuencias simuladas de imágenes cardíacas de ultrasonido.

Author
M. en I. Lorena Paola Vargas Quintero

Thesis advisor
Dr. Boris Escalante Ramírez

Segmentation and motion estimation in fetal echocardiography using a multi-texture active appearance model and the steered Hermite transform

ABSTRACT

Currently, a suitable prenatal diagnosis is a fundamental task for detecting any type of malformation in fetuses. Fetal echocardiography studies are essential for identifying cardiac anomalies at early gestational ages. With this purpose, in this work a segmentation method was developed applied to analysis of fetal echocardiography images. The segmentation algorithm is combined with an improved method for motion estimation. The main objective of this work is to develop a useful tool for evaluation of the fetal heart. For the segmentation method, a multi-texture active appearance model (AAM) based on the steered Hermite transform is proposed. In this method, different types of texture features are coded using the steered Hermite coefficients which are subsequently used into the multi-texture AAM method. Because methods based on AAMs use local information, it is required to provide a good initialization for the segmentation process. For this purpose, an initialization algorithm was designed which consists of a detection and localization process of the cardiac structures using thresholding, morphology and correlation algorithms. On the other hand, a modification of the optical flow algorithm based on the steered Hermite transform developed in [1] is proposed in this work for the motion estimation. The new proposed scheme includes a constraint for homogenous regions in order to avoid estimation of the velocity field in those areas where motion is not present. Analogously, terms of the estimation functional depend on the steered Hermite coefficients. The methods are evaluated for analysis of the left ventricle using real fetal echocardiography studies and simulated sequences of cardiac ultrasound images.

CONTENIDO

RESUMEN.....	iii
ABSTRACT	iv
CONTENIDO.....	v
LISTA DE FIGURAS.....	vii
LISTAS DE TABLAS.....	x
1. INTRODUCCIÓN	1
1.1. SEGMENTACIÓN DE IMÁGENES DE ULTRASONIDO CARDIACO	2
1.2. SEGMENTACIÓN EN ECOCARDIOGRAFÍA FETAL	3
1.3. ESTIMACIÓN DE MOVIMIENTO EN IMÁGENES DE ECOCARDIOGRAFÍA	4
1.4. DESCRIPCIÓN GENERAL DEL PROYECTO	6
2. ECOCARDIOGRAFIA FETAL.....	8
2.1. ECOCARDIOGRAFÍA FETAL PARA LA DETECCIÓN DE ANOMALÍAS CARDIACAS.....	8
2.2. VISTA DE CUATRO CÁMARAS	9
3. LA TRANSFORMADA DE HERMITE	12
3.1. LA TRANSFORMADA DE HERMITE ROTADA EN DOS DIMENSIONES.....	15
4. ALGORITMO DE SEGMENTACIÓN AAM MULTI-TEXTURA BASADO EN LA TRANSFORMADA DE HERMITE ROTADA	18
4.1. BASE DE DATOS PARA EL ALGORITMO DE INICIALIZACIÓN	19
4.2. INICIALIZACIÓN.....	20
4.2.1. Detección de la región de interés	21
4.2.2. Correlación basada en correspondencias.....	22
4.2.3. Selección de la forma inicial	22
4.3. SEGMENTACIÓN USANDO MODELOS DE APARIENCIAS ACTIVAS (AAMs).....	22

4.3.1. Modelo de apariencia activa (AAM)	22
4.3.1.1. Modelo estadístico de forma	23
4.3.1.2. Modelo estadístico de textura	25
4.3.1.3. Combinación de los modelos estadísticos de forma y textura	28
4.3.1.4. Segmentación con AAM	28
4.4. AAM MULTI-TEXTURA BASADO EN LA TRANSFORMADA DE HERMITE ROTADA.....	29
5. ESTIMACIÓN DE MOVIMIENTO USANDO LA TRANSFORMADA DE HERMITE ROTADA.....	32
5.1. ESTIMACIÓN DE MOVIMIENTO USANDO FLUJO ÓPTICO	32
5.2. FLUJO ÓPTICO USANDO LA TRANSFORMADA DE HERMITE ROTADA.....	35
5.2.1. Restricción de intensidad constante	36
5.2.2. Restricción para los coeficientes de Hermite	36
5.2.3. Restricción de suavizado	36
5.3. FUNCIONAL DE ESTIMACIÓN CON RESTRICCIÓN DE REGIONES HOMOGÉNEAS PARA LOS COEFICIENTES DE HERMITE.....	36
6. EXPERIMENTOS Y RESULTADOS	39
6.1. SECUENCIAS DE EVALUACIÓN	39
6.1.1. Imágenes reales para evaluación de la segmentación	39
6.1.2. Imágenes simuladas para evaluación de la estimación de movimiento	39
6.2. RESULTADOS DE LA ETAPA DE INICIALIZACIÓN	40
6.3. RESULTADOS DE LA SEGMENTACIÓN AAM MULTI-TEXTURA	42
6.4. RESULTADOS DE LA ESTIMACIÓN DE MOVIMIENTO.....	49
6.5. APLICACIÓN: SEGMENTACIÓN Y ESTIMACIÓN DE MOVIMIENTO DEL VENTRÍCULO IZQUIERDO DEL CORAZÓN FETAL.....	52
7. DISCUSIONES Y CONCLUSIONES	54
7.1. TRABAJOS FUTUROS.....	56
8. BIBLIOGRAFIA	57

LISTA DE FIGURAS

Figura 1. Esquema general del sistema propuesto.....	6
Figura 2. a. Proceso de adquisición de una ecocardiografía fetal. b. Imagen de ejemplo en la cual no se aprecian las cavidades cardiacas. c. Imagen de ejemplo con las cavidades cardiacas visibles.	9
Figura 3. Estructuras del corazón fetal	10
Figura 4. Vista de cuatro cámaras del corazón fetal, LA = aurícula izquierda, LV = ventrículo izquierdo, RA = aurícula derecha, RV =ventrículo derecho, DA = aorta descendente.....	11
Figura 5. Proceso de descomposición de la transformada de Hermite.....	13
Figura 6. Arreglo gráfico para los coeficientes de Hermite hasta el segundo orden.	14
Figura 7. Filtros de Hermite en dos dimensiones. a. Filtros en el dominio espacial, b. Filtros en el dominio de la frecuencia.....	14
Figura 8. Coeficientes de Hermite hasta el segundo orden para una imagen de ecocardiografía fetal tomada en una vista de cuatro cámaras.....	15
Figura 9. Coeficientes rotados de la transformada de Hermite obtenidos a partir de los coeficientes cartesianos de la Figura 8.....	17
Figura 10. Diagrama del método AAM multi-textura propuesto.	18
Figura 11. Ejemplos de imágenes de la base de datos usada para la etapa de inicialización, a. Parches de una de las imágenes rotada a 17 ángulos diferentes, b. Parche de la imagen original e imagen escalada en la fase de sístole (izquierda) y fase de diástole (derecha) del ciclo cardiaco.....	20
Figura 12. Ecocardiografías fetales con diferentes orientación y tamaño de la región cardiaca.....	21
Figura 13. Diagrama general del algoritmo de inicialización para el ventrículo izquierdo.	21
Figura 14. Landmarks que delimitan el objeto en imágenes del conjunto de entrenamiento.	23

Figura 15. Ejemplo de formas alineadas y forma promedio. En rojo se visualizan los puntos de cada imagen ecocardiográfica alineada. En azul se ilustra la forma promedio.	24
Figura 16. Ejemplo de formas obtenidas al variar el parámetro b	25
Figura 17. Selección del parche de textura en las imágenes de entrenamiento.....	26
Figura 18. Ejemplo de textura promedio G obtenida del conjunto de entrenamiento.	26
Figura 19. Texturas obtenidas al variar tres elementos de r	27
Figura 20. Modos de variación del modelo estadístico usando los mapas de texturas dados por los coeficientes $L_{0,0}$, $L_{1,0,\theta}$ y $L_{2,0,\theta}$ de la transformada de Hermite rotada. ϑ_1 es el primer eigenvalor obtenido para el modelo de apariencia usando cada coeficiente de Hermite rotado.	30
Figura 21. Secuencia de imágenes en tiempos diferentes con desplazamiento (dx, dy)	34
Figura 22. Resultados del método de estimación de movimiento, a. Método propuesto por Moya-Albor [1], b. Versión modificada propuesta.	38
Figura 23. Resultados del proceso de inicialización para tres imágenes de evaluación diferentes.	40
Figura 24. Inicialización obtenida usando bases de datos con diferentes números de parches, producto de diferente número de rotaciones. La curva azul utiliza imágenes sin escalar y la curva roja es el resultado utilizando dos escalas.	41
Figura 25. Resultado de la segmentación usando varias iteraciones. a. Forma inicial, b. Iteración 2, c. Iteración 7, d. Iteración 10, e. Iteración 20, f. Iteración 30. El contorno verde es el resultado de la segmentación en cada iteración y el contorno rojo es la forma inicial.....	42
Figura 26. Deformación del modelo de textura construido para cada uno de los coeficientes de Hermite rotados en varias iteraciones.	43
Figura 27. Resultados de la segmentación usando el método propuesto y otros tres usados para propósitos de comparación.	45
Figura 28. Mejor y peor resultado obtenido con el coeficiente de DICE para las imágenes de prueba evaluadas. La segmentación automática es el contorno verde y la segmentación manual es el contorno rojo. a. Mejor resultado obtenido, imagen en la fase final de diástole. b. Peor resultado obtenido, imagen en la fase final de sístole.	45
Figura 29. Resultados de la segmentación usando dos imágenes de prueba y cuatro métodos empleados para comparación. a. Snake, b. ASM, c. AAM, d. AAM con LBP y AAM multi-textura. El contorno verde es la segmentación automática y el rojo es la segmentación manual.	46

Figura 30. Evolución de la distancia punto-a-curva en varias iteraciones. Cuatro métodos fueron usados para este análisis: Snake, ASM, AAM clásico y AAM multi-textura.	47
Figura 31. Distancia punto-a-curva del método propuesto para dos secuencias de prueba. El error es evaluado para todo el ciclo cardiaco.	48
Figura 32. Segmentación obtenida para el ventrículo izquierdo aplicando cuatro diferentes criterios para los parámetros de pesos del AAM multi-textura.	49
Figura 33. Resultados de la estimación de movimiento con el método implementado en una imagen de prueba de la secuencia sintética.	50
Figura 34. Evaluación cuantitativa del error de punto final promedio entre el método de flujo desarrollado en [1] y el algoritmo mejorado propuesto.	51
Figura 35. Resultados de la segmentación y estimación de movimiento para un estudio de ecocardiografía fetal. En este se presentan las imágenes 1, 4, 7, 10, 15 y 25 de la secuencia del ciclo cardiaco.	53

LISTAS DE TABLAS

Tabla 1. Resultados cuantitativos del algoritmo de inicialización.....	40
Tabla 2. Distancia promedio punto-a-curva para 5 pacientes usando varios métodos de segmentación. Los valores de las distancias están expresados en $\mu \pm \text{std}$	44
Tabla 3. Efectos de la variación de los parámetros en el AAM multi-textura. Como métrica se usó la distancia punto-a-curva y el índice de DICE.	48
Tabla 4. Parámetros empleados en el algoritmo.....	50
Tabla 5. Medida de error de punto final (EE) en la secuencia de prueba usando varios métodos..	52

1. INTRODUCCIÓN

Las enfermedades cardíacas han sido una de las principales causas de muerte en los últimos años [2]. La detección de anomalías en el corazón todavía constituye un gran reto para los médicos especialistas, particularmente cuando los estudios son realizados en la etapa fetal. Las imágenes médicas son una herramienta indispensable para llevar a cabo un adecuado diagnóstico prenatal de la función cardíaca [3]. La ecocardiografía es una de las principales herramientas aplicadas al análisis del corazón fetal debido a que no usa radiación ionizante. Sin embargo, este tipo de herramientas presentan muchas desventajas para la interpretación clínica debido al bajo contraste y los patrones de *speckle* presentes en las imágenes.

Dentro de las estructuras cardíacas del corazón fetal, el ventrículo izquierdo es una de las cavidades que más se utiliza para identificar problemas cardíacos y/o evaluar el funcionamiento del corazón del feto. La ecocardiografía fetal, entonces, es muy útil para evaluar cuantitativa y cualitativamente el ventrículo izquierdo en todas las fases del ciclo cardíaco. Por lo general, estas evaluaciones se llevan a cabo usando una vista de cuatro cámaras [4]. Para algunas de estas evaluaciones es necesario segmentar y analizar el movimiento del ventrículo izquierdo. Actualmente, estas delimitaciones son realizadas de forma manual por los expertos, constituyéndose en tareas que consumen mucho tiempo, son tediosas y llegan a ser dependientes del operador. Por esta razón, resulta esencial y de mucho beneficio desarrollar técnicas robustas de segmentación automática y estimación de movimiento que ayuden en la evaluación del sistema cardíaco. La segmentación automática para este tipo de cavidades ha sido ampliamente desarrollada en adultos [5], [6], [7], [8], [9], [10], [11], [12], pero es un tema que apenas comienza a trabajarse en ultrasonido fetal. En esta última aplicación, se debe tener en cuenta el tamaño y forma del corazón debido a que se trata de una estructura en formación, por lo que puede variar significativamente dependiendo de la etapa de gestación. No obstante, la calidad de las imágenes, las cuales son degradadas por el *speckle*, se manifiesta como una limitante para el buen desempeño de los algoritmos de segmentación.

Además de los métodos de segmentación usados para el análisis y mediciones de características anatómicas, es de gran importancia complementar con técnicas de estimación de movimiento. Estas permiten estudiar los cambios de movimiento y analizar las propiedades mecánicas de las cavidades cardíacas, lo cual es indispensable para llevar a cabo una valoración más completa del funcionamiento cardíaco fetal, así como identificar tejidos normales y con anomalías [13]. Cuando se utilizan algoritmos de estimación de movimiento en estas aplicaciones, es necesario tener en cuenta las mismas consideraciones que se tenían para el caso de la segmentación con respecto a las características de las imágenes y el objeto bajo estudio. Estos algoritmos han encontrado su mayor utilidad en la evaluación de imágenes cardíacas gracias a la naturaleza dinámica del corazón.

A continuación, se presenta una descripción breve del estado del arte de los métodos de segmentación que han sido usados en aplicaciones de imágenes ecocardiográficas de adultos, así como en aplicaciones fetales. Se presenta también una revisión de los métodos de estimación de movimiento, en particular aquellos que han sido usados en imágenes de ultrasonido.

1.1. SEGMENTACIÓN DE IMÁGENES DE ULTRASONIDO CARDIACO

El problema de segmentación de imágenes de ecocardiografía ha sido abordado por los investigadores usando diferentes tipos de técnicas y enfoques. Entre estos encontramos los modelos de formas y apariencias activas [6], [7], [8], [11], [12], [14], [15], y los contornos activos paramétricos [5], [16]. Estos últimos, también conocidos como *Snakes* (o ACM por su nombre en inglés) [16], consisten de una curva la cual se va deformando gracias a la acción de fuerzas internas y externas que guían la curva hacia los bordes del objeto de interés. Marsousi et al. [5] propusieron un *Snake* basado en *B-splines*, en el cual se combina un conjunto de fuerzas usando un esquema multiresolución para segmentar el endocardio del ventrículo izquierdo en estudios ecocardiográficos. El trabajo de Nandagopalan [17] incluye un algoritmo clásico de K-medias en el modelo del contorno activo para extraer el borde de la cavidad ventricular. Otros investigadores han optado por incorporar información a priori en el algoritmo ACM considerando que las imágenes de ultrasonido pueden ser modeladas usando funciones de distribuciones de Rayleigh [18]. Estos métodos, sin embargo, presentan dificultades debido a que son altamente sensibles al ruido y a la inicialización [19].

Los modelos de formas activas (ASMs por su nombre en inglés) son una alternativa para abordar las limitaciones de los contornos activos paramétricos. Estos métodos fueron desarrollados por Cootes et al. [12], [14] y consisten de un modelo estadístico obtenido a partir de un conjunto de entrenamiento. El objetivo del método es segmentar estructuras similares a las que fueron empleadas para entrenar el modelo. Un ASM se compone de un conjunto de puntos de referencia, cada uno representando la posición espacial de una parte específica de la estructura. Para implementar el modelo se necesitan puntos de referencia que describen el conjunto de objetos de entrenamiento. Estos puntos son conocidos comúnmente en inglés como *Landmarks*. El análisis estadístico de las posiciones relativas de los puntos de referencia, en diferentes ejemplos, permite modelar la forma del objeto en estudio y sus posibles variaciones. Los niveles de grises en las proximidades de cada punto de referencia también se modelan estadísticamente. El modelo construido es usado para segmentar nuevas imágenes. Hamarneh et al. [9] incorporaron un modelo ASM para restringir la deformación de la curva en un modelo *Snake*. La combinación de estas dos técnicas fue aplicada en la segmentación del ventrículo izquierdo en imágenes de ecocardiografía. Paragios et al. [6] usaron un método de forma activa en el cual se consideran dos modelos, uno para la fase de sístole y otro para la fase de diástole. Posteriormente, una combinación de los dos modelos es usada para obtener la deformación del ventrículo y de esta forma lograr una segmentación precisa de la cavidad. ASM y ACM son métodos que usan solamente información

alrededor del contorno, codificada por medio de perfiles de grises y gradientes, lo cual puede afectar el desempeño en aplicaciones de ecocardiografía.

Los modelos de apariencia activa (AAM, sigla derivada de su nombre en inglés) son una alternativa para caracterizar no solo la forma sino la textura de las imágenes de análisis. Este método es una extensión de ASM, en el cual la forma es combinada con la textura del objeto para obtener un solo modelo que sea capaz de procesar ambas características [7], [8], [20]. En el trabajo presentado por Bosch et al. [15], se presenta un modelo de apariencia activa para delinear el contorno del ventrículo izquierdo en secuencias de imágenes de ecocardiografía tomadas para todo el ciclo cardiaco.

Muchos autores han hecho sus contribuciones sobre métodos de segmentación basados en ACM, ASM y AAM aplicados a imágenes de ecocardiografía de adultos. Sin embargo, las aplicaciones en segmentación de ecocardiografía fetal aún son escasas [19].

1.2. SEGMENTACIÓN EN ECOCARDIOGRAFÍA FETAL

En esta sección se presenta una breve descripción de los métodos que han sido aplicados a la segmentación del corazón usando ecocardiografía fetal. Como se mencionó, muchos de los esquemas usados para segmentar el corazón en imágenes de ultrasonido han sido desarrollados para el análisis de pacientes adultos. Sin embargo, los métodos de segmentación aplicados al estudio de ecocardiografías fetales han ido ganando gran importancia, esto debido al interés que existe por determinar algún tipo de cardiopatía desde etapas tempranas de gestación.

Entre las aplicaciones orientadas al análisis de ecocardiografía fetal se encuentra la segmentación de las cavidades cardiacas, entre ellas el ventrículo izquierdo. Algoritmos difusos, modelos de apariencia activa y métodos basados en *Level Sets* son algunas de las técnicas que más han sido usadas para segmentar el corazón de fetos en imágenes de ultrasonido [19], [21], [22], [23], [24].

Yi Guo et al. [19] presentaron un novedoso esquema que combina un modelo de representación *Sparse*, información global y una técnica de refinamiento local con modelos de apariencia activa para segmentar el ventrículo izquierdo. Sampath et al. [21] desarrollaron una técnica de conectividad difusa para la segmentación de las cuatro cavidades del corazón fetal. El método consta de una etapa de filtrado para reducir el *speckle* en la imagen de ultrasonido, basada en un modelo de estimación de máximo a posteriori. En el método también se necesitan puntos semillas de referencia seleccionados de la estructura cardiaca.

Dindoyal I. et al. [22] emplearon un método de *Level Set*, el cual utiliza información a priori de las cavidades cardiacas para delimitar la segmentación del corazón. Similarmente, Lassige et al. [23] utilizaron un *Level Set* para delinear el endocardio del ventrículo izquierdo del corazón fetal. Yinhui Deng et al. [24] presentaron un modelo activo cardiaco para la segmentación de las estructuras cardiacas durante una etapa fetal temprana. Este esquema consta de una etapa de pre-procesamiento de fase, donde el área de interés es localizada a través de un proceso de detección

automática basada en un método de estimación de movimiento y de difusión anisotrópica. El movimiento de las cavidades cardíacas se realiza usando el modelo activo cardíaco.

1.3. ESTIMACIÓN DE MOVIMIENTO EN IMÁGENES DE ECOCARDIOGRAFÍA

El análisis de movimiento es un método muy empleado en aplicaciones de visión por computador y que ha sido extendido a otros campos de investigación. Entre las aplicaciones donde más relevancia han adquirido estas técnicas, están las imágenes médicas, en específico en el análisis de ecocardiografía donde se evalúa el comportamiento mecánico del corazón. El análisis de movimiento de las cavidades cardíacas se puede llevar a cabo usando diferentes modalidades de imagenología médica. Entre estas, han sido de mucha importancia los sistemas de ultrasonido [25], [26], [27]. Entre las ventajas más significativas de estos sistemas están su seguridad, su bajo costo y que se procesa en tiempo real. Además, es una herramienta muy adecuada para las evaluaciones fetales.

Son muchas las técnicas que se han desarrollado para analizar movimiento en imágenes de ecocardiografía y algunas de ellas incluyen un proceso de seguimiento de líneas a través de las intensidades mínimas [28], otras utilizan registros deformables [29], [30], y otras están basadas en estimación de flujo óptico [31], [32].

Los métodos basados en seguimiento de líneas con intensidad mínima, los cuales usan un modelo de un perfil de intensidad, tienen la desventaja de consumir mucho tiempo de procesamiento y, además, necesitan que la línea de seguimiento sea localizada con anterioridad [28].

Las técnicas de registros deformables [29] han sido adaptadas a la detección del movimiento del miocardio [30]. Muchos de estos métodos de detección de movimiento no consideran las características estadísticas del ultrasonido en sus esquemas de estimación.

Los métodos de estimación de flujo óptico pueden agruparse en tres clases. La primera de ellas corresponde a las técnicas diferenciales o métodos basados en gradiente [33], [34], [35], [36], los cuales suponen que el brillo de un patrón es invariante con el tiempo y calculan la velocidad en la imagen a partir de las derivadas de las intensidades. Esta técnica da buenos resultados en imágenes con buena calidad, sin embargo, es altamente sensible al ruido. En el segundo caso, se tienen las técnicas en frecuencia basadas en fase [37]. Teóricamente, la estimación de flujo óptico basada en fase es el método más apropiado en imágenes de ultrasonido. El uso de la información de fase la hace una técnica robusta para artefactos atenuados. En una tercera clasificación entran las técnicas de ajuste de regiones (del inglés *block matching*) [38], [39], [40], [41], las cuales usan la naturaleza de dependencia del *speckle* en la imagen como un registro espacial para determinar el movimiento del tejido. Estos métodos logran una estimación más precisa que los métodos que se basan en las intensidades. Un inconveniente en los algoritmos de ajuste de regiones es que su captura varía con el tamaño del bloque. Es difícil seleccionar un tamaño de bloque óptimo que capture deformaciones grandes y pequeñas simultáneamente.

Alessandrini et al [42]. utilizaron un método de estimación de flujo óptico monogénico multiescala para cuantificar el movimiento en imágenes de ultrasonido cardiacas, en el cual se estima los desplazamientos teniendo en cuenta la fase. En el método se integra un modelo de desplazamiento local afine que considera el movimiento del corazón durante y las fases de sístole diástole. Además, se incluye un esquema piramidal que ayuda cuando se tiene grandes desplazamientos.

En general, los métodos basados en intensidades o que usan técnicas de estimación de flujo óptico presentan resultados poco satisfactorios en este tipo de aplicaciones, debido a que el *speckle* degrada de forma significativa la calidad de las imágenes haciendo que las regiones homogéneas y bordes sean difíciles de identificar.

Otros métodos de estimación de movimiento están basados en esquemas de análisis bayesiano. Wang et al. [43] presentaron una fusión de características unificadas que incluye patrones de *speckle*, un método de detección de bordes y gradientes, así como técnicas de predicción de movimiento utilizando un marco bayesiano aplicado a la estimación de movimiento en 3D. Este modelo usa un conjunto de entrenamiento para codificar los movimientos conocidos. El problema sería saber si un conjunto de entrenamiento puede manejar todos los posibles casos patológicos. Este enfoque es conveniente debido a que estima el movimiento en cada cuadro de una manera secuencial. Otros autores plantean algoritmos de estimación de movimiento en tejidos suaves, en secuencias de imágenes de ultrasonido, usando modelos estadísticos y técnicas de máximo a posteriori [38], [39], las cuales son adaptadas a las características estadísticas locales de estas imágenes [44]. En la literatura, también existen métodos de estimación de movimiento en secuencias de imágenes de ultrasonido que tienen en cuenta la correlación de regiones utilizando medidas de similitud y métodos bayesianos [39], [40].

Una de las técnicas de estimación de movimiento en imágenes de ultrasonido que ha cobrado mucha relevancia en la actualidad, es el método de rastreo de *speckle* (conocida en inglés como *Speckle Tracking*) [45] [46]. En esta técnica, se trata de hacer un seguimiento de los patrones de *speckle* que se mueven con el tiempo. Los métodos más comúnmente usados son los de correspondencia de bloques (conocido en inglés como *Block Matching*) o algoritmos de flujo óptico basados en diferencias. El *Speckle Tracking* ha sido ampliamente usado en aplicaciones clínicas en 2D [45], [46], [47]. Este método tiene la desventaja de que es inexacto en regiones con un alto grado de correlación del *speckle*. En base a esto se han hecho varias modificaciones con el fin de resolver este inconveniente. Una de estas consiste en integrar información a priori basada en las propiedades físicas del movimiento de los tejidos en el proceso de estimación [48]. Además, se han hecho propuestas con el propósito de extender este algoritmo para estimar movimiento en secuencias de imágenes en un espacio tridimensional [49], [50].

Otros investigadores [30], [41], [51], [52] presentan algoritmos de estimación de movimiento elástico (no rígido) en imágenes de ultrasonido cardiaco con el fin de hacer frente a las deformaciones que se puedan presentar en las estructuras debido a cambios anatómicos. En [30] se presenta un método el cual se caracteriza por utilizar un modelo paramétrico local para la deformación usando *splines*.

Muchas de las técnicas clásicas para la estimación de movimiento no son muy adecuadas para abordar el problema en imágenes de ultrasonido debido a la influencia del *speckle* y la degradación presente en este tipo de imágenes. Por consiguiente, muchos de los métodos propuestos para estimar el movimiento de objetos han sido usados en imágenes de ultrasonido con algunas modificaciones, [30], [32], [38], [39], [40].

1.4. DESCRIPCIÓN GENERAL DEL PROYECTO

En el proyecto, básicamente, se busca segmentar y analizar el movimiento del ventrículo izquierdo en secuencias de imágenes de ultrasonido fetal. Para la segmentación se diseñó un algoritmo AAM multi-textura aplicado sobre cada imagen de la secuencia. El movimiento de la cavidad es estimado usando un algoritmo de flujo óptico mejorado. Ambos métodos usan los coeficientes de la transformada de Hermite rotada. En la Figura 1. Esquema general del sistema propuesto. se muestra el diagrama general del proyecto desarrollado. Inicialmente, la secuencia de imágenes de entrada es analizada usando la transformada de Hermite rotada. Luego, Los coeficientes obtenidos son usados como datos de entrada en el AAM multi-textura para segmentar el ventrículo izquierdo, así como en el algoritmo de flujo óptico.

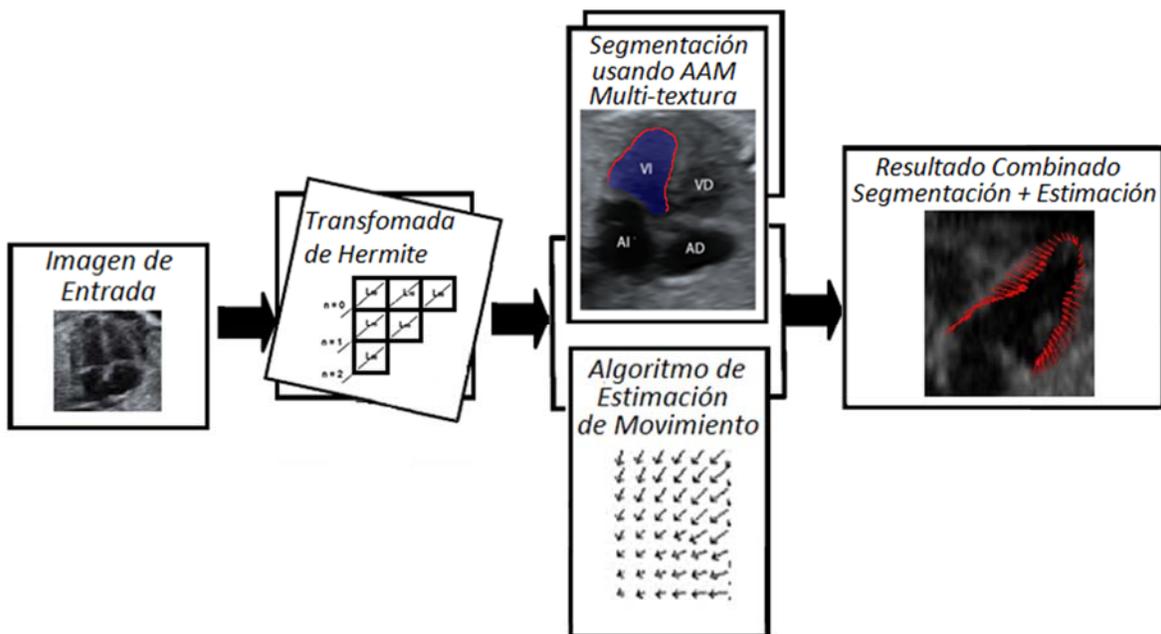


Figura 1. Esquema general del sistema propuesto.

Finalmente, los resultados de ambas etapas son combinados con el objetivo de suministrar una herramienta capaz de analizar el comportamiento mecánico de esta cavidad ventricular. La combinación de estas dos etapas, segmentación y estimación de movimiento, permite hacer un análisis localizado sobre el ventrículo izquierdo, tal como fue ilustrado en la figura anterior. Ambas etapas utilizan la transformada de Hermite para extraer las características de las secuencias de

imágenes de entrada. Parte de los resultados que se obtuvieron del desarrollo de este proyecto de investigación han sido reportados en [53].

Cada una de estas etapas es descrita en los capítulos siguientes. El capítulo 2 describe las características de las imágenes de ultrasonido fetal y su utilidad. El capítulo 3 presenta las definiciones y conceptos relacionados con la transformada de Hermite. En el capítulo 4, se detalla el método de segmentación propuesto. El capítulo 5 describe el algoritmo mejorado de flujo óptico utilizado en este proyecto. Los experimentos y resultados son expuestos en el capítulo 6. Finalmente, las conclusiones del proyecto son presentadas en el capítulo 7.

2. ECOCARDIOGRAFIA FETAL

El ultrasonido es una de las modalidades de imagenología médica más empleada para el diagnóstico en fetos. Es utilizado en una etapa primaria de revisión y evaluación clínica. Su funcionamiento se basa en la transmisión de pulsos hacia el cuerpo, y las amplitudes de los ecos retornados, después de pasar por diferentes tejidos, son codificadas y procesadas para formar una imagen. Es una técnica que tiene muchas ventajas comparada con otras modalidades de imagenología médica. Su importancia en el análisis y evaluación fetal es debido a ciertas características como su bajo costo, no utiliza radiación ionizante, trabaja en tiempo real, es portable y además presenta muy bajo riesgo para el feto y la madre.

Los sistemas de ultrasonidos son muy utilizados para calcular medidas de volumen, obtener parámetros anatómicos y realizar análisis de movimiento. Los avances que se han ido desarrollando e incorporando en la actualidad en estos sistemas han permitido realizar estudios en tres y cuatro dimensiones. Además, con las nuevas tecnologías de escaneo compuesto se ha conseguido mejorar significativamente la calidad de las imágenes, lo cual ha contribuido a que se realicen mejores interpretaciones por parte de los especialistas.

El ultrasonido se ha convertido en una modalidad estándar para la evaluación fetal. Una de las aplicaciones en las cuales ha adquirido gran relevancia es en el estudio del corazón, en donde se evalúa la anatomía cardíaca fetal para detectar algún tipo de problema o anomalía durante el periodo de gestación.

2.1. ECOCARDIOGRAFÍA FETAL PARA LA DETECCIÓN DE ANOMALÍAS CARDIACAS

Las cardiopatías congénitas están entre los problemas que causan más mortalidad infantil debido a que afectan el funcionamiento del corazón. Estos defectos están presentes en 8 de cada 1000 nacimientos, aproximadamente [54]. Un diagnóstico en una etapa temprana de gestación es esencial y permite una adecuada preparación para los procedimientos que deben realizarse después del parto. Un análisis de las imágenes cardíacas fetales puede ser esencial para identificar diferentes cardiopatías congénitas y tener un conocimiento aún más claro de la anomalía [55].

Los desarrollos tecnológicos y mejoras en los equipos de ultrasonido han permitido un gran avance para el diagnóstico prenatal y determinar en mayor detalle algunos tipos de anomalías cardíacas. Adicionalmente, diferentes modalidades y aplicaciones, como son la ecografía *Doppler* y estudios de rastreo de *speckle*, han sido incluidas para evaluar el estado del feto y detectar defectos cardíacos del funcionamiento mecánico del corazón [56]. De igual forma, la imagenología en 3 y 4 dimensiones

mejora la definición de las estructuras cardíacas y, por ende, ayuda a la evaluación e identificación de las anomalías cardiovasculares.

Muchas de las anomalías han podido ser detectadas en el útero por medio de las diferentes modalidades de imagenología médica. Los estudios realizados con ecocardiografía fetal han sido ventajosos para diagnosticar inusuales patologías que no son detectadas clínicamente por ausencia de síntomas durante el embarazo. Una ecocardiografía es muy útil durante la etapa prenatal, y en específico la vista de cuatro cámaras, debido a que es clínicamente aceptable para diagnosticar y detectar un porcentaje considerable de las anomalías intracardiacas o algunas anomalías no muy comunes presentes en el feto [57].

2.2. VISTA DE CUATRO CÁMARAS

En la evaluación del comportamiento del corazón fetal se realiza la adquisición de la ecocardiografía fetal en diferentes planos. Muchas veces, tener una vista adecuada para el estudio dependerá de la posición fetal y la experiencia del médico especialista. En ocasiones resulta difícil determinar las cavidades cardíacas cuando el feto se encuentra en una posición transversal. En la Figura 2 se muestra un ejemplo de adquisición de los estudios de ecocardiografía fetal. Se puede observar una imagen donde las cavidades no se pueden apreciar debido a una mala adquisición, y otra donde estas cavidades son visibles.

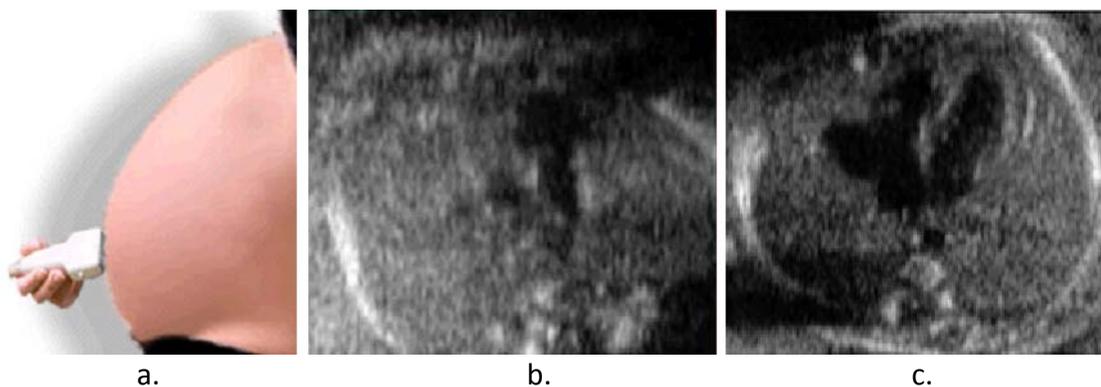


Figura 2. a. Proceso de adquisición de una ecocardiografía fetal. b. Imagen de ejemplo en la cual no se aprecian las cavidades cardíacas. c. Imagen de ejemplo con las cavidades cardíacas visibles.

Una de las vistas más utilizadas para el análisis es la de cuatro cámaras, debido a que se trata de una de las vistas más fáciles de conseguir y que además tienen gran relevancia en estudios de corazón fetal. Un 60% de los casos de patologías cardíacas son determinados a través de esta vista [58]. Para la adquisición es importante considerar que el eje cardíaco se ubica aproximadamente a 45° de la posición de la línea media del corazón [59], [60], [61]. Muchos de los defectos cardíacos pueden ser difíciles de detectar si las imágenes adquiridas no presentan alto grado de resolución. Algunos de

estos problemas se pueden presentar a causa de la posición del feto o el tamaño del corazón, lo cual dificulta la adquisición. En la Figura 3 se ilustra un esquema gráfico con las partes y estructuras principales del corazón fetal.

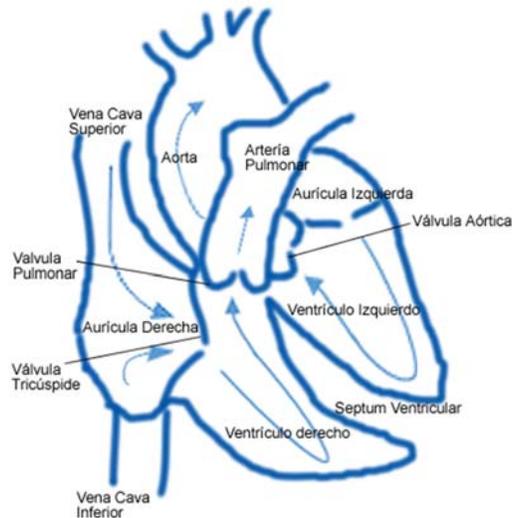


Figura 3. Estructuras del corazón fetal

Una imagen tomada en una vista de cuatro cámaras, con las respectivas estructuras cardiacas, es mostrada en la Figura 4. Como se puede notar, las aurículas son similares en su tamaño y están separadas por el septum de la aurícula. La fosa oval debe abrir hacia la aurícula izquierda. También, en esta parte se localiza el septum primum, el cual hace parte de la cruz cardiaca. Esta última es donde se encuentran la parte inferior del septum auricular y la parte superior del tabique ventricular. A su vez, ambos ventrículos tienen aproximadamente igual tamaño, pero a medida que avanza la etapa gestacional el lado derecho del corazón se vuelve más grande. Las válvulas tricúspide y mitral se encuentran ubicadas en el lado derecho e izquierdo, respectivamente. Así mismo, en esta vista se puede visualizar la aorta descendente en la parte izquierda de la espina [62]. Este examen se realiza durante el segundo trimestre de gestación, usualmente entre las semanas 18 y 22. Este estudio de ultrasonido nos permite una evaluación amplia y detallada de la función cardiaca fetal, en la que se busca la identificación de anomalías que afectan al feto.

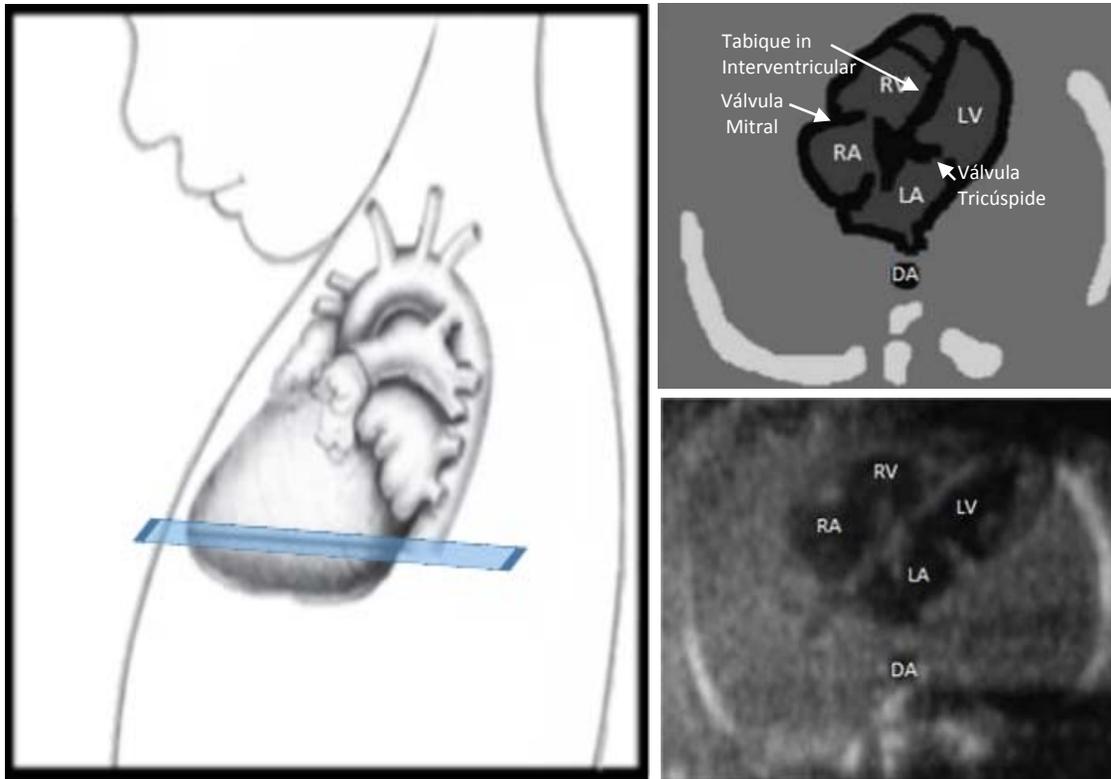


Figura 4. Vista de cuatro cámaras del corazón fetal, LA = aurícula izquierda, LV = ventrículo izquierdo, RA = aurícula derecha, RV = ventrículo derecho, DA = aorta descendente.

3. LA TRANSFORMADA DE HERMITE

La transformada de Hermite es una herramienta de descomposición que ha sido de mucha utilidad en el análisis de imágenes [1], [63], [64], [65], [66], [67], [68], [69]. Esta transformada incorpora propiedades significativas del sistema visual humano, tales como análisis direccional local y el modelo de derivadas de Gaussianas, propio de la visión temprana [1], [63], [70], [71]. Adicionalmente, esta transformada permite codificar detalles relevantes de las imágenes, los cuales pueden ser muy útiles en el desarrollo de aplicaciones médicas [64], [65], [72]. Los polinomios de Hermite son usados como las funciones base de la descomposición, los cuales son ortogonales con respecto a una función Gaussiana. En una dimensión, esta propiedad de ortogonalidad se expresa como

$$\int_{-\infty}^{\infty} V^2(x)G_n(x)G_m(x)dx = \delta_{nm} \quad (1)$$

donde $V(x) = \frac{1}{\sqrt{\pi}\sigma} e^{-x^2/2\sigma^2}$ corresponde a la función Gaussiana con desviación estándar σ , y $G_n(x) = \frac{1}{\sqrt{2^n n!}} H_n(x/\sigma)$ son los polinomios de Hermite normalizados y ortogonales con respecto a $V^2(x)$. La transformada de Hermite unidimensional permite obtener la descomposición de una función $L(x)$ usando la siguiente expresión

$$L_n(kT) = \int_{-\infty}^{\infty} L(x)G_n(x - kT)V^2(x - kT)dx \quad (2)$$

donde $L_n(kT)$ son los coeficientes de Hermite. El orden de la transformada es definido por n . Los coeficientes pueden ser obtenidos por la convolución entre la función $L(x)$ y los filtros, y luego submuestreando en las posiciones kT . Los filtros son calculados como

$$D_n(x) = G_n(-x)V^2(-x) \quad (3)$$

Haciendo uso de las propiedades de los polinomios de Hermite, los filtros se pueden escribir como

$$D_n(x) = \frac{1}{\sqrt{2^n n!}} \left[\frac{d^n}{d(x/\sigma)^n} \left(\frac{1}{\sigma\sqrt{\pi}} e^{-(x/\sigma)^2} \right) \right] \quad (4)$$

En dos dimensiones, la definición de la transformada de Hermite es similar. Sea $L(x, y)$ una función continua arbitraria, su transformada de Hermite es calculada como

$$L_{m,n-m}(p, q) = \iint_{-\infty}^{\infty} L(x, y) G_{m,n-m}(x - p, y - q) V^2(x - p, y - q) dx dy \quad (5)$$

donde $V^2(x, y) = \left(\frac{1}{(\sigma\sqrt{\pi})^2} e^{-(x^2+y^2)/\sigma^2} \right)$ es la ventana Gaussiana definida en un espacio bidimensional, $G_{m,n-m}(x, y) = \frac{1}{\sqrt{2^n(n-m)!} m!} H_m(x/\sigma) H_{n-m}(y/\sigma)$ son los polinomios de Hermite normalizados en dos dimensiones, y $L_{m,n-m}(p, q)$ son los coeficientes de la transformada, los cuales son llamados comúnmente como *Coefficientes Cartesianos de Hermite*. Además, $n = 1, 2, \dots, \infty$ y $m = 0, 1, \dots, n$ siendo n el orden de la transformada. Análogamente, de la definición anterior se puede inferir que la transformada de Hermite en dos dimensiones puede ser obtenida por medio de un proceso de convolución y submuestreo en las posiciones (p, q) . Por consiguiente, los filtros de Hermite en dos dimensiones están definidos como

$$D_{m,n-m}(x, y) = G_{m,n-m}(-x, -y) V^2(-x, -y) \quad (6)$$

Reemplazando,

$$D_{m,n-m}(x, y) = \frac{1}{\sqrt{2^n(n-m)!} m!} \left[\frac{d^m}{d(x/\sigma)^m} \frac{d^{m-n}}{d(y/\sigma)^{m-n}} V^2(x, y) \right] \quad (7)$$

Un esquema gráfico del proceso de descomposición se ilustra en la Figura 5. Los coeficientes obtenidos son agrupados como se ilustra en la Figura 6. En este esquema, los coeficientes se agrupan dependiendo del orden de la transformada.

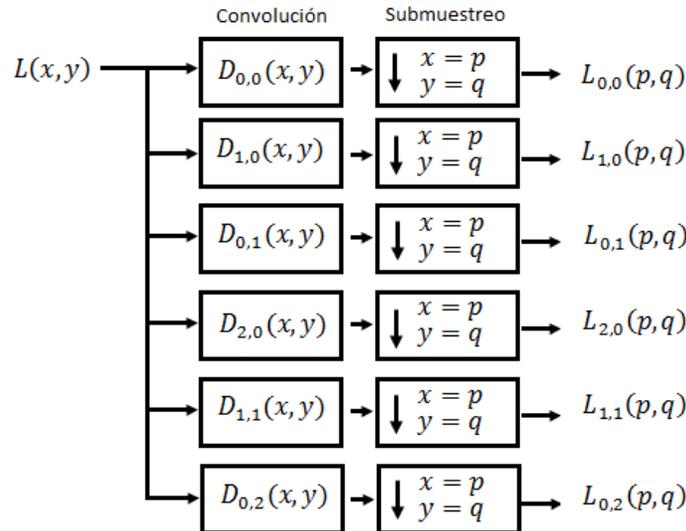


Figura 5. Proceso de descomposición de la transformada de Hermite.

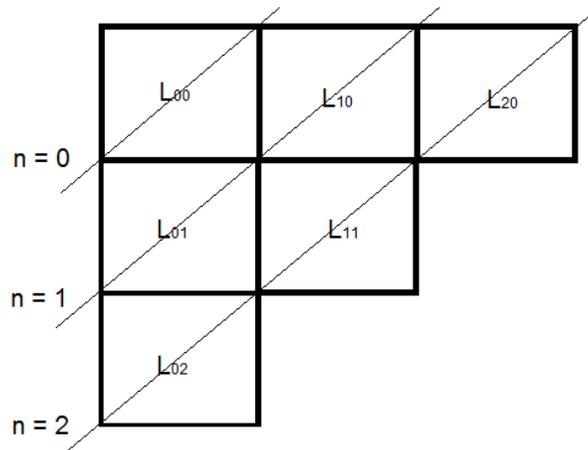


Figura 6. Arreglo gráfico para los coeficientes de Hermite hasta el segundo orden.

De la ecuación 7 se puede observar que los filtros de Hermite corresponden a derivadas de Gaussianas. En la Figura 7 se ilustra la forma de estos filtros en dos dimensiones. El coeficiente de Hermite de orden cero corresponde a una versión suavizada de la función original, mientras que los coeficientes de primer orden son útiles para detectar cambios bruscos de la función de entrada, que en el caso de las imágenes corresponden a los bordes de las mismas. Los coeficientes de segundo orden son eficientes para detectar cruces por cero. En general, los coeficientes de orden $n \geq 1$ son útiles para codificar texturas en aplicaciones de imágenes.

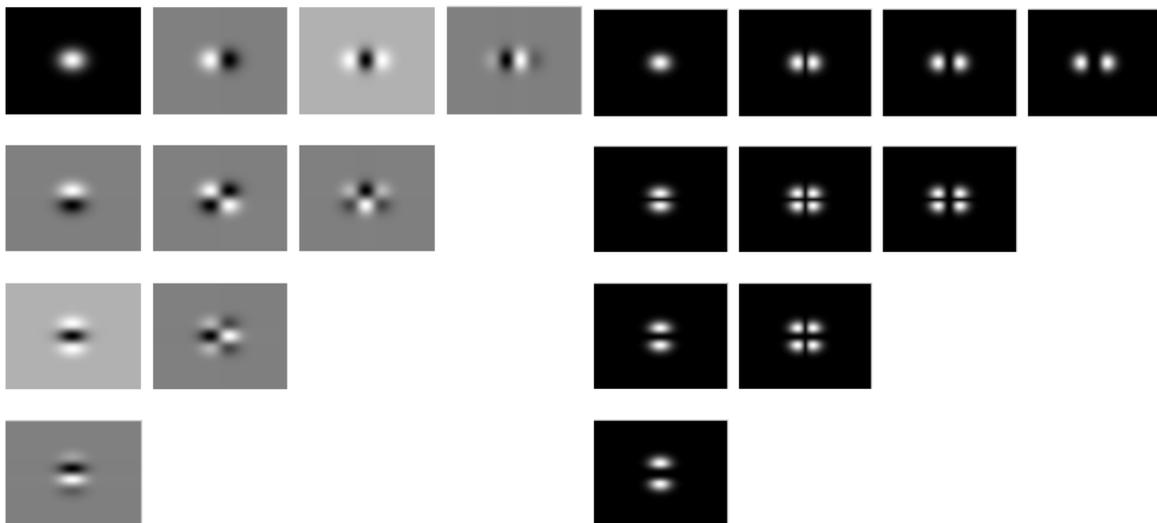


Figura 7. Filtros de Hermite en dos dimensiones. a. Filtros en el dominio espacial, b. Filtros en el dominio de la frecuencia.

Un ejemplo de los coeficientes de Hermite hasta el segundo orden obtenidos para una imagen de ecocardiografía fetal se visualiza en la Figura 8.

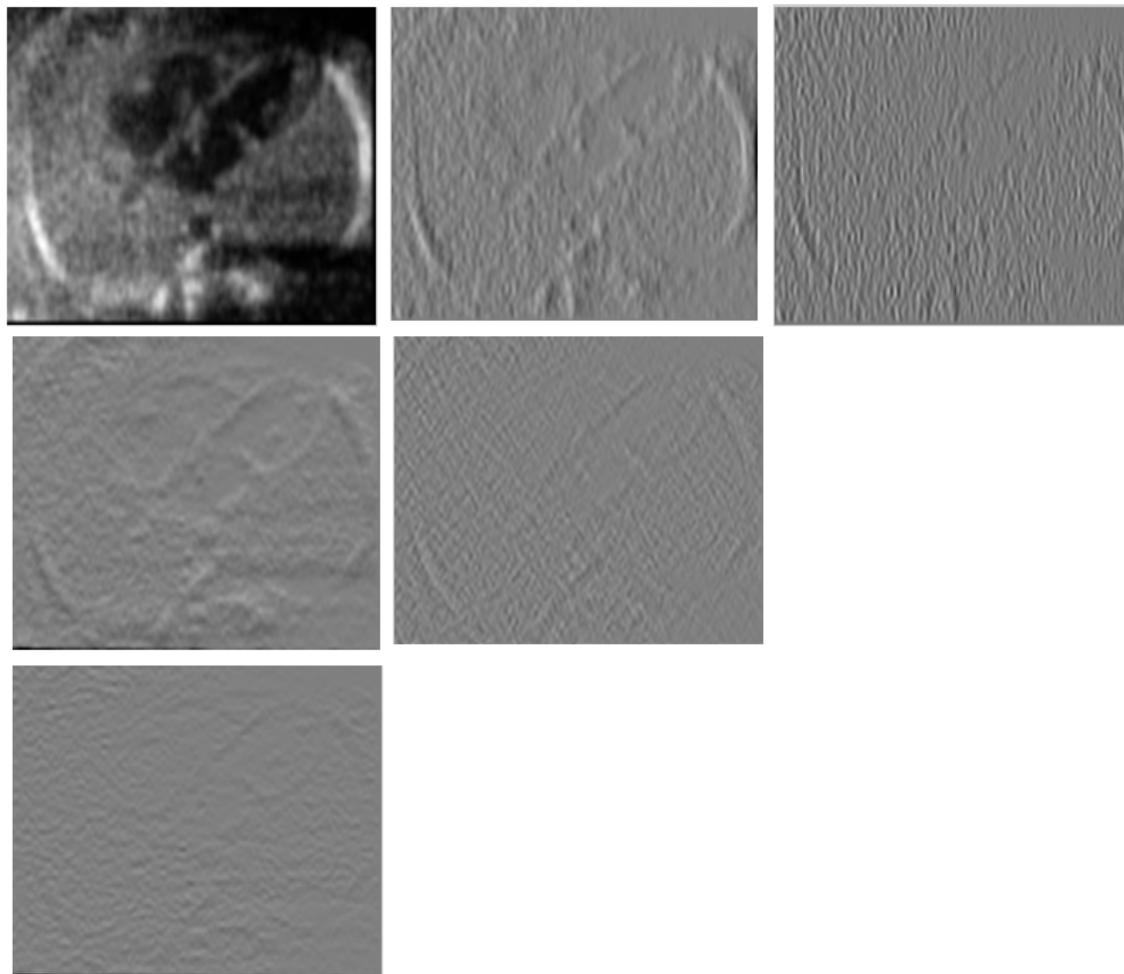


Figura 8. Coeficientes de Hermite hasta el segundo orden obtenidos para una imagen de ecocardiografía fetal tomada en una vista de cuatro cámaras.

3.1. LA TRANSFORMADA DE HERMITE ROTADA EN DOS DIMENSIONES

Una de las principales características de la transformada de Hermite es que permite realizar análisis direccional, lo cual resulta de mucha utilidad cuando se buscan resaltar características unidimensionales en las imágenes. Para este análisis direccional se calculan los coeficientes rotados de Hermite a partir de los coeficientes cartesianos. Esto se puede hacer mediante una combinación lineal de los coeficientes cartesianos obtenidos previamente [68], [69]. Luego, los coeficientes quedan orientados a un ángulo específico.

El desarrollo matemático para la rotación se hace en el dominio de la transformada de Fourier. Los coeficientes son separados en el dominio espacial y polar. Luego, los filtros de Hermite puede ser definidos como

$$d_m(w_x)d_{n-m}(w_y) = q_{m,n-m}(\theta)d_n(w) \quad (8)$$

donde $w_x = w \cos \theta$, $w_y = w \sin \theta$. También, d_m y d_{n-m} representan las transformadas de Fourier de los filtros unidimensionales aplicados sobre cada eje de coordenadas. Luego, tenemos que la transformada de Fourier del filtro expresada en frecuencia radial es

$$d_n(w) = \frac{1}{\sqrt{2^n n!}} (-jw\sigma)^n e^{-\frac{(w\sigma)^2}{4}} \quad (9)$$

La orientación del filtro está dada por

$$q_{m,n-m}(\theta) = \sqrt{\binom{n}{m}} \cos^m \theta \sin^{n-m} \theta \quad (10)$$

Considerando la orientación en frecuencia, la propiedad de direccionalidad de los filtros de Hermite puede ser definida por

$$q_{m,n-m}(\theta - \theta_0) = \sum_{i=0}^n c_{m,i}^{(n)}(\theta_0) q_{n-i,i}(\theta) \quad (11)$$

donde $c_{m,i}^{(n)}(\theta_0)$ son los coeficientes usados para llevar a cabo el proceso de rotación. Finalmente, los coeficientes de Hermite rotados pueden ser obtenidos con la siguiente expresión

$$L_{m,n-m,\theta} = \sum_{i=0}^n q_{i,n-i} L_{i,n-i} \quad (12)$$

donde $L_{i,n-i}$ son los coeficientes cartesianos y $L_{m,n-m,\theta}$ son los coeficientes rotados. En la Figura 9 se pueden observar los coeficientes rotados para el ejemplo de la imagen de ecocardiografía fetal. Estos fueron obtenidos a partir de los coeficientes cartesianos mostrados previamente en la Figura 8. Es de anotar que la rotación permite concentrar toda la energía sobre los primeros coeficientes de cada orden. Esto se puede considerar como un proceso de filtrado si se asume que la información contenida en los otros coeficientes es ruido.

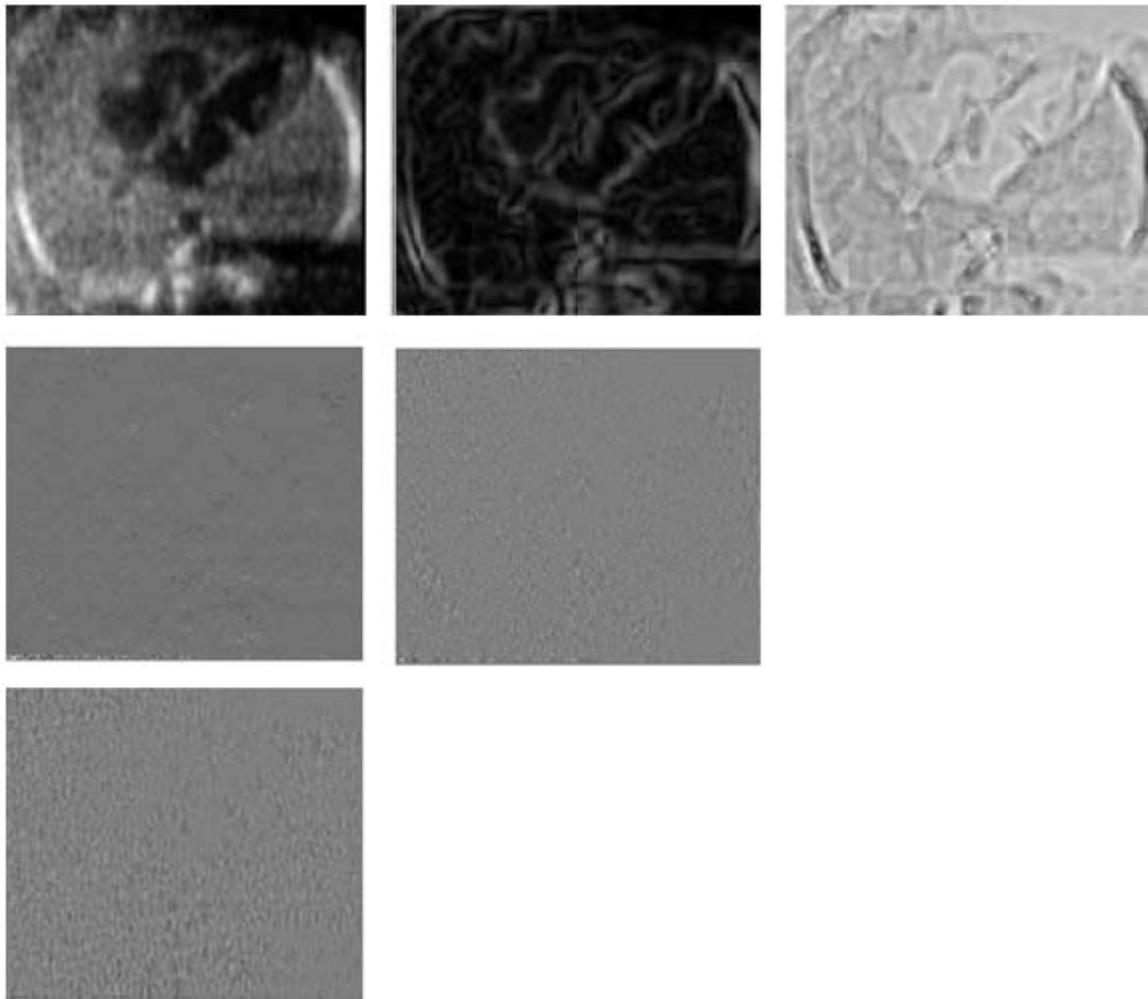


Figura 9. Coeficientes rotados de la transformada de Hermite obtenidos a partir de los coeficientes cartesianos de la Figura 8.

4. ALGORITMO DE SEGMENTACIÓN AAM MULTI-TEXTURA BASADO EN LA TRANSFORMADA DE HERMITE ROTADA

En este capítulo se describe el algoritmo desarrollado para la segmentación del ventrículo izquierdo en ecocardiografía fetal. El método consiste de un modelo de apariencia activa basado en la transformada de Hermite rotada. Básicamente, los coeficientes de Hermite rotados son usados como parámetros de textura en el modelo de apariencia. Los coeficientes rotados, los cuales concentran la máxima energía hasta el segundo orden, son combinados en un esquema multi-textura basado en un método AAM. Aquí se aprovechan las propiedades de la transformada de Hermite para extraer diferentes tipos de información de textura del objeto bajo estudio. El esquema general del método detallado se muestra en la Figura 10.

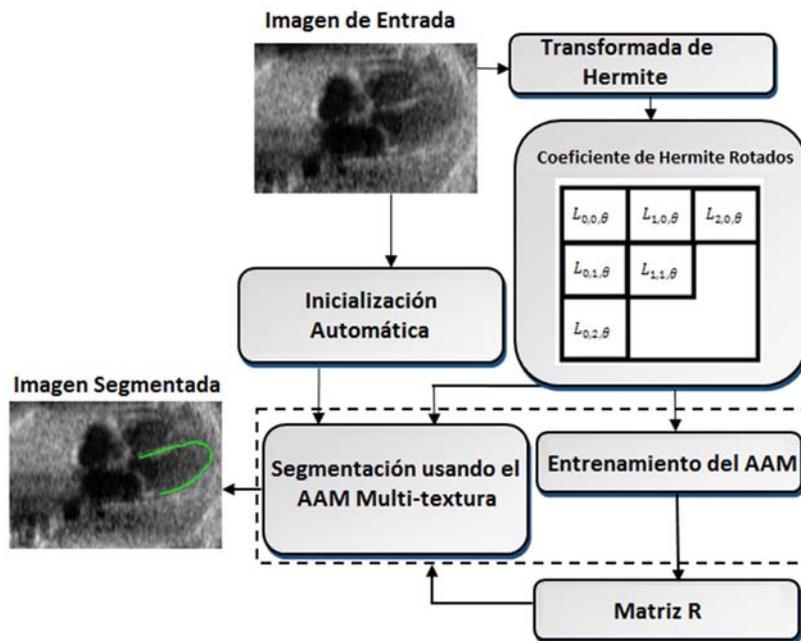


Figura 10. Diagrama del método AAM multi-textura propuesto.

El método desarrollado consta de varias etapas, tal como se ilustra en la Figura 10. La etapa principal consiste de un método AAM multi-textura, el cual utiliza diferentes coeficientes de la transformada de Hermite rotada. En el proceso se construyen tres modelos de apariencia individuales, los cuales

codifican diferentes tipos de información de textura. Esta información es obtenida de una etapa previa, la cual está conformada por la transformada de Hermite, cuyas características, definiciones y propiedades fueron expuestas en el capítulo 3. Esta transformada suministra la información de textura necesaria para cada modelo de apariencia. Dada la naturaleza local de los algoritmos basados en AAMs, se hace necesario contar con una buena inicialización para el proceso de segmentación. Para este propósito, se diseñó un algoritmo automático de inicialización en el cual se combinan técnicas de umbralización, morfología matemática y correlación para encontrar la posición de la forma inicial del ventrículo izquierdo en la imagen de ecocardiografía fetal. Este algoritmo de inicialización requiere de una base de datos con ejemplos marcados que muestren las posibles variaciones que puede tener el ventrículo izquierdo en este tipo de imágenes. Las etapas correspondientes al método de inicialización y al AAM multi-textura son expuestas en este capítulo.

4.1. BASE DE DATOS PARA EL ALGORITMO DE INICIALIZACIÓN

Esta base de datos se construyó con parches de imágenes reales de ecocardiografía fetal usando una vista de cuatro cámaras. Como se mencionó, en esta vista se pueden apreciar las cuatro cavidades del corazón y la aorta descendente. En la Figura 4 se muestra un ejemplo de las estructuras cardiacas en este tipo de imágenes. La base de datos está conformada por parches de la región completa del corazón, la cual incluye las cavidades cardiacas y la aorta. Estos parches fueron seleccionados de un conjunto de imágenes de entrenamiento, las cuales, además, fueron manualmente segmentadas por los expertos. Esta segmentación manual se hizo sobre el ventrículo izquierdo, el cual es el objeto de análisis en este proyecto.

Además, con estos parches se busca cubrir todas las posibles variaciones tanto en tamaño como en orientación de las estructuras cardiacas. Esto se logró haciendo un escalamiento y rotando a varios ángulos cada una de las imágenes utilizadas. Para construir la base de datos, se tomaron 15 imágenes de entrenamiento y luego fueron rotadas usando 17 ángulos en un rango de $[0, 2\pi]$. Adicionalmente, cada una de las imágenes resultantes fueron escaladas usando dos escalas para cada imagen. Finalmente, la base de datos consiste de un número total de 510 parches, los cuales fueron obtenidos después de realizar el procedimiento descrito. Ejemplos de los parches de esta base de datos se puede ver en la Figura 11. Aquí se ilustran las estructuras cardiacas fetales con diferentes orientaciones y tamaños. La Figura 11a muestra que los parches fueron rotados 17 veces, cada 21 grados aproximadamente, para cubrir las posibles variaciones en cuanto a la orientación. Para cada imagen de la base de datos se usan dos escalas, lo que permite cubrir las posibles variaciones en cuanto al tamaño. No obstante, para construir la base de datos se consideraron imágenes de las diferentes fases del ciclo cardiaco entre sístole y diástole. La diástole es la fase donde el ventrículo izquierdo está más expandido y exhibe mayor tamaño, mientras que la sístole es cuando el ventrículo está más contraído. En la Figura 11b se muestran ejemplos de los parches escalados para las fases de sístole y diástole del ciclo cardiaco, respectivamente. Una vez que la base de datos es almacenada, es utilizada posteriormente en el proceso de inicialización del método de segmentación.

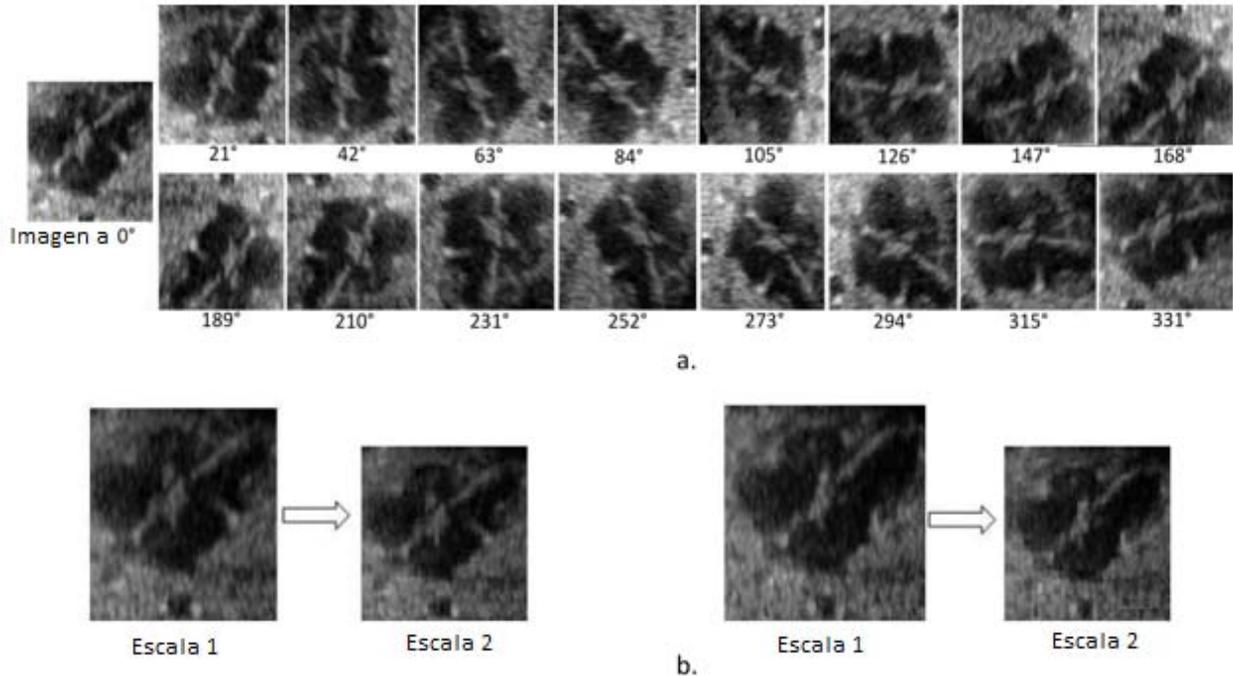


Figura 11. Ejemplos de imágenes de la base de datos usada para la etapa de inicialización, a. Parches de una de las imágenes rotada a 17 ángulos diferentes, b. Parche de la imagen original e imagen escalada en la fase de sístole (izquierda) y fase de diástole (derecha) del ciclo cardiaco.

4.2. INICIALIZACIÓN

Un aspecto que se debe tener en cuenta cuando se emplean modelos de apariencia activa es la naturaleza local del método, lo cual implica que el proceso de inicialización sea algo fundamental. La inicialización puede ser un problema crítico para el desempeño de estos métodos. Ésta tiene que ser lo suficientemente cercana a la estructura para lograr una segmentación aceptable. Por tal razón, se diseñó un método de inicialización automático que localice la estructura deseada, es decir, la posición del ventrículo izquierdo en la imagen de ultrasonido del corazón de feto. Durante el proceso de adquisición, las cavidades cardiacas pueden exhibir diferentes orientaciones en la imagen de ultrasonido debido a diversas razones, tales como la posición del feto o del transductor. Esto llega a ser un gran reto para la inicialización automática. El tamaño de la región cardiaca, así como la forma del ventrículo, es también una característica importante que se tiene en cuenta durante este proceso. Tres diferentes imágenes adquiridas son mostradas en la Figura 12. En estas imágenes se observa la variación tanto en tamaño como en orientación de las cavidades cardiacas.

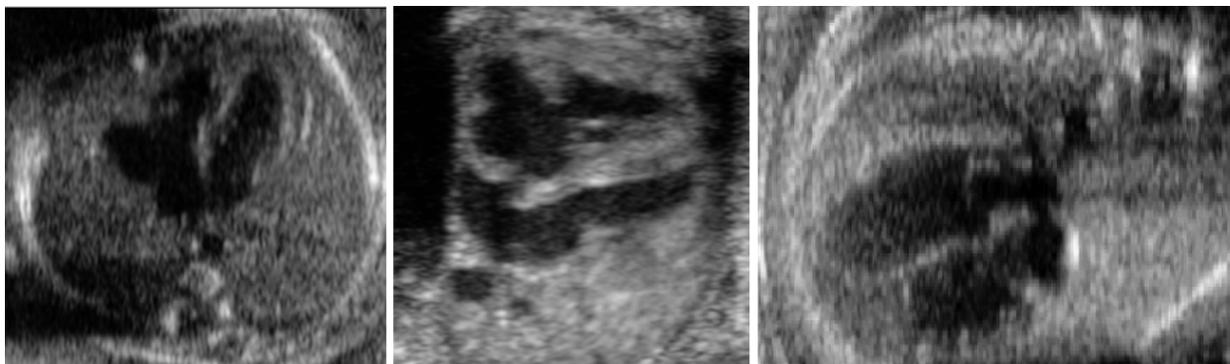


Figura 12. Ecocardiografías fetales con diferentes orientación y tamaño de la región cardiaca.

El esquema general del algoritmo de inicialización se muestra en la Figura 13. El proceso se lleva a cabo a través de tres etapas que serán descritas a continuación.

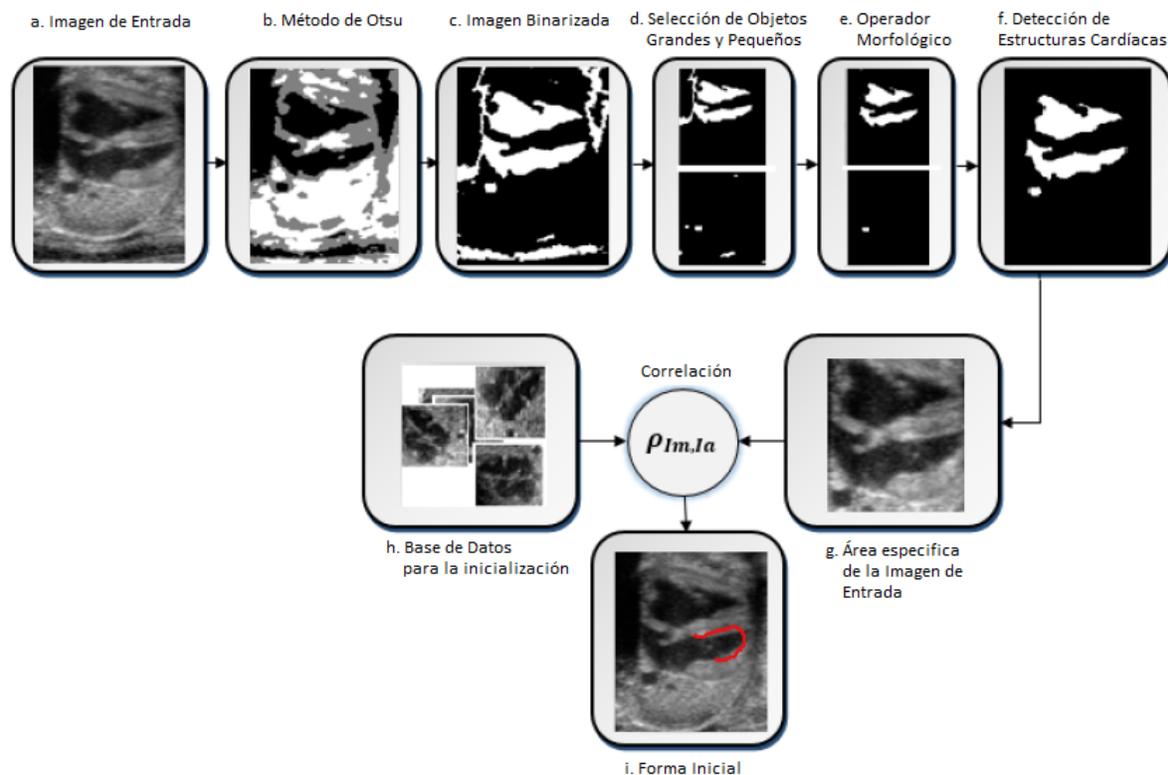


Figura 13. Diagrama general del algoritmo de inicialización para el ventrículo izquierdo.

4.2.1. Detección de la región de interés

Las cavidades del corazón deben ser detectadas dentro de la imagen de ultrasonido. Para esto se usa la técnica de umbralización de Otsu, con la cual se divide la imagen en diferentes clases. Cuatro

regiones son identificadas, entre las cuales están el fondo de la imagen, las estructuras cardiacas que incluyen las cuatro cavidades y la aorta, los músculos y los huesos. La Figura 13b muestra las clases en las cuales se divide la imagen. La segunda clase obtenida corresponde a la región cardiaca.

El siguiente paso es binarizar la imagen con respecto a la clase seleccionada. El proceso es ilustrado en la Figura 13c. En esta etapa se procede a clasificar las estructuras de mayor y menor tamaño, las cuales son seleccionadas de la imagen binaria con el objetivo de encontrar las estructuras cardiacas, tal como se muestra en la Figura 13d. La imagen aún presenta algunos artefactos que no corresponden a las estructuras, por lo cual se aplica morfología matemática en busca de removerlos (Figura 13e). Finalmente, las estructuras de mayor área corresponden a las cavidades. También, la aorta descendente es el objeto con menor área que a su vez se encuentra más cercano a las estructuras cardiacas. La imagen binaria final está compuesta por las estructuras cardiacas y la aorta, tal como se ilustra en la Figura 13f.

4.2.2. Correlación basada en correspondencias

La región de interés detectada en el paso anterior ayuda a identificar las estructuras cardiacas en la imagen original. Por lo tanto, esta región se mapea a la imagen original lo que permite seleccionar el parche que incluya las estructuras cardiacas, ver Figura 13g. Esta región es correlacionada con cada parche de la base de datos almacenada previamente. El parche de mayor correspondencia con la región seleccionada es el que se toma como referencia.

4.2.3. Selección de la forma inicial

Finalmente, la forma inicial del ventrículo izquierdo se toma del parche de referencia obtenido en el paso anterior. Es de anotar que las coordenadas de la forma inicial de cada parche son previamente conocidas. El resultado de la forma inicial es mostrado en la Figura 13i.

4.3. SEGMENTACIÓN USANDO MODELOS DE APARIENCIAS ACTIVAS (AAMs)

El método desarrollado consiste de un esquema AAM multi-textura basado en la transformada de Hermite. En esta sección se describe el método AAM clásico el cual sirve de base para el esquema multi-textura desarrollado.

4.3.1. Modelo de apariencia activa (AAM)

Este método fue desarrollado por Cootes et al. [12] y en él se trata de obtener un modelo estadístico, construido mediante un proceso de entrenamiento. Con el método se busca codificar las posibles variaciones de forma y textura del conjunto de entrenamiento. Con el objetivo de construir el modelo estadístico, es necesario contar con un conjunto relativamente alto de ejemplos de las formas y estructuras que se quieren analizar. En el modelo de apariencia activa no solo se debe considerar la forma sino también la textura que caracteriza a los objetos de análisis. La mayor ventaja de este método es que solo permite segmentar formas y objetos conocidos. El método

consiste básicamente de tres etapas. En la primera es necesario obtener un modelo estadístico de las formas de entrenamiento. A este modelo normalmente se le conoce como Modelo de Distribución de Puntos. La segunda etapa busca crear un modelo de las texturas de los objetos de entrenamiento. La tercera etapa es una combinación de los dos modelos anteriores. Cada una de estas etapas se describe a continuación. La descripción se lleva cabo usando como ejemplo el ventrículo izquierdo de las imágenes cardiacas de ultrasonido fetal.

4.3.1.1. Modelo estadístico de forma

Para obtener el modelo estadístico de forma, normalmente llamado *Modelo de Distribución de Puntos* (PDM), debemos contar con un conjunto de N imágenes de entrenamiento previamente anotadas, X_i con $i = 1, 2, \dots, N$. Las formas en estas imágenes de entrenamiento deben tener la misma cantidad de puntos. Estos puntos son llamados en la literatura como *landmarks* (conocidos como *puntos fiduciaros*). Por lo tanto, cada forma es representada con un número m de puntos como

$$X_i = [F_{i1}, F_{i2}, \dots, F_{im}] \quad (13)$$

donde m corresponde a la cantidad de puntos de la forma y $F_{i\varphi} = (x_i, y_i)$ son las coordenadas espaciales de cada punto en la imagen, $\varphi = 1, 2, \dots, m$. En la Figura 14 se muestran dos imágenes del conjunto de entrenamiento con sus respectivos *landmarks*. Esos puntos constituyen la segmentación de la estructura de análisis hecha por el experto en las imágenes de entrenamiento.

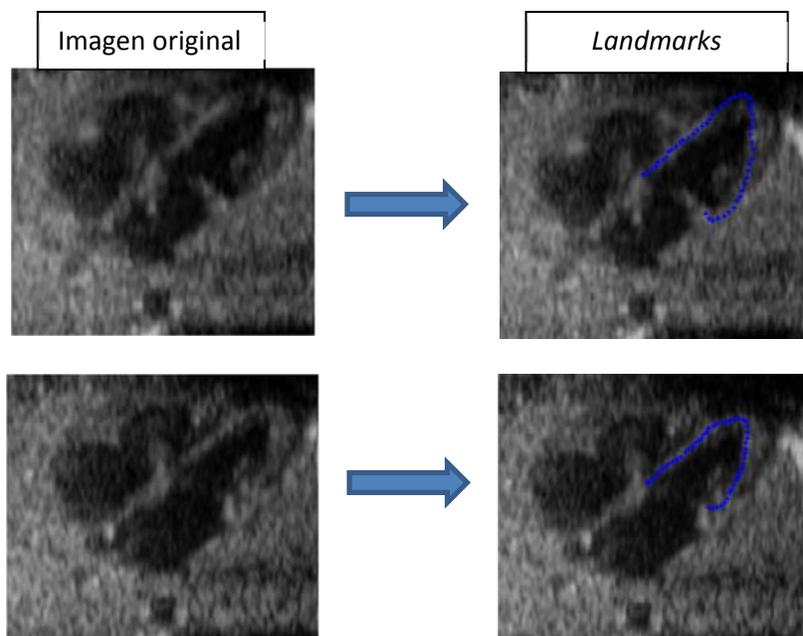


Figura 14. Landmarks que delimitan el objeto en imágenes del conjunto de entrenamiento.

Luego, se continúa con un proceso de alineamiento de estas formas. En el alineamiento se llevan a cabo transformaciones de escalamiento, rotación y traslación para alinear todas las formas de entrenamiento con respecto a una forma de referencia. La técnica de alineamiento más comúnmente usada es el método de Procrustes. Cootes et al. [12], [14] también desarrollaron un método de alineamiento para llevar a cabo esta tarea. En la Figura 15 se ilustra un ejemplo de un conjunto de formas alineadas. La idea del alineamiento es remover las diferencias en cuanto al escalamiento, orientación y desplazamiento.

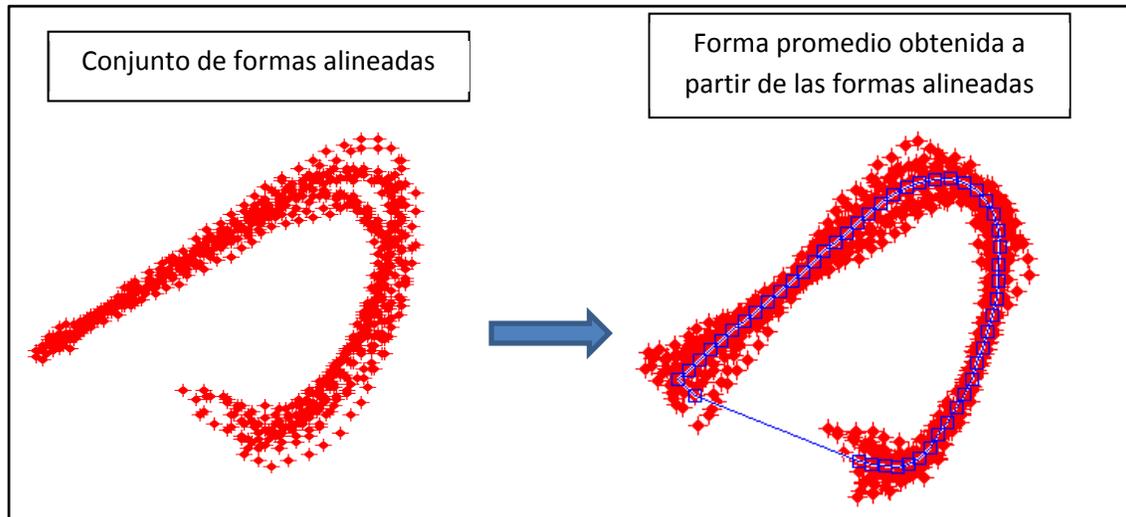


Figura 15. Ejemplo de formas alineadas y forma promedio. En rojo se visualizan los puntos de cada imagen ecocardiográfica alineada. En azul se ilustra la forma promedio.

Posteriormente se procede a obtener el modelo estadístico. Dado el conjunto de N formas alineadas S_i , la forma promedio \bar{S} es calculada como

$$\bar{S} = \frac{1}{N} \sum_{i=1}^N S_i \quad (14)$$

En la Figura 15 se ilustra un ejemplo de la forma promedio calculada a partir de un conjunto de formas alineadas. Los ejes principales de variación, en cada punto de la forma promedio, pueden ser calculados aplicando un análisis de componentes principales (PCA, sigla derivada de su nombre en inglés). Para cada forma alineada en el conjunto de entrenamiento, se calcula su desviación de la media dS_i ,

$$dS_i = S_i - \bar{S} \quad (15)$$

A continuación, se calcula la matriz de covarianza,

$$C = \frac{1}{N-1} \sum_{i=1}^N dS_i dS_i^T \quad (16)$$

De la matriz de covarianza C , se obtienen los eigenvectores correspondientes a los eigenvalores λ_s más significativos. Consecuentemente, el modelo de distribución de puntos de las formas asociadas al objeto de estudio corresponde a la forma promedio obtenida más la matriz Z que contiene los eigenvectores obtenidos del análisis PCA. Esta matriz de eigenvectores es multiplicada por un vector de pesos b el cual es llamado el parámetro de forma. El PDM es calculado como

$$S = \bar{S} + Z b \quad (17)$$

Con este modelo, cualquier forma en el conjunto de entrenamiento puede ser obtenida variando los coeficientes del vector b el cual es un parámetro que varía en el rango $-3\sqrt{\lambda_s} \leq b_s \leq 3\sqrt{\lambda_s}$. En la Figura 16 se observan algunos ejemplos de formas generadas al variar los primeros dos elementos del vector b .

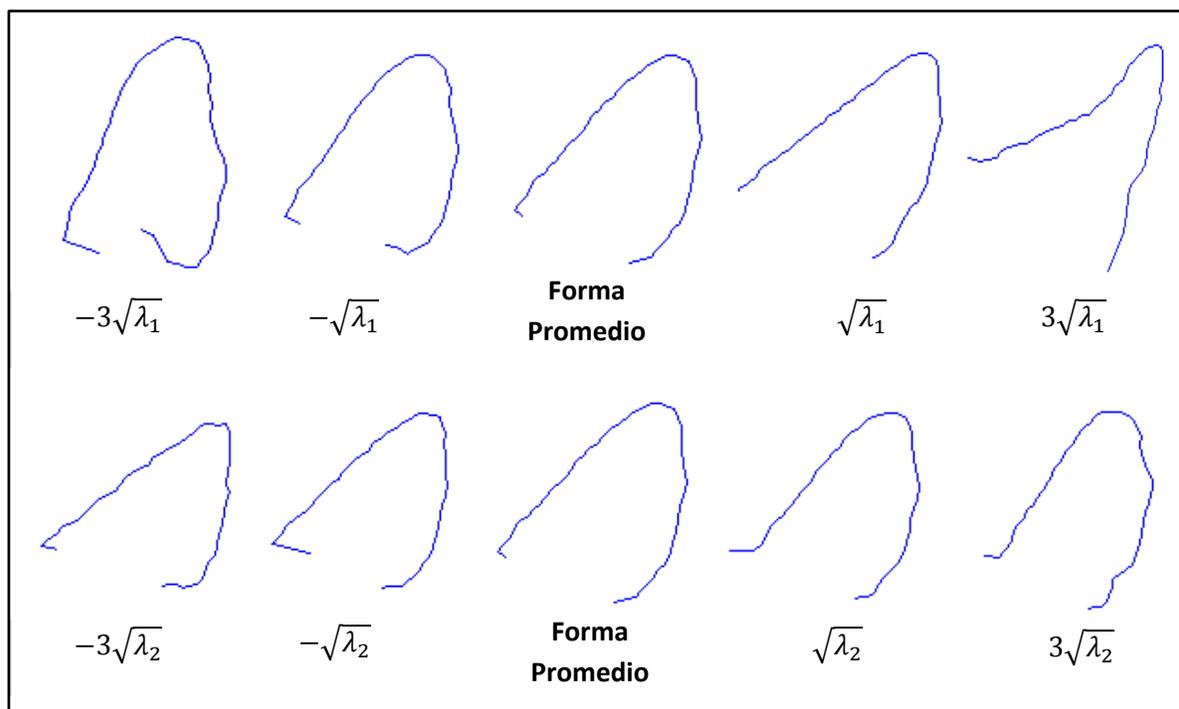


Figura 16. Ejemplo de formas obtenidas al variar el parámetro b .

4.3.1.2. Modelo estadístico de textura

El siguiente paso en la construcción del AAM es obtener el modelo estadístico de textura. Esta característica en las imágenes de entrenamiento, está dada por el vector de niveles de grises de cada objeto. La región encerrada por la forma se toma como el parche de textura a analizar. Luego, el vector de textura de cada objeto de entrenamiento se define como

$$G_i = [g_{i1}, g_{i2}, \dots, g_{ik}]^T \quad (18)$$

donde $i = 1, 2, \dots, N$, con N el número de muestras de entrenamiento, g_{iz} es el nivel de gris, $z = 1, 2 \dots k$ y siendo k el número de píxeles encerrados por la forma. En la Figura 17 se muestra un ejemplo de cómo se selecciona el parche de textura a partir de la forma que describe el objeto.

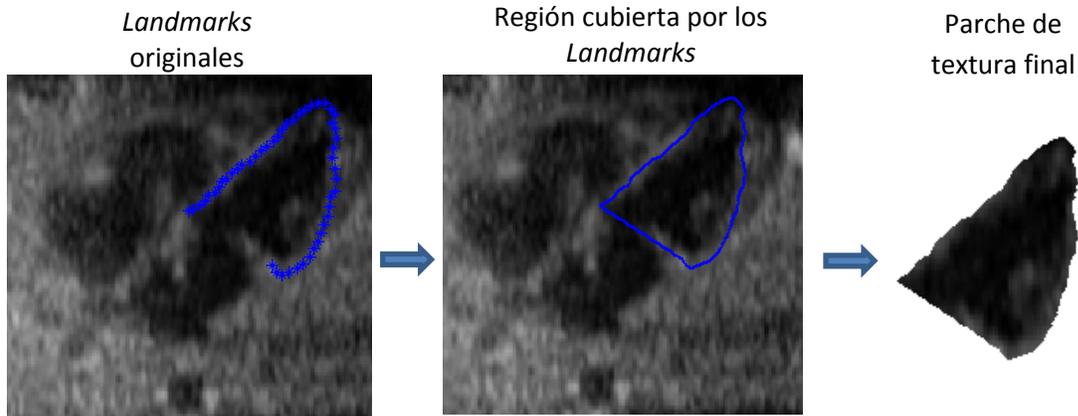


Figura 17. Selección del parche de textura en las imágenes de entrenamiento

El modelo estadístico de textura se obtiene de manera similar al caso anterior. Inicialmente, es necesario alinear los vectores de textura con respecto a una textura de referencia. Para esta tarea se utilizan algunas transformaciones afines [10], [73] y métodos de triangulación [74]. Una vez que los vectores de textura han sido alineados se obtiene la textura promedio, es decir

$$\bar{G} = \frac{1}{N} \sum_{i=1}^N \mathbb{G}_i \quad (19)$$

donde \mathbb{G}_i son las texturas alineadas. Siguiendo con las imágenes de ecocardiografía fetal, en la Figura 18 se observa la textura promedio \bar{G} obtenida usando un ejemplo del ventrículo izquierdo del corazón fetal. Esta textura promedio fue calculada usando las imágenes de entrenamiento.

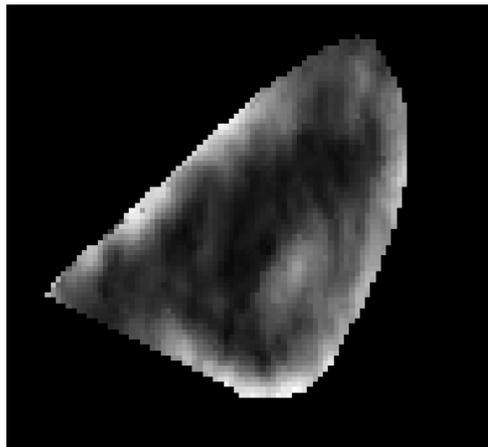


Figura 18. Ejemplo de textura promedio \bar{G} obtenida del conjunto de entrenamiento.

Posteriormente, es necesario realizar un análisis de componente principales para codificar los modos de variación de las texturas. Análogamente, se obtiene la matriz de covarianza R , es decir

$$\mathfrak{K} = \frac{1}{N-1} \sum_{i=1}^N (\mathbb{G}_i - \bar{\mathbb{G}})(\mathbb{G}_i - \bar{\mathbb{G}})^T \quad (20)$$

Entonces, aplicando PCA a \mathfrak{K} obtenemos la matriz de eigenvectores L correspondientes a los eigenvalores σ_n más significativos. Por lo general, se toman aquellos M eigenvalores cuya suma sea al menos 98%, es decir $\sum_{n=1}^M \sigma_n \geq 98\%$.

Finalmente, el modelo estadístico de textura es obtenido como

$$G = \bar{G} + Lr \quad (21)$$

donde r es el parámetro que permite deformar el modelo. Esta variable es conocida como el parámetro de textura y tiene un rango de variación definido por $-3\sqrt{\sigma_n} \leq r_n \leq 3\sqrt{\sigma_n}$.

Algunas texturas obtenidas al variar tres elementos de este parámetro se ilustran en la Figura 19.

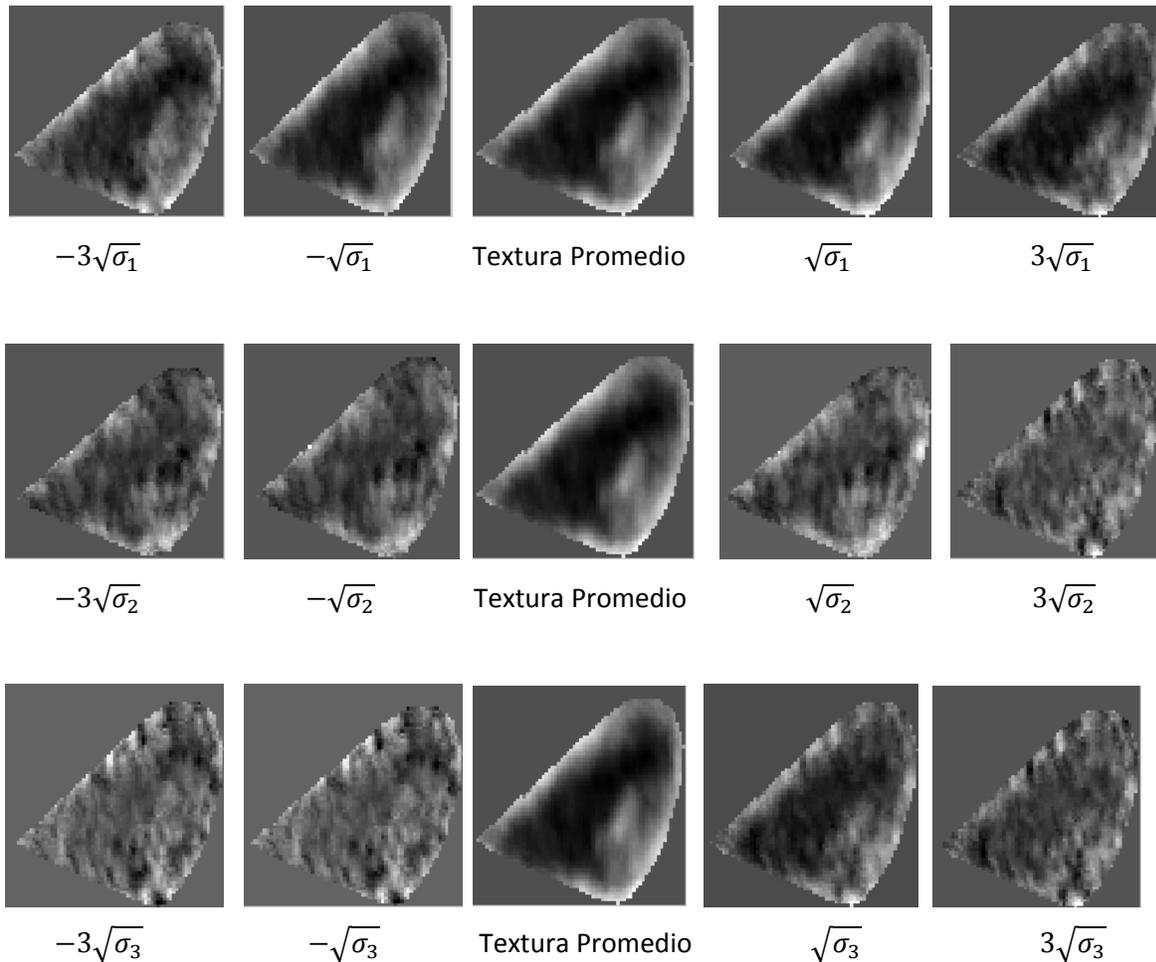


Figura 19. Texturas obtenidas al variar tres elementos de r .

4.3.1.3. Combinación de los modelos estadísticos de forma y textura

Finalmente, para obtener el AAM se combinan los dos modelos descritos anteriormente (forma y textura) para hacer un modelo más robusto. Aquí es necesario hacer una concatenación entre el parámetro de forma b y el de textura r . Luego,

$$h = \begin{bmatrix} \rho b \\ r \end{bmatrix} = \begin{bmatrix} \rho \mathbb{Z}^T (S_i - \bar{S}) \\ L^T (G_i - \bar{G}) \end{bmatrix} \quad (22)$$

El término ρ es una matriz de pesos que nos permite compensar las diferencias en los rangos de variación de b y r , debido a que uno sirve para modificar las coordenadas de las formas y el otro para variar las texturas.

En este proceso se realiza un tercer análisis de componentes principales sobre el modelo combinado. Luego, como resultado de este análisis, se obtiene el modelo final como

$$h = Qc \quad (23)$$

donde Q es el conjunto de eigenvectores correspondientes a los eigenvalores ϑ_f más significativos, y c es el parámetro final el cual sirve para modificar los modelos de forma y textura al mismo tiempo. Análogamente, este parámetro varía en el rango $-3\sqrt{\vartheta_f} \leq c_f \leq 3\sqrt{\vartheta_f}$. Usando este modelo, los otros modelos de forma y textura se pueden obtener debido a la naturaleza lineal del método. Ahora, las ecuaciones modificadas en los modelos de forma y textura se escriben como

$$S = \bar{S} + \mathbb{Z} \rho^{-1} Q_S c \quad (24)$$

$$G = \bar{G} + L Q_G c \quad (25)$$

donde Q_S es la matriz de eigenvectores para el modelo de forma y Q_G es la matriz de eigenvectores para el modelo de textura. El conjunto de eigenvectores Q puede ser expresado como

$$Q = \begin{bmatrix} Q_S \\ Q_G \end{bmatrix} \quad (26)$$

4.3.1.4. Segmentación con AAM

En la segmentación de nuevos ejemplos usando AAM es necesario encontrar el parámetro c que mejor ajusta el modelo entrenado a la imagen de entrada. Este parámetro es el encargado de guiar los modelos de forma y textura en el proceso de segmentación. La diferencia entre el modelo de

textura estadístico y la imagen de prueba debe ser minimizada. Esto puede ser expresado como el vector diferencia δI el cual se escribe como

$$\delta I = I_{imagen\ actual} - I_{imagen\ del\ modelo} \quad (27)$$

El algoritmo original de ajuste fue desarrollado por Edward et al. [11] y posteriormente mejorado por Cootes et al. [12]. Este método calcula la diferencia δI para estimar el parámetro c en cada iteración. Una matriz R de regresión lineal tiene que ser calculada previamente en el entrenamiento, donde se utiliza un método de regresión múltiple para realizar la búsqueda. Esta matriz codifica las posibles variaciones con respecto a los parámetros de textura (niveles de intensidad) y de forma (rotación, escalamiento y desplazamientos). Luego, las nuevas formas y texturas pueden ser calculadas usando las ecuaciones (24) y (25). El proceso es iterativo y el resultado de una iteración es usado como inicialización para la siguiente.

4.4. AAM MULTI-TEXTURA BASADO EN LA TRANSFORMADA DE HERMITE ROTADA

Por lo general, el modelo de apariencia activa es utilizado sobre la imagen original. Sin embargo, los cambios de intensidades y el *speckle* presente en las imágenes de ultrasonido pueden reducir el desempeño de la segmentación cuando se usa la textura de la imagen original. En diversos trabajos en la literatura, se ha demostrado que codificar la textura original de la imagen (datos en crudo), con el fin de construir el modelo de apariencia activa, puede llevar a algunas inexactitudes durante la búsqueda y ajuste del modelo [70], [75], [76]. Este problema es aún mayor cuando se trabaja con imágenes de ecocardiografía fetal. Aquí, el patrón de *speckle* y algunos artefactos degradan significativamente la calidad de las imágenes haciendo casi imposible determinar y extraer características como bordes y regiones homogéneas. En [77] se discutió ampliamente el efecto de usar varios patrones de textura en algoritmos AAM. Esto ha permitido mejorar el comportamiento del modelo de apariencia en comparación con el uso de datos en un espacio original. Adicionalmente, se obtiene un nivel de robustez mayor cuando los patrones de textura son obtenidos y codificados en otro espacio de representación. Esto es logrado mediante el uso de diferentes transformadas [70], [78], [79], [80]. Algunos métodos que combinan transformadas con AAM han sido propuestos con el objetivo de codificar diferentes características de las texturas presentes en las imágenes. Entre las principales transformadas utilizadas para este propósito están Gabor y Wavelet, las cuales han sido empleadas para tareas de segmentación en diferentes aplicaciones [70], [79], [80]. No obstante, el procedimiento común para abordar los problemas generados por el *speckle* en este tipo de imágenes ha sido utilizar técnicas de filtrado. Sin embargo, existe una tendencia reciente de aprovechar las características de los patrones de *speckle* para lograr extraer información implícita en él, en lugar de usar técnicas de reducción de ruido [81], [82]. La justificación es que puede haber mucha información relevante, en relación con las estructuras, que se perdería o modificaría si se aplica un proceso de filtrado.

Por las razones expuestas, en este proyecto se desarrolló un esquema AAM multi-textura usando la transformada de Hermite rotada. Como se mencionó, con esta transformada se codifican diferentes patrones de textura de las imágenes de entrada. Este método ha sido diseñado para ser aplicado en las imágenes cardiacas de ultrasonido fetal.

El modelo AAM multi-textura es construido con los coeficientes rotados de Hermite hasta el segundo orden, los cuales concentran la máxima energía, es decir $L_{0,0}$, $L_{1,0,\theta}$ y $L_{2,0,\theta}$. Para este propósito, un esquema AAM es creado para cada coeficiente. Luego, estos modelos se combinan con el objetivo de obtener una segmentación eficiente. Tres texturas diferentes son usadas, las cuales codifican información de intensidad, gradiente y cruces por cero. El esquema propuesto suministra un método robusto, en el cual la segmentación analiza tres diferentes tipos de características. En este método se llevan a cabo dos procesos principales. El primero de ellos consiste en construir un AAM para cada coeficiente de Hermite rotado. Esto implica calcular la transformada de Hermite rotada para cada imagen del conjunto de entrenamiento y entonces construir un AAM para cada coeficiente seleccionado.

En la Figura 20 se presentan algunos ejemplos de los modos de variación para los modelos de textura creados a partir de los coeficientes de Hermite rotados. El ejemplo es presentado para una imagen de ecocardiografía fetal donde se analiza el ventrículo izquierdo.

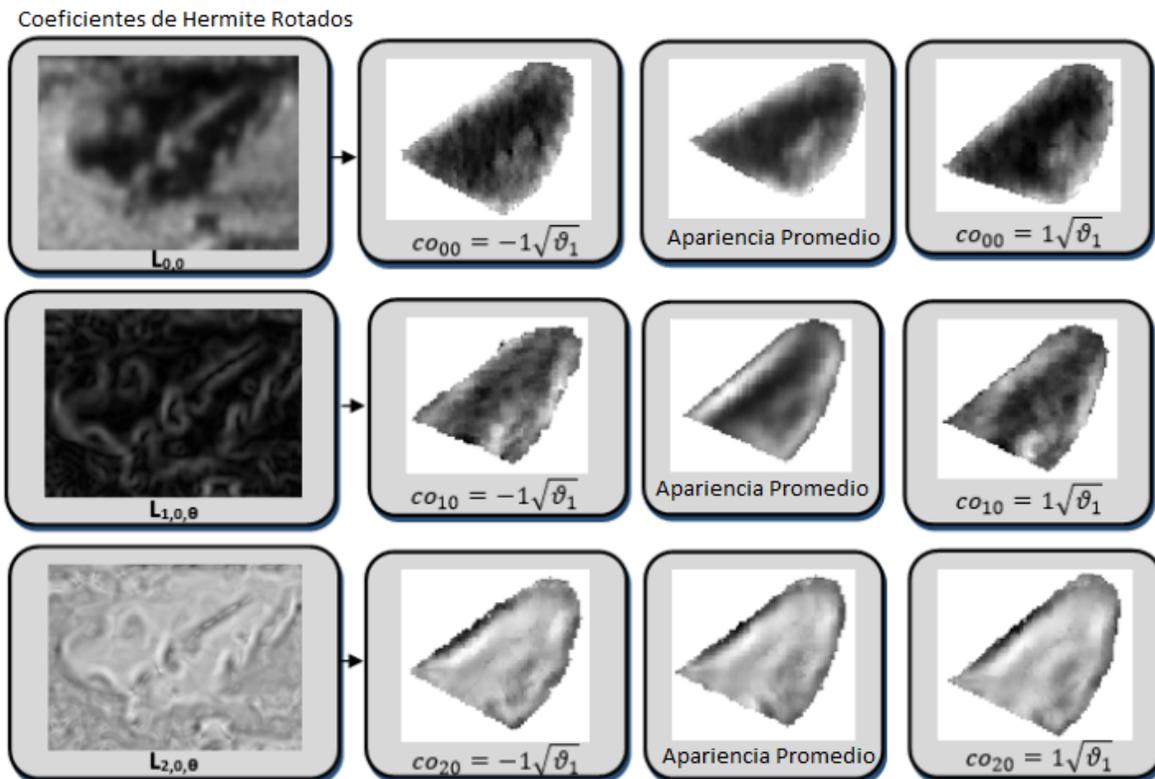


Figura 20. Modos de variación del modelo estadístico usando los mapas de texturas dados por los coeficientes $L_{0,0}$, $L_{1,0,\theta}$ y $L_{2,0,\theta}$ de la transformada de Hermite rotada. ϑ_1 es el primer eigenvalor obtenido para el modelo de apariencia usando cada coeficiente de Hermite rotado.

El segundo proceso es la segmentación de nuevas imágenes usando los modelos creados. Esta etapa consiste de una búsqueda activa en la cual los modelos estadísticos almacenados son usados para la segmentación. Inicialmente, se debe aplicar la transformada de Hermite rotada hasta el segundo orden a la imagen de entrada. Adicionalmente, la etapa de inicialización también es aplicada previamente para generar la forma inicial. Por lo tanto, usando la posición de la forma inicial, la textura del patrón de entrada es obtenida. Aquí se procesan cada uno de los coeficientes de Hermite rotados y sus correspondientes modelos. Se asume que j_0 indica un coeficiente de Hermite particular, con $j = 0, 1, 2$. Estos corresponden a la primera fila de coeficientes rotados en el esquema gráfico de la transformada de Hermite, en los cuales se concentran la máxima energía (Figura 6). Es decir, estos coeficientes tienen los subíndices 00, 10, 20. Las diferencias δL_{j_0} entre los datos de entrada y los modelos estadísticos de textura correspondientes son calculadas usando la ecuación (27). Luego, el vector de los parámetros óptimos co_{j_0} es calculado como:

$$co_{j_0}^t = co_{j_0}^{t-1} - R_{j_0} \delta L_{j_0} \quad (28)$$

donde R_{j_0} es la matriz de regresión obtenida durante la etapa de entrenamiento y t indica la iteración actual. El ajuste del algoritmo es realizado de forma iterativa por lo cual es necesario un $co_{j_0}^0$ (valor inicial). En este caso, los valores de los parámetros del vector inicial son cero. Por lo tanto, los modelos de forma y textura en cada iteración pueden ser actualizados usando el parámetro $co_{j_0}^t$. El modelo de textura es actualizado usando la ecuación (25) para cada uno de los coeficientes de Hermite rotado. Debido a que solo estamos interesados en obtener el contorno de la segmentación, aquí se propone actualizar el modelo de forma estadística combinando los modelos de formas obtenidos para cada uno de los coeficientes de Hermite rotados. Por consiguiente, la ecuación (24) es modificada por un esquema ponderado. Luego, el modelo de forma es calculado como

$$S_t = \sum_{j=0}^2 a_j (\bar{S}_{j_0} + \mathbb{Z}_{j_0} \rho_{j_0}^{-1} Q_{j_0} co_{j_0}^t) \quad (29)$$

donde a_j son los pesos asignados a cada modelo de forma, normalizados como $\sum_{j=0}^2 a_j = 1$. La combinación de los modelos de forma fue usada para obtener las mejores posiciones para los puntos de la forma inicial. El modelo de textura entrenado guía la deformación del modelo de apariencia. El proceso se realiza de forma iterativa y el resultado dado en la ecuación (29) es usado como inicialización para la siguiente iteración.

5. ESTIMACIÓN DE MOVIMIENTO USANDO LA TRANSFORMADA DE HERMITE ROTADA

El análisis y estimación de movimiento en secuencias de imágenes ha ganado gran importancia a causa del elevado número de aplicaciones que han surgido en diferentes campos. Entre las aplicaciones que más se destacan se encuentran las del área de imágenes médicas. La estimación de movimiento es un problema interesante ya que proporciona la ubicación espacial de los objetos en una secuencia de imágenes en distintos instantes de tiempo, lo cual permite detectar diferentes cambios que ocurren en la imagen. El auge de muchas aplicaciones ha llevado al desarrollo de un gran número de trabajos con diversos enfoques. Los métodos propuestos en la literatura han tenido en cuenta algunos aspectos como son los puntos característicos de las imágenes, la orientación de los contornos, los parámetros relacionados con el modelo, entre otros.

En este proyecto, la estimación de movimiento se presenta como un complemento del proceso de segmentación, con el objetivo de desarrollar una herramienta robusta y confiable para evaluar la función cardíaca en imágenes de ecocardiografía fetal. Gracias a la naturaleza dinámica del corazón, los algoritmos de análisis de movimiento han encontrado un gran campo de aplicación en imágenes de ecocardiografía. La estimación de movimiento en ecocardiografía fetal permite analizar las secuencias del ciclo cardíaco entre las fases de sístole y diástole.

En este proyecto, se modificó el método de estimación de movimiento propuesto por Moya-Albor et al. [1], el cual consiste de un esquema de flujo óptico diferencial basado en la transformada de Hermite rotada. En este capítulo se describe brevemente este método. Inicialmente se describe de forma general el método de flujo óptico, luego se exponen los detalles del método de flujo óptico basado en la transformada de Hermite. Además, se propone una solución para abordar uno de los problemas que este método presenta.

5.1. ESTIMACIÓN DE MOVIMIENTO USANDO FLUJO ÓPTICO

El flujo óptico puede definirse comúnmente como los patrones de movimiento de las estructuras, bordes o cualquier otra característica presente en un conjunto de imágenes. Este movimiento está relacionado con las velocidades aparentes dadas por las variaciones en la imagen. En otras palabras, la finalidad es encontrar una aproximación del campo de movimiento de los cambios de intensidad en las secuencias de imágenes.

En el análisis de estimación de movimiento usando métodos basados en modelos variacionales se debe cumplir con una serie de restricciones. Entre ellas, se tienen restricciones locales, estadísticas y de coherencia espacial.

Para el análisis se parte de una imagen $\mathcal{I}(x, y, t)$, donde \mathcal{I} corresponde a los niveles de grises de la imagen en la posición (x, y) , en el tiempo t , en una secuencia de imágenes. El método inicia con el cálculo de la velocidad de la derivada espacio-temporal de las intensidades presentes en las imágenes. Entre los aportes más significativas se encuentran los hechos por Horn y Shunck [35], en el cual se incluye una restricción de suavizado global. La condición de suavizado es aquella donde se considera que objetos presentan velocidades similares y que las intensidades cambian muy suavemente en cualquier parte de la imagen. Por lo tanto, se asume que el nivel de gris de un pixel de la imagen en una posición no varía por el desplazamiento, es decir

$$\mathcal{I}(x + dx, y + dy, t + dt) = \mathcal{I}(x, y, t) \quad (30)$$

Por lo cual, la imagen puede ser representada como una función de posición y tiempo en donde se asumen desplazamientos lineales dados por la ecuación (30), la cual puede ser expandida usando series de Taylor,

$$\mathcal{I}(x + dx, y + dy, t + dt) = \mathcal{I}(x, y, t) + \mathcal{I}_x dx + \mathcal{I}_y dy + \mathcal{I}_t dt + O(\partial^2) \quad (31)$$

donde el parámetro $O(\partial^2)$ indica a los términos de orden superior. Teniendo en cuenta la condición de que los niveles de intensidad no cambian en un punto (x, y) cuando se traslada una pequeña distancia (dx, dy) durante un intervalo dt (ver Figura 21), podemos decir que

$$\frac{\partial \mathcal{I}}{\partial x} dx + \frac{\partial \mathcal{I}}{\partial y} dy + \frac{\partial \mathcal{I}}{\partial t} dt = 0 \quad (32)$$

Luego, organizando la expresión se obtiene la ecuación de movimiento del método de flujo óptico [35]. Esta se escribe como

$$\frac{\partial \mathcal{I}}{\partial x} \frac{dx}{dt} + \frac{\partial \mathcal{I}}{\partial y} \frac{dy}{dt} + \frac{\partial \mathcal{I}}{\partial t} = 0 \quad (33)$$

Reescribiendo,

$$\mathcal{I}_x u + \mathcal{I}_y v + \mathcal{I}_t = 0 \quad (34)$$

donde $\frac{\partial \mathcal{I}}{\partial t} = \mathcal{I}_t$ es la diferencia de intensidad de las imágenes en dos tiempos diferentes, $\left(\frac{\partial \mathcal{I}}{\partial x}, \frac{\partial \mathcal{I}}{\partial y}\right) = (\mathcal{I}_x, \mathcal{I}_y)$ es el gradiente de la imagen, y $\mathbf{v} = \left(\frac{dx}{dt}, \frac{dy}{dt}\right) = (u, v)$ representan los desplazamientos horizontales y verticales, los cuales son las variables a encontrar. Esto se hace a través de un proceso de minimización.

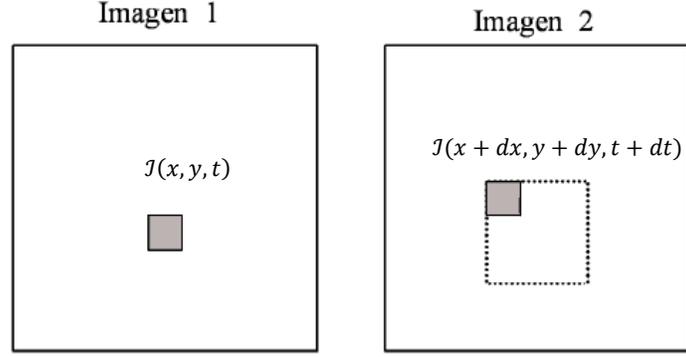


Figura 21. Secuencia de imágenes en tiempos diferentes con desplazamiento (dx, dy) .

Para resolver el problema de minimización [83] de la ecuación (34), se asume la condición del flujo constante en una ventana de la imagen. Esta ventana es denotada por \mathcal{G}_0 y corresponde a una función Gaussiana. La solución es encontrada usando el método de mínimos cuadrados [1], [72]. Por lo tanto,

$$E_{flujo} = \int_{\Omega} \left(\mathcal{G}_0(J_x)u + \mathcal{G}_0(J_y)v + \mathcal{G}_0(J_t) \right) dX = \int_{\Omega} \left(\mathcal{G}_0(\nabla J) \cdot \boldsymbol{\nu} + \mathcal{G}_0(J_t) \right) dX \quad (35)$$

donde $dX = (dx, dy, dt)$.

Las secuencias de imágenes no tienen las intensidades constantes, por lo que un criterio de invariabilidad a los cambios de intensidad es necesario. Para este caso es utilizada la condición de gradiente constante [36]. Luego,

$$\nabla J(x, y, t) = \nabla J(x + u, y + v, t + 1) \quad (36)$$

Otra condición denominada restricción de suavizado [35] fue incluida en el desarrollo de la estimación de movimiento para calcular una adecuada aproximación de la velocidad, en el cual se asume que los puntos en el plano se mueven de forma similar [84], [85], [86]. Por consiguiente,

$$E_{suavizado} = \int_{\Omega} ((\nabla u)^2 + (\nabla v)^2) dX = \int_{\Omega} (\nabla \boldsymbol{\nu})^2 dX \quad (37)$$

Por lo tanto, la función total está compuesta por:

$$E(u, v) = E_{flujo} + \lambda E_{suavizado} \quad (38)$$

donde λ es un parámetro de peso o regularización. Este parámetro de suavizado ha sido incluido debido a que es poco probable obtener una estimación de movimiento óptima solo con el parámetro de intensidad. Sin embargo, en muchos casos un suavizado muy grande puede ocasionar problemas en el cálculo. Por este motivo, en [87] se propuso la función $\rho(s^2)$, la cual corresponde a una variable independiente que permite el control de los cambios de intensidad. Esta penaliza la variación del flujo óptico [86], [87], y además es robusta cuando se presentan problemas de discontinuidades. Esta condición es llamada regularización isotrópica de flujo. Luego,

$$E(u, v) = \int_{\Omega} (\varrho((\mathcal{G}_v(\nabla J) \cdot v + \mathcal{G}_v(J_t))^2) + \lambda \varrho(\nabla v)^2) dX \quad (39)$$

Considerando que la expresión de restricción de flujo óptico permite manejar solo pequeños desplazamientos, se propuso en [1], [88], [89], [90], [91], [92] un esquema multiresolución con el fin de obtener los campos de velocidades cuando se tienen movimientos con mayor desplazamiento. El funcional encontrado para la representación multiresolución está dado por

$$E^m = \int_{\Omega} (\varrho(\mathcal{G}_v(\nabla J^m) \cdot \delta v^m + \mathcal{G}_v(J_t^m)) + \lambda \varrho((\nabla(v^m + \delta v^m))^2)) dX \quad (40)$$

El término del vector velocidad va estar dado por $v^{m+1} = v^m + \delta v^m$, donde δv^m corresponde a las velocidades en las diferentes resoluciones m .

Finalmente, la expresión que integra los términos de restricción de flujo óptico, gradiente, restricción de suavizado y el término de la representación multiresolución es obtenida por el siguiente funcional de energía

$$E = \int_{\Omega} \varrho(|J(X + v) - J(X)|^2 + \zeta |\nabla J(X + v) - \nabla J(X)|^2) dX + \lambda \int_{\Omega} \varrho(|\nabla_3 v|^2) dX \quad (41)$$

donde $\nabla_3 = (\partial x, \partial y, \partial t)$ y $\varrho(s^2) = \sqrt{s^2 + \epsilon^2}$, siendo $\epsilon = 0.001$.

5.2. FLUJO ÓPTICO USANDO LA TRANSFORMADA DE HERMITE ROTADA

El análisis de estimación de movimiento utilizando la transformada de Hermite ha sido implementado previamente en diferentes trabajos [93], [94]. Sin embargo, el enfoque presentado en [1] ha demostrado ser un método robusto al ruido, lo que constituye un factor muy importante cuando se trabaja con aplicaciones en imágenes de ultrasonido.

Para obtener el modelo de flujo óptico basado en la transformada de Hermite rotada se asume que se tienen las imágenes en un tiempo t_1 y t_2 . Esta transformada es aplicada a estas imágenes con el objetivo de extraer diferentes características y además poder tener una representación multiresolución. Al trabajar con la transformada de Hermite se incluye un procesamiento local semejante al descrito en la ecuación (35), lo que hace que este método sea robusto frente al ruido tal como sucede con los métodos diferenciales locales [1], [83], [95]. Posteriormente, este análisis local es incorporado en un funcional diferencial global para calcular el campo de velocidad.

Como se mencionó, este método utiliza las ecuaciones descritas anteriormente para el algoritmo de flujo óptico, pero desarrolladas en el espacio de la transformada de Hermite rotada. Por lo tanto, Moya-Albor et al. [1] propusieron utilizar las restricciones descritas a continuación.

5.2.1. Restricción de intensidad constante

En este caso se parte del coeficiente $L_{0,0}$ de la transformada de Hermite, el cual corresponde a una versión suavizada de la imagen original. Por lo tanto, la ecuación (30) se reemplaza por

$$L_{0,0}(p, q, t) = L_{0,0}(p + dp, q + dq, t + dt) \quad (42)$$

El desarrollo de esa ecuación resulta en el primer término del funcional de la ecuación (41) pero escrito en términos del coeficiente de Hermite.

5.2.2. Restricción para los coeficientes de Hermite

Se debe tener en cuenta que una variación del parámetro de intensidad en la secuencia de imágenes puede ocasionar que no se cumpla la condición anterior. La solución planteada a este problema es utilizar el gradiente de la imagen. Por consiguiente, los coeficientes de Hermite rotados de primer orden o superior son utilizados para este caso. Con estos coeficientes se obtienen los gradientes y cruces por cero de la imagen en distintas direcciones. Estos son importantes porque describen características específicas de la imagen con las cuales se puede determinar movimientos de traslación y rotación que no son fáciles de detectar cuando se utiliza solo la restricción de intensidad. Por lo tanto, la ecuación (36) se escribe en términos de los coeficientes de Hermite rotados de orden $n \geq 1$, es decir

$$L_{m,n-m,\theta}(p, q, t) = L_{m,n-m,\theta}(p + dp, q + dq, t + dt) \quad (43)$$

Igualmente, el desarrollo de esta ecuación resulta en el segundo término del funcional de la ecuación (41) pero escrito en términos de los coeficientes de Hermite.

5.2.3. Restricción de suavizado

El tercer término incluido en el método corresponde a la función de suavizado. Esta función fue descrita anteriormente y corresponde al último término de la ecuación (41). Con este término se obtiene mayor robustez con respecto a las discontinuidades de flujo [96], [97], [92]. Luego, este término se escribe como

$$E_{suavizado} = \int_{\Omega} \rho((\nabla u)^2 + (\nabla v)^2) dP \quad (44)$$

donde ρ representa la función de penalización que permite un suavizado en el campo de movimiento.

5.3. FUNCIONAL DE ESTIMACIÓN CON RESTRICCIÓN DE REGIONES HOMOGÉNEAS PARA LOS COEFICIENTES DE HERMITE

Uno de los problemas del método propuesto por Moya-Albor et al. [1] es que calcula los vectores de velocidad en toda la imagen incluyendo las zonas donde no existe movimiento. Esto sucede

debido al esquema de suavizado incluido en el funcional. Naturalmente, esto puede causar errores en el proceso de estimación. En busca de solucionar en cierta medida este tipo de problemas, algunos autores propusieron incorporar un término de regiones homogéneas [98] [99]. De esta manera se reduce las propagaciones indeseables del campo de velocidades en todos los puntos de la imagen donde no existe movimiento. La función que describe la restricción en regiones homogéneas está dada por

$$E_h = \int_{\Omega} H(P) (\boldsymbol{v})^2 dP \quad (45)$$

donde H es la función que penaliza las zonas homogéneas en la imagen. Este parámetro incluye una función de penalización en regiones donde el gradiente es bajo, es decir, donde se generan movimientos poco perceptibles. En este proyecto se propone incluir este término en el funcional final, pero en términos de los coeficientes de Hermite. Luego, la función H es calculada como

$$H(P) = \frac{1}{\sqrt{(L_{0,0}(P+\boldsymbol{v}) - L_{0,0}(P))^2}} \quad (46)$$

donde $P = (p, q, t)$. Esta función penaliza las zonas donde no se genera movimiento entre las versiones suavizadas $L_{0,0}^1$ y $L_{0,0}^2$ correspondientes a los coeficientes de Hermite de orden cero de las imágenes en los tiempos t_1 y t_2 , respectivamente.

Finalmente, el funcional completo propuesto en este proyecto está conformado por la suma de todos los términos descritos previamente. Luego,

$$E^2(u, v) = \int_{\Omega} \underbrace{\rho \left(|L_{0,0}(P + \boldsymbol{v}) - L_{0,0}(P)|^2 + \varsigma |L_{m,n-m,\theta}(P + \boldsymbol{v}) - L_{m,n-m,\theta}(P)|^2 \right)}_{\text{Flujo y gradiente}} dP + \underbrace{\lambda \int_{\Omega} \rho ((\nabla u)^2 + (\nabla v)^2) dP}_{\text{Suavizado}} + \underbrace{\beta \int_{\Omega} H(P) (\boldsymbol{v})^2 dP}_{\text{Zonas Homogéneas}} \quad (47)$$

donde β es el peso asignado al término adicional.

En la Figura 22 se muestra un resultado del campo vectorial obtenido para una imagen sintética de ejemplo. El resultado es presentado para el método desarrollado por Moya-Albor et al. [1] y para la modificación de este método propuesta en este proyecto. Es notable cómo el campo de velocidades se reduce en las zonas donde no hay movimiento cuando se le adiciona la restricción de regiones homogéneas.

Para la aplicación de estimación de movimiento en imágenes de ecocardiografía fetal, la restricción de regiones homogéneas resulta de mucha utilidad debido a que restringe el cálculo de los vectores en las zonas donde no hay movimiento. En este tipo de imágenes, existen muchas zonas donde no se presenta movimiento durante las fases del ciclo cardiaco. Un ejemplo de estas zonas

corresponde al interior de las cavidades ventriculares. En este sentido, el hecho de que el algoritmo inicial propuesto por Moya-Albor et al. [1] calcule vectores de movimiento en estas zonas homogéneas, generaría inexactitudes al momento de usar estos vectores para la aplicación clínica. Por ende, la modificación propuesta resulta en un aporte bastante significativo para esta aplicación.

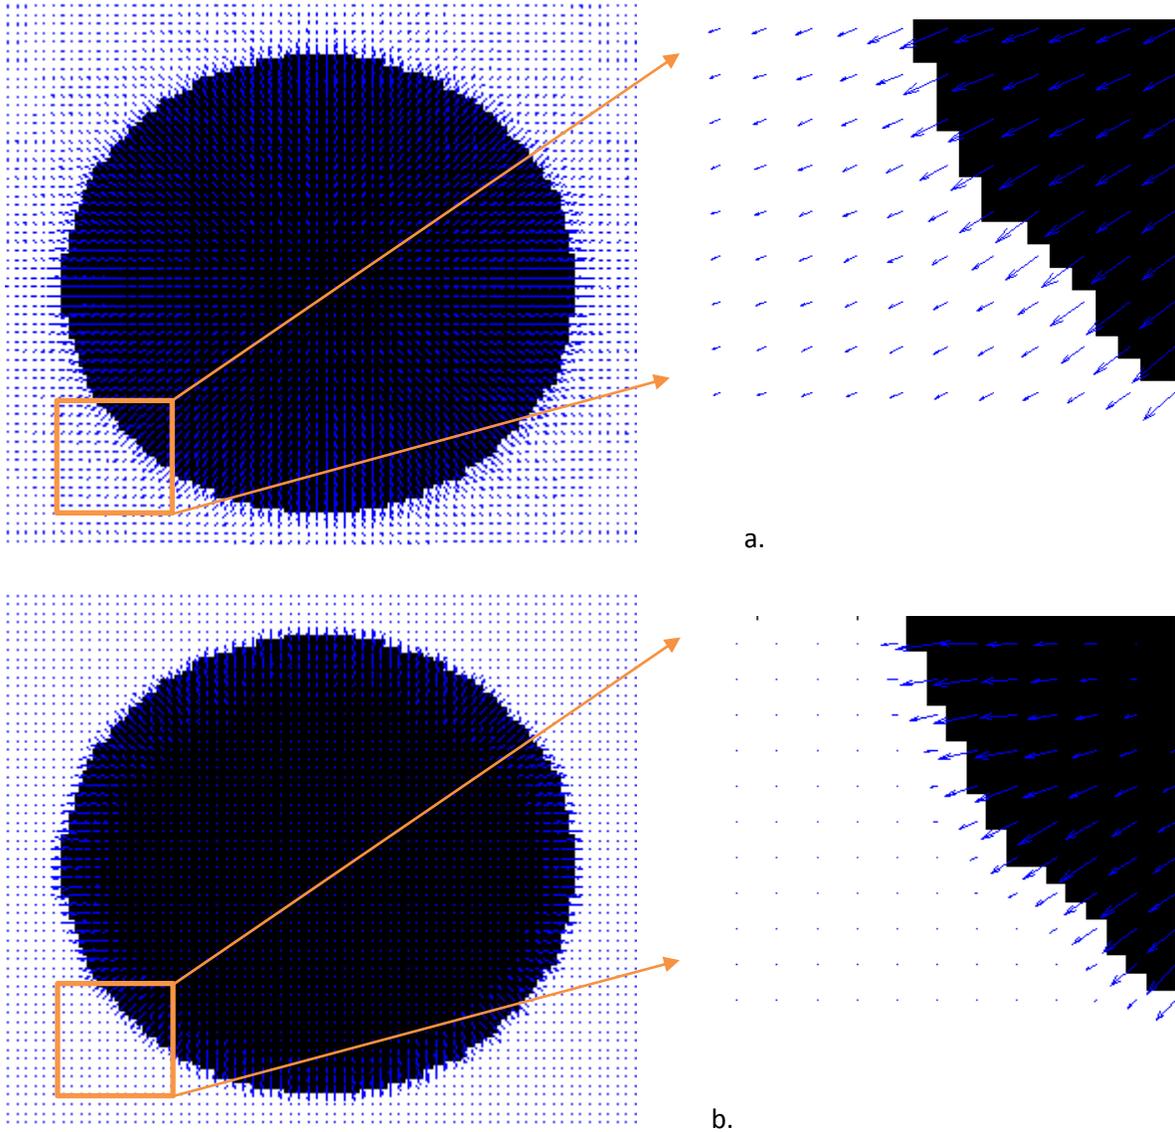


Figura 22. Resultados del método de estimación de movimiento, a. Método propuesto por Moya-Albor [1], b. Versión modificada propuesta.

6. EXPERIMENTOS Y RESULTADOS

Los resultados de los métodos de segmentación y estimación de movimiento fueron evaluados usando imágenes simuladas y reales de ultrasonido del corazón. La estructura de análisis es el ventrículo izquierdo. Otros métodos de la literatura son utilizados para efectos de comparación. Evaluaciones cualitativas y cuantitativas son llevadas a cabo.

6.1. SECUENCIAS DE EVALUACIÓN

Para la evaluación de los métodos se usaron dos conjuntos de secuencias de imágenes. Las características de estos datos se describen a continuación.

6.1.1. Imágenes reales para la evaluación de la segmentación

Para la evaluación del método propuesto se utilizó 10 casos clínicos donde cada uno corresponde a un paciente diferente. Estos casos, en total, suman 143 imágenes de ultrasonido reales las cuales fueron adquiridas y suministradas por el Instituto Nacional de Perinatología de la Ciudad de México. Estas imágenes corresponden a estudios ecocardiográficos fetales adquiridos usando un equipo de ultrasonido Voluson E8 del fabricante General Electric. De los casos clínicos se seleccionó el corte que el especialista consideró más adecuado para evaluar el corazón del feto. Estos estudios fueron adquiridos de fetos normales sin cardiopatías. En las imágenes se muestra el corazón del feto en varias fases del ciclo cardiaco entre sístole y diástole. El conjunto de imágenes fue segmentado previamente por los médicos especialistas del instituto. Los tamaños de las imágenes varían de 190x230 a 360x280 píxeles, cuantizadas a 8 bits por píxel. Los estudios presentan variación en cuanto a la posición, tamaño y contraste. En el algoritmo de segmentación se utilizaron 98 imágenes anotadas correspondientes a 5 pacientes para el entrenamiento del AAM multi-textura. Un equivalente a 45 imágenes correspondientes al resto de los pacientes fueron usadas para la validación.

6.1.2. Imágenes simuladas para la evaluación de la estimación de movimiento

Este conjunto de imágenes corresponde a secuencias simuladas que fueron generadas y compartidas en la referencia [100]. Estas han sido utilizadas en la literatura para la validación y comparación de métodos de estimación de movimiento en imágenes de ultrasonido. Esta base de datos está conformada por 51 imágenes del corazón en una vista de cuatro cámaras. Estas secuencias se utilizaron para la evaluación del método de estimación de movimiento. Estas incluyen información de referencia de los vectores de movimiento en toda la secuencia.

6.2. RESULTADOS DE LA ETAPA DE INICIALIZACIÓN

Una adecuada inicialización es fundamental para el algoritmo de apariencia activa debido a que éste procesa información local. Para que el AAM-multi-textura converja a un resultado aceptable, la forma inicial debe estar cerca del objeto que se quiere segmentar. En la Figura 23 se observan los resultados de la inicialización obtenidos para tres imágenes diferentes de la base de datos. Como se mencionó, las imágenes de ultrasonido cardiacas fetales pueden exhibir diferentes orientaciones y tamaños de las cavidades cardiacas. Aquí se observa cómo el algoritmo de inicialización propuesto puede adaptarse a este tipo de variaciones.

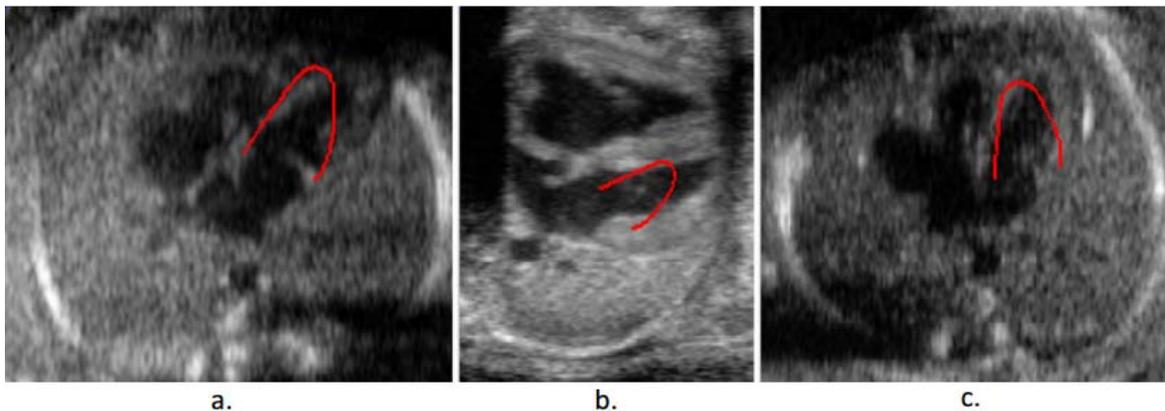


Figura 23. Resultados del proceso de inicialización para tres imágenes de evaluación diferentes.

Para el análisis cuantitativo de este algoritmo fueron utilizadas diferentes métricas. En la Tabla 1 se presentan los resultados para esta etapa de inicialización. En el estudio se usaron la distancia euclidiana, el coeficiente de DICE y la estimación del error de orientación. Estas métricas fueron comparadas usando la forma obtenida como resultado de la etapa de inicialización y la segmentación manual de la estructura. La orientación fue obtenida con respecto al eje principal del ventrículo izquierdo.

Tabla 1. Resultados cuantitativos del algoritmo de inicialización.

Inicialización	Paciente 1	Paciente 2	Paciente 3	Paciente 4	Paciente 5
Error de Orientación	$10.30^\circ \pm 5.36^\circ$	$24.59^\circ \pm 7.51^\circ$	$16.46^\circ \pm 6.90^\circ$	$7.40^\circ \pm 4.18^\circ$	$5.32^\circ \pm 4.56^\circ$
Distancia (pixeles)	9.16 ± 3.26	20.40 ± 4.54	8.62 ± 2.61	7.59 ± 3.67	3.78 ± 1.32
DICE	0.70 ± 0.07	0.65 ± 0.08	0.73 ± 0.03	0.75 ± 0.02	0.79 ± 0.03

Además, se incluyó un experimento que permite evaluar los cambios en la forma inicial con respecto al número de parches que se almacenan en la base de datos de la inicialización. Se seleccionó una imagen de prueba, la cual fue comparada con varias bases de datos de inicialización que contienen diferentes números de parches. Esto fue realizado con el objetivo de determinar el número de rotaciones y escalas adecuadas que se necesitan para cubrir las posibles variaciones que presenta el ventrículo izquierdo en este tipo de imágenes.

Para determinar el número de rotaciones y escalamientos de la etapa de inicialización se tuvieron en cuenta dos casos:

- En el primer caso, los 15 parches originales fueron rotados sin escalar.
- En el segundo caso, los 15 parches originales fueron escalados una vez y luego rotados.

Por lo tanto, la cantidad de parches de imágenes en cada base de datos de prueba depende del número de rotaciones y escalas que se tengan. La Figura 24 muestra el resultado para este experimento. La curva azul fue obtenida para el primer caso y la curva roja para el segundo. El eje horizontal de la gráfica especifica el número de rotaciones usadas para construir cada base de datos. El eje vertical es el error de distancia promedio obtenido entre el contorno inicial obtenido y el contorno manual de referencia.

Un aspecto interesante que se encontró en las curvas es que el error no varía mucho cuando se usa una base de datos con más de 17 rotaciones para cada caso aproximadamente. La razón es que con 17 rotaciones es posible cubrir las posibles orientaciones que puede presentar el ventrículo izquierdo. Por otro lado, al incluir diferentes escalas se puede obtener una mejor forma inicial dado que se cubren los posibles tamaños de la estructura analizada. No obstante, al tener en la base de datos de inicialización imágenes de todo el ciclo cardiaco se tiene una descripción más general de los posibles tamaños de las cavidades cardíacas.

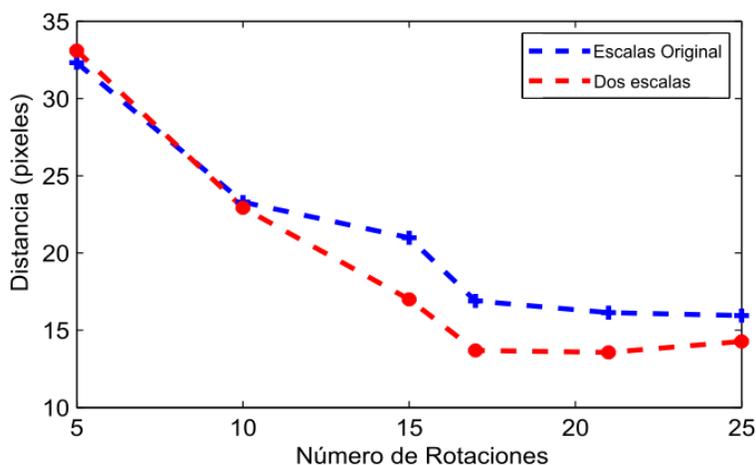


Figura 24. Inicialización obtenida usando bases de datos con diferentes números de parches, producto de diferentes números de rotaciones. La curva azul utiliza imágenes sin escalar y la curva roja es el resultado utilizando dos escalas.

6.3. RESULTADOS DE LA SEGMENTACIÓN AAM MULTI-TEXTURA

En esta sección se analizan los resultados obtenidos utilizando el algoritmo de segmentación propuesto. Además, se llevan a cabo comparaciones con diferentes técnicas de segmentación de la literatura. Las técnicas usadas para comparar son *Snake*, ASM, AAM clásico y AAM con LBP (del inglés Local Binary Pattern). Todos los métodos fueron ejecutados usando las mismas características de la imagen. Además, los algoritmos fueron evaluados usando 30 iteraciones. Para la implementación de ASM, se tiene en cuenta la información del contorno del ventrículo izquierdo, así como los perfiles de los niveles de grises en la dirección normal a cada punto del contorno. En el AAM clásico, se codifica la textura usando la imagen original. En el AAM usando LBP se obtiene la textura de la imagen usando patrones binarios locales. Experimentalmente, se encontró que el mejor peso para el ajuste de la forma en el algoritmo AAM multi-textura propuesto fue de $a_j = \frac{1}{3}$ con $j = 1,2,3$.

Una imagen de prueba y los resultados de segmentación son mostrados en la Figura 25. Para efectos de comparación, la forma inicial del ventrículo izquierdo se dibuja también en la Figura 25f, la cual fue obtenida de la etapa de inicialización. Adicionalmente, se presentan las segmentaciones resultantes en las iteraciones 2, 7, 10, 20 y 30 visualizadas en las Figura 25b, Figura 25c, Figura 25d, Figura 25e y Figura 25f, respectivamente. Para esta imagen de prueba el algoritmo converge después de 11 iteraciones.

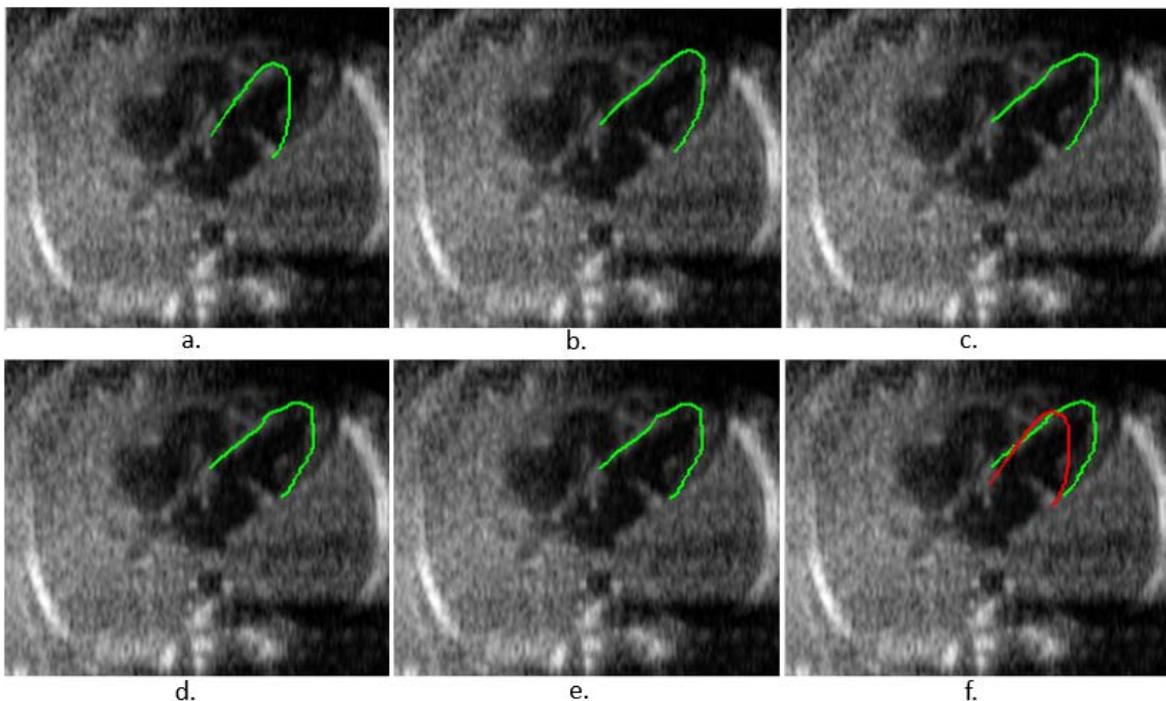


Figura 25. Resultado de la segmentación usando varias iteraciones. a. Forma inicial, b. Iteración 2, c. Iteración 7, d. Iteración 10, e. Iteración 20, f. Iteración 30. El contorno verde es el resultado de la segmentación en cada iteración y el contorno rojo es la forma inicial.

De la Figura 25f se puede apreciar que la forma inicial se localiza cerca de la cavidad cardiaca, lo cual permite que el algoritmo converja rápidamente. Aquí se puede observar que la forma inicial esta rotada y desplazada con respecto al eje principal de la estructura. El AAM multi-textura se ajusta bastante bien logrando una eficiente segmentación.

Como se ha mencionado, en este tipo de métodos se codifican las variaciones no solo de forma sino también de la textura del objeto. Para una mejor descripción de esta textura se usaron tres coeficientes de Hermite rotados. Un ejemplo del ajuste y adaptación que sufren estos modelos de textura en el método desarrollado se muestra en la Figura 26. Los coeficientes de Hermite rotados utilizados fueron $L_{0,0}$, $L_{1,0,\theta}$ y $L_{2,0,\theta}$. Sobre la imagen original se dibujó el contorno inicial. Se puede observar como varia la textura en cada uno de los coeficientes utilizados. Los cambios suceden hasta que el algoritmo converge a un estado estable, el cual fue alcanzado en la iteración 7. El ajuste de la textura es logrado cuando se obtiene la mejor similitud entre la textura del modelo estadístico y la textura de la imagen de entrada. La última imagen de cada coeficiente es el resultado final cuando el algoritmo converge.

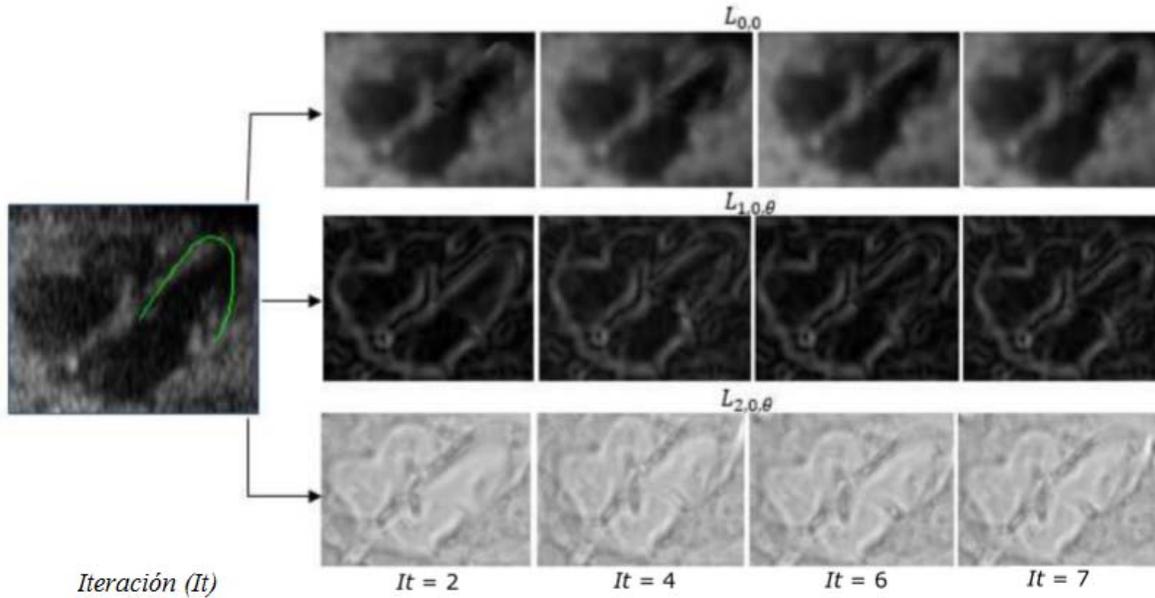


Figura 26. Deformación del modelo de textura construido para cada uno de los coeficientes de Hermite rotados en varias iteraciones.

También se llevaron a cabo evaluaciones cuantitativas usando dos métricas diferentes. La primera de ellas corresponde a la distancia *punto-a-curva* promedio la cual es definida como

$$D_{punto-a-curva} = \frac{1}{ni} \sum_{l=1}^{ni} \min(Dist(x_l, x_{cpl})) \quad (48)$$

Donde x_l es el punto del contorno segmentado de forma automática y x_{cpl} son todos los puntos de la marcación de referencia o manual y $Dist$ es la distancia euclidiana.

Además, se realizó una comparación con otros métodos clásicos usados en la literatura. En las evaluaciones de los métodos se utilizaron cinco casos clínicos, compuestos en total por 45 imágenes de prueba. Los resultados obtenidos usando los diferentes métodos de segmentación son presentados en la Tabla 2. Cada caso clínico fue tomado de un paciente diferente y corresponde a una secuencia completa del ciclo cardiaco. En la Tabla 2 se presentan los resultados promediados para todas las imágenes de cada secuencia. El mejor desempeño se obtuvo con el método desarrollado.

Tabla 2. Distancia promedio punto-a-curva para 5 pacientes usando varios métodos de segmentación. Los valores de las distancias están expresados en $\mu \pm std$. Todos los valores están dados en pixeles.

Pacientes	Snake	ASM	AAM Clásico	AAM con LBP	AAM Multi-textura
Paciente 1 (9 Imágenes)	5.40 ± 4.58	5.27±3.62	3.35 ± 1.86	5.16 ± 2.47	2.16 ± 1.15
Paciente 2 (11 Imágenes)	4.76 ± 4.05	4.61±4.23	3.42 ± 1.85	4.11 ± 2.82	2.21 ± 0.60
Paciente 3 (7 Imágenes)	4.13 ± 3.80	4.16±2.09	3.03 ± 1.08	4.15 ± 3.60	1.94 ± 1.21
Paciente 4 (6 Imágenes)	6.37 ± 4.26	4.76±4.22	3.55 ± 1.03	5.51 ± 2.90	1.87 ± 0.95
Paciente 5 (12 Imágenes)	6.36 ± 5.98	5.02±4.11	2.21 ± 1.90	6.06 ± 4.35	1.92 ± 0.92

La segunda métrica empleada para evaluación es el coeficiente de similitud de DICE. Esta medida es usada para calcular el grado de similitud entre la anotación manual y la segmentación obtenida con el método automático. El área de la región encerrada por cada contorno es tomada y entonces la región traslapada es calculada. Este índice se calcula como

$$DICE = \frac{2|A_1 \cap A_2|}{|A_1| + |A_2|} \quad (49)$$

donde A_1 define la región segmentada automáticamente y A_2 es la región de referencia o marcada por el especialista.

Los resultados obtenidos usando el índice de DICE son presentados en la Figura 27. En el diagrama de barras se muestra el análisis para los cinco pacientes del conjunto de secuencias de evaluación. Nuevamente, este coeficiente fue promediado para todas las imágenes de cada secuencia. De la misma forma, se comparan los resultados del método desarrollado y otros de la literatura. En todos los casos, el método propuesto exhibe el mejor desempeño.

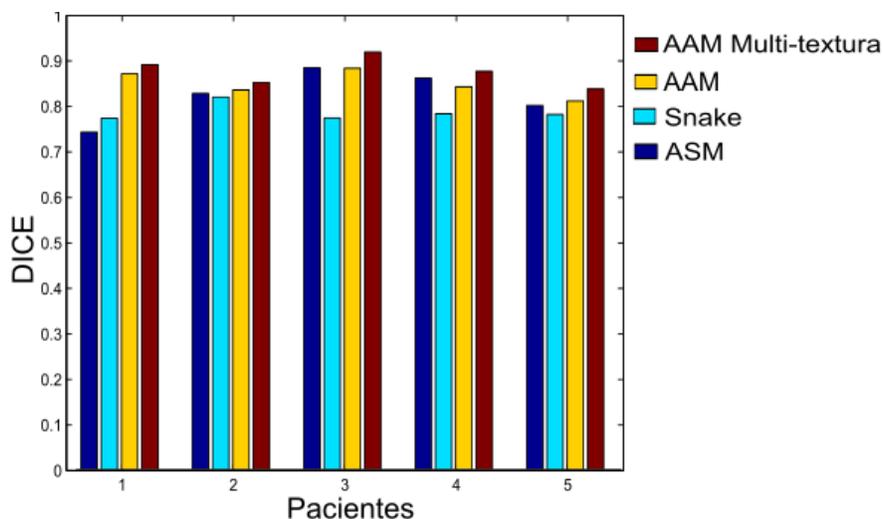


Figura 27. Resultados de la segmentación usando el método propuesto y otros tres usados para propósitos de comparación.

Los resultados individuales en el método desarrollado también fueron analizados. De las 45 imágenes de evaluación, el mejor índice de DICE conseguido con el método propuesto fue de 0.963, el cual corresponde a una imagen en el comienzo de la fase de diástole mientras que el peor resultado fue de 0.7887 correspondiente a una imagen en la fase final de sístole. Los contornos obtenidos para los dos casos son mostrados en la Figura 28.

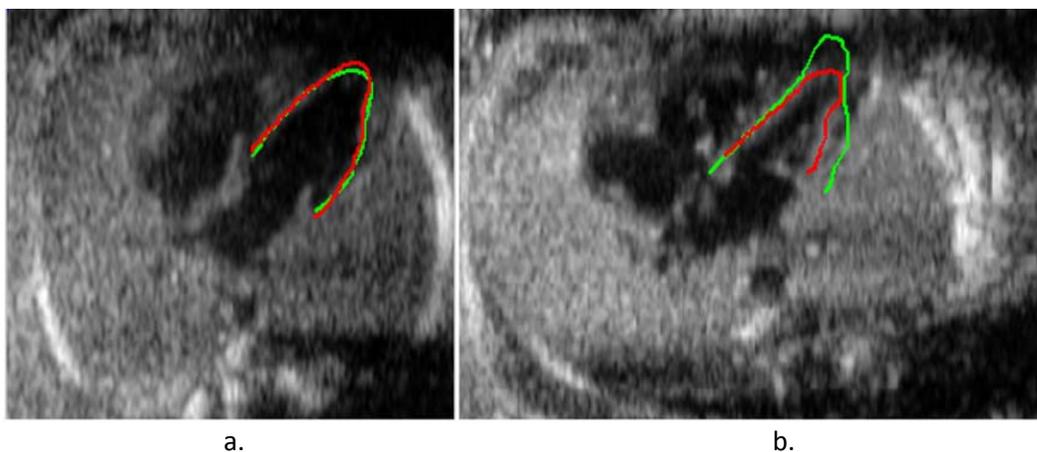
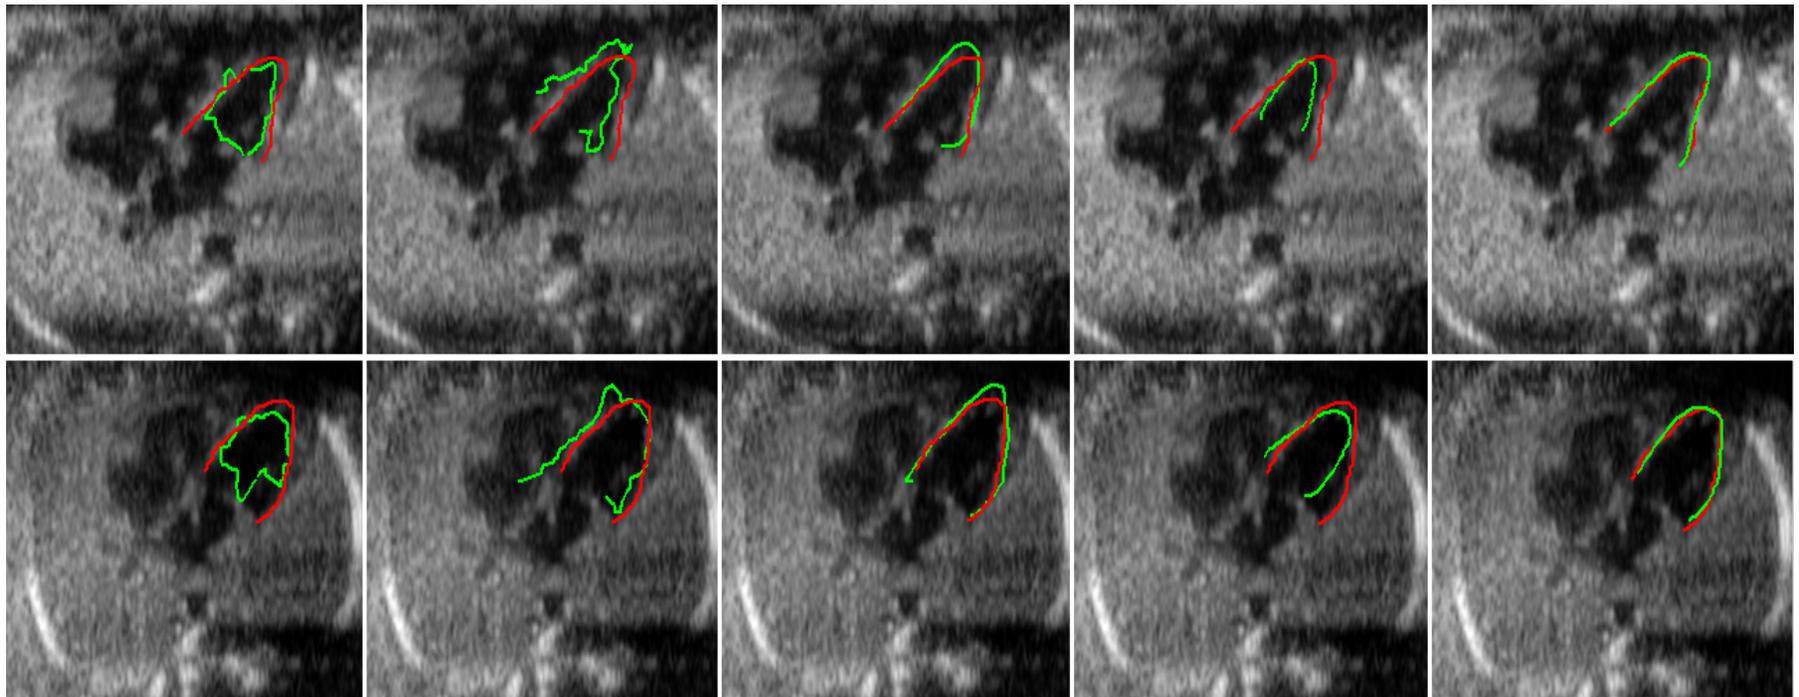


Figura 28. Mejor y peor resultado obtenido con el coeficiente de DICE para las imágenes de prueba evaluadas. La segmentación automática es el contorno verde y la segmentación manual es el contorno rojo. a. Mejor resultado obtenido, imagen en la fase final de diástole. b. Peor resultado obtenido, imagen en la fase final de sístole.

Los resultados visuales de la segmentación usando los diferentes métodos son mostrados en la Figura 29. El contorno rojo es la marcación realizada por el médico y el verde es la segmentación obtenida con cada una de los métodos utilizados. El método propuesto presenta los mejores resultados.



a.

b.

c.

d.

e.

Figura 29. Resultados de la segmentación usando dos imágenes de prueba y cuatro métodos empleados para comparación. a. *Snake*, b. ASM, c. AAM, d. AAM con LBP y AAM multi-textura. El contorno verde es la segmentación automática y el rojo es la segmentación manual.

También se hizo un análisis de convergencia del algoritmo usando una imagen de prueba. El resultado conseguido con el AAM multi-textura es comparado con otros tres métodos. La medida es hallada calculando la distancia punto-a-curva contra el número de iteraciones. Estos resultados son mostrados en la Figura 30. El error entre la segmentación manual y automática fue calculado para 30 iteraciones. Se puede ver que el método de *Snake* presenta una rápida convergencia porque solo evalúa los perfiles de cada punto para encontrar la mínima energía de su funcional. Debido a que *Snake* se basa en un funcional de gradiente, este método es poco efectivo en imágenes de ultrasonido. El método ASM usa el perfil de los niveles de gris y el gradiente lo cual limita su funcionamiento en estas imágenes. El desempeño es mejor comparado con *Snake*, pero la estabilidad se pierde debido al ruido en la imagen. El AAM multi-textura propuesto converge de forma más lenta que *Snake*, pero más rápido y más estable que AAM clásico y ASM. Adicionalmente, presenta mejor resultado comparado con los otros métodos. Los coeficientes de textura de la transformada de Hermite rotada ayudan a obtener un mejor desempeño porque varias características son tenidas en cuenta al momento de analizar la imagen. Este comportamiento fue similar evaluando sobre el resto de las imágenes.

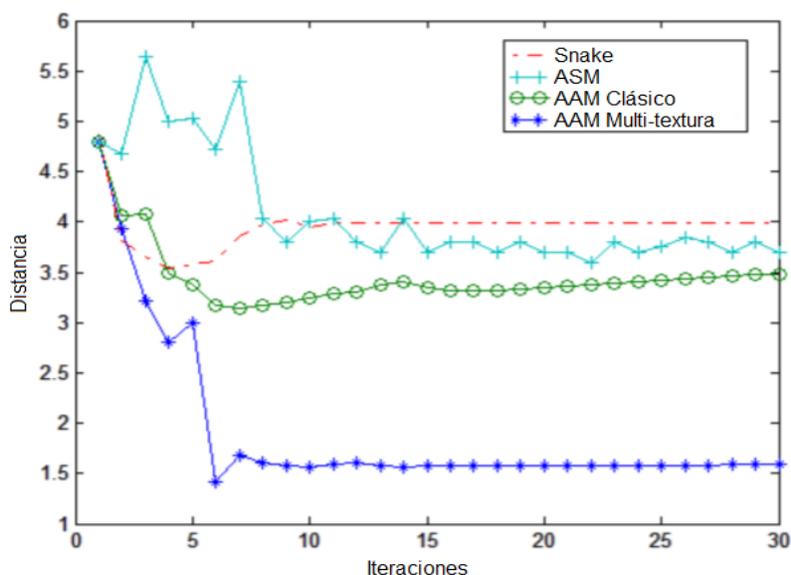


Figura 30. Evolución de la distancia punto-a-curva en varias iteraciones. Cuatro métodos fueron usados para este análisis: Snake, ASM, AAM clásico y AAM multi-textura. Esta distancia está dada en píxeles.

El tamaño y la forma del ventrículo izquierdo pueden cambiar significativamente durante el ciclo cardiaco entre las fases de diástole y sístole. En otro experimento, se evaluó el comportamiento del método en todo el ciclo cardiaco. Para este propósito, se usaron dos secuencias de la base de datos y se calculó el error de distancia de la segmentación para cada imagen de la secuencia. En cada secuencia de evaluación se utilizó un número total de 19 imágenes. En la Figura 31 se ilustran los resultados obtenidos. El mejor resultado fue logrado para la fase de diástole y el comienzo de sístole. El peor desempeño fue obtenido durante el final de la sístole donde el ventrículo izquierdo se

encuentra más contraído y por lo tanto su forma es más irregular. Esto hace que el proceso de adaptación del modelo AAM multi-textura falle. Un interesante resultado en este experimento es que el comportamiento fue muy similar para las dos secuencias utilizadas.

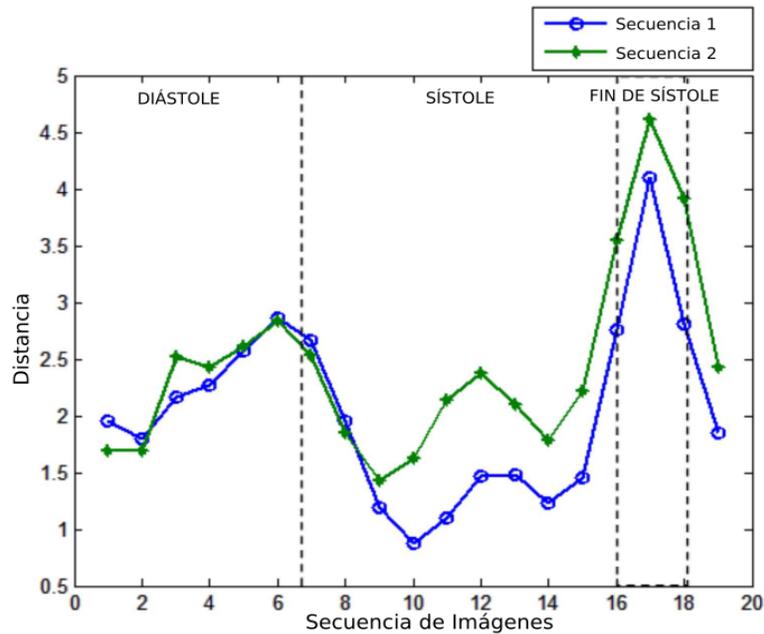


Figura 31. Distancia punto-a-curva del método propuesto para dos secuencias de prueba. El error es evaluado para todo el ciclo cardíaco. Esta distancia está dada en píxeles.

Un aspecto crítico del método propuesto es la selección de los valores de peso en la ecuación 29. El método propuesto usa varios modelos de apariencia ponderados con un conjunto de pesos. Esto implica que se debe escoger los valores adecuados para estos pesos. Para este efecto, se desarrolló un experimento para determinar el peso óptimo en las imágenes de prueba. Entonces, se evaluó el algoritmo para cuatro casos, $a_1 > (a_2, a_3)$, $a_2 > (a_1, a_3)$, $a_3 > (a_1, a_3)$ y $a_1 = a_2 = a_3$. Los resultados promedios obtenidos para todos los casos usando la distancia punto-a-curva y el índice de DICE son mostrados en la Tabla 3. Los mejores desempeños fueron logrados cuando todos los pesos tenían el mismo valor.

Tabla 3. Efectos de la variación de los parámetros en el AAM multi-textura. Como métrica se usó la distancia punto-a-curva y el índice de DICE.

Parámetros de peso	Distancia $\mu \pm \text{std}$	DICE
$a_1 > a_2 \ \& \ a_1 > a_3$	2.83 ± 2.12 píxeles	0.83
$a_2 > a_1 \ \& \ a_2 > a_3$	3.01 ± 1.96 píxeles	0.80
$a_3 > a_1 \ \& \ a_3 > a_2$	2.10 ± 1.57 píxeles	0.84
$a_1 = a_2 = a_3$	1.72 ± 1.16 píxeles	0.85

Similarmente, los contornos obtenidos para una imagen de prueba usando estos casos se muestran en la Figura 32.

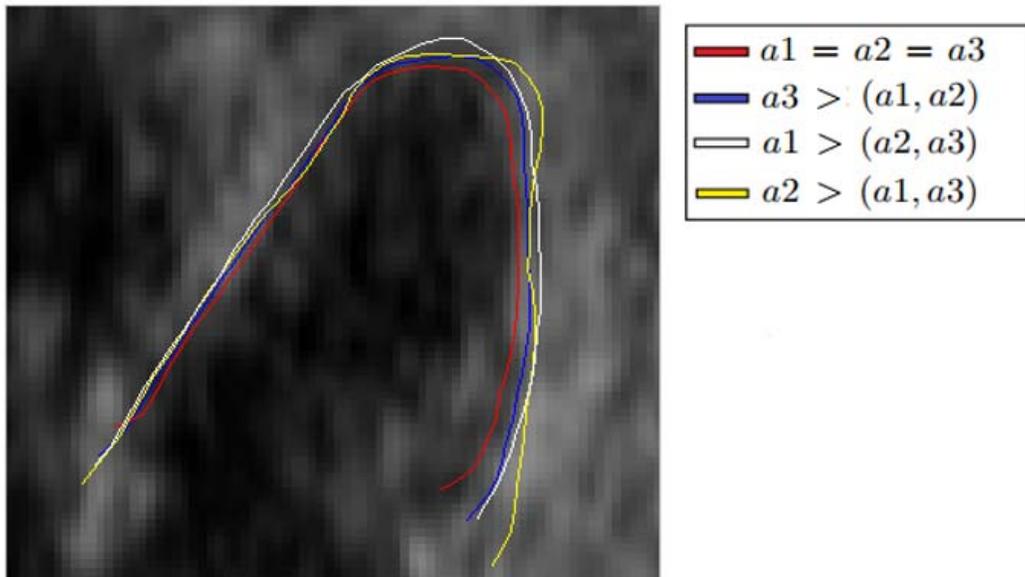


Figura 32. Segmentación obtenida para el ventrículo izquierdo aplicando cuatro diferentes criterios para los parámetros de pesos del AAM multi-textura.

6.4. RESULTADOS DE LA ESTIMACIÓN DE MOVIMIENTO

En esta sección se presentan los resultados obtenidos para la estimación de movimiento usando el método desarrollado por Moya-Albor et al. [1] y la versión modificada propuesta en este proyecto. Adicionalmente, se realizan comparaciones con otras técnicas de estimación de movimiento usadas en imágenes de ultrasonido [100], [42]. Para la evaluación se usó la secuencia de imágenes simuladas del corazón en una vista de cuatro cámaras. Además, se evaluó el método en imágenes reales suministradas por el Instituto Nacional de Perinatología.

La medida utilizada para el análisis de desempeño de los algoritmos es el error de punto final (EE) [42], [101], el cual se calcula como

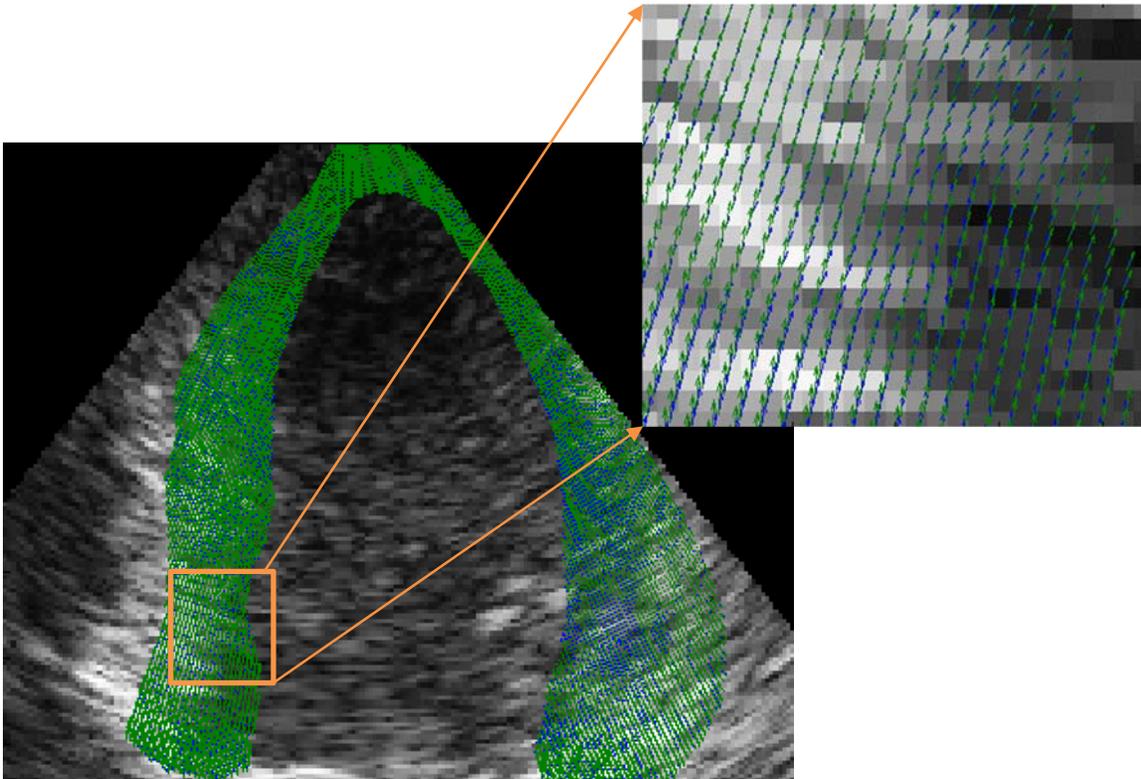
$$EE = \|de - dr\|_2 \quad (50)$$

donde de representa el desplazamiento estimado obtenido con los algoritmos y dr corresponde al desplazamiento de referencia dado. Los parámetros usados para configurar los dos algoritmos mencionados se muestran en la Tabla 4. Con estos parámetros se obtuvo el mejor desempeño de los algoritmos.

Tabla 4. Parámetros empleados en el algoritmo.

Parámetro	Valores asignado
Variable de regularización (λ)	10
Peso de la constante local (ζ)	1
Peso del parámetro de homogeneidad β	1
Numero de iteraciones internas	3
Numero de iteraciones externas	30
Nivel de descomposición	3

En la Figura 33 se ilustran los resultados cualitativos obtenidos con el método implementado usando dos imágenes de la secuencia sintética de prueba. En las imágenes se muestran los vectores que describen el movimiento del corazón en un instante del ciclo cardíaco. Los vectores obtenidos con el método propuesto (color azul) son comparados con los vectores de referencia (color verde).

**Figura 33.** Resultados de la estimación de movimiento con el método implementado en una imagen de prueba de la secuencia sintética.

Una evaluación comparativa del método propuesto por Moya-Albor [1] y la versión mejorada en este trabajo se muestra en la Figura 34. En esta se ilustra el error de punto final obtenido por estos dos métodos usando todas las imágenes de la secuencia de prueba. Como se puede notar, el error es menor en la mayoría de los casos con el método mejorado y propuesto en este proyecto.

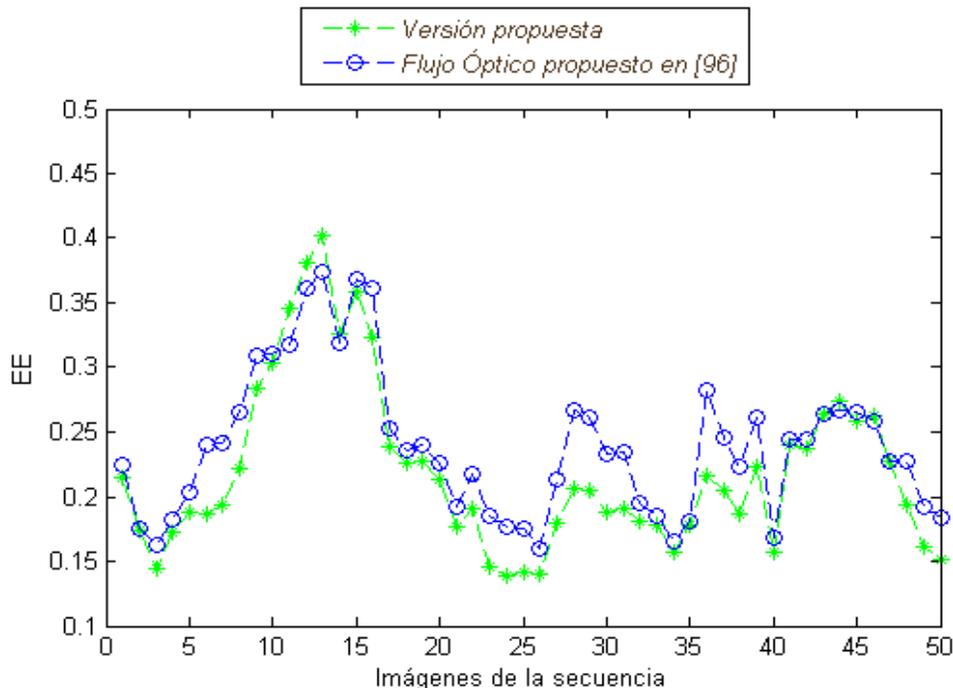


Figura 34. Evaluación cuantitativa del error de punto final promedio entre el método de flujo desarrollado en [1] y el algoritmo mejorado propuesto.

La estimación de movimiento fue realizada en todo el ciclo cardiaco durante las fases de sístole a diástole. La secuencia sintética empleada para la medición consta de 51 imágenes y el análisis fue realizado de forma detallada para cada una ellas. Aquí, el desempeño del algoritmo modificado con respecto al propuesto en [1] es mejor cuando los cambios son más pequeños en las imágenes de la secuencia. Esto se debe a la restricción de homogeneidad incluida en el algoritmo. Todas las evaluaciones hechas para los dos métodos fueron realizadas usando los mismos parámetros citados en la Tabla 4.

Adicionalmente, el desempeño del algoritmo también fue comparado con otros resultados publicados en la literatura para estas imágenes. En la Tabla 5 se presenta esta comparación usando los resultados publicados en [42]. Cabe notar que el error (EE) en el algoritmo implementado presenta el mejor desempeño. Por lo tanto, se puede decir que los coeficientes de Hermite rotados constituyen una buena base para caracterizar las imágenes de ultrasonido y de esta forma extraer información relevante para este tipo de métodos. El algoritmo mejorado propuesto presenta resultados más satisfactorios con respecto a los otros métodos.

Tabla 5. Medida de error de punto final (EE) en la secuencia de prueba usando varios métodos.

Método	Error mean \pm std
Zang *	0.294 \pm 0.217
Alessandrini *	0.264 \pm 0.190
Moya-Albor et al. [1]	0.239 \pm 0.064
Algoritmo propuesto	0.219 \pm 0.078

*Estos resultados fueron presentados en [42].

6.5. APLICACIÓN: SEGMENTACIÓN Y ESTIMACIÓN DE MOVIMIENTO DEL VENTRÍCULO IZQUIERDO DEL CORAZÓN FETAL

La finalidad de desarrollar técnicas de segmentación y estimación de movimiento aplicadas a estudios de ecocardiografía fetal es poder tener una herramienta que ayude al médico en la evaluación de parámetros clínicos y cuantitativos que sean de utilidad en la identificación de algún tipo de malformación o defecto cardíaco. Analizar estructuras por separado favorece en gran medida a la detección de ciertas enfermedades específicas. Como se ha mencionado, una de las cavidades de análisis con gran importancia durante la etapa de gestación es el ventrículo izquierdo.

Por lo tanto, uno de los objetivos finales de esta tesis es suministrar una herramienta robusta y confiable que sea útil en este tipo de evaluación clínica. Por tal motivo, se propone combinar los métodos de segmentación y estimación de movimiento para evaluar el comportamiento del ventrículo izquierdo. La segmentación permite aislar la cavidad estudiada del resto de la imagen mientras que la estimación de movimiento permite estudiar el comportamiento mecánico de esta estructura. No obstante, la segmentación y la estimación de movimiento por sí solas permiten hacer análisis individuales a las estructuras estudiadas. Al definir un contorno y combinarlo con técnicas de estimación de movimiento se delimita el análisis a una región de interés. En la Figura 35 se muestra el campo de movimiento para una secuencia de ecocardiografía fetal sobre el ventrículo izquierdo, el cual fue previamente segmentado. Aquí se visualizan algunas imágenes del ciclo cardíaco y se puede apreciar el comportamiento del corazón en cuanto a su función dinámica. Esto puede ser útil en la evaluación de la función cardíaca del ventrículo izquierdo.

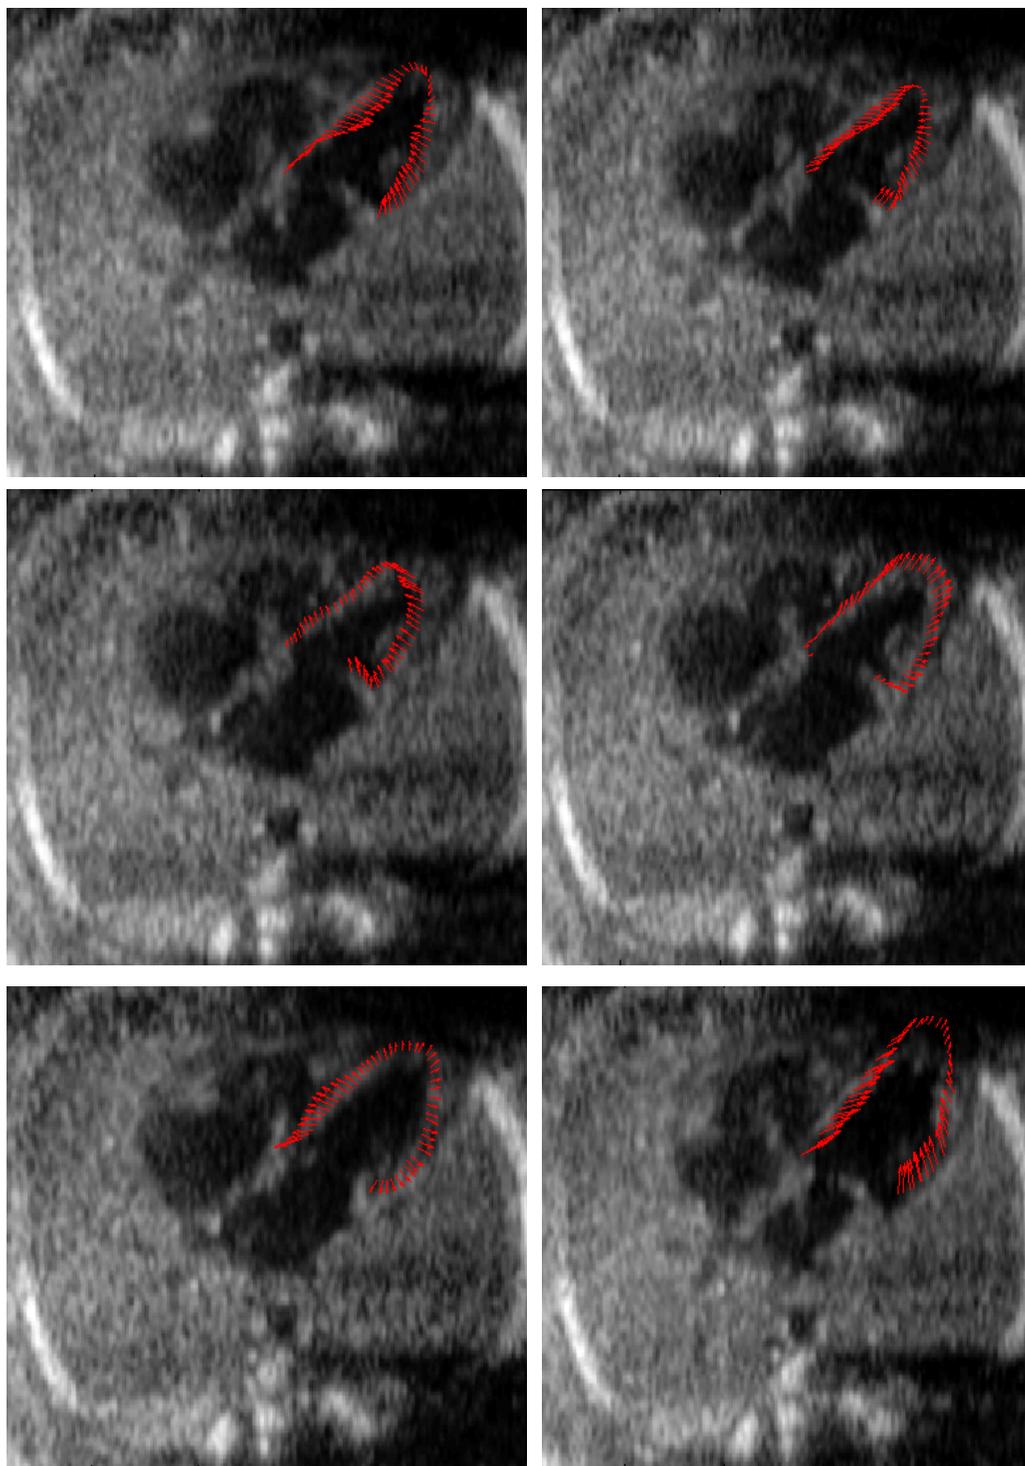


Figura 35. Resultados de la segmentación y estimación de movimiento para un estudio de ecocardiografía fetal. En este se presentan las imágenes 1, 4, 7, 10, 15 y 25 de la secuencia del ciclo cardiaco.

7. DISCUSIONES Y CONCLUSIONES

En este capítulo se presentan las discusiones y conclusiones correspondientes a cada una de las etapas del proyecto, teniendo en cuenta los experimentos, pruebas y resultados obtenidos en cada una de las evaluaciones.

Como se observa en la Figura 12, las imágenes de ultrasonido de corazón de fetos pueden presentar variaciones con respecto a las diferentes orientaciones y tamaños que exhiben las cavidades cardiacas. En general, los bordes de las cavidades no están bien definidos. Un efecto de esto es que resulta difícil encontrar los límites que separan el ventrículo izquierdo de la aurícula izquierda. Las variaciones que se tienen en este tipo de imágenes dependen de aspectos como el periodo gestacional del feto, la habilidad y experiencia por parte del especialista para adquirir las imágenes, y el sistema de ultrasonido. Teniendo en cuenta estos problemas, diseñar un algoritmo automático de inicialización es un gran reto debido a las variaciones presentes con respecto a la posición y orientación del ventrículo izquierdo en las imágenes de ultrasonido. En este trabajo, se propuso un esquema de inicialización el cual consiste de un método simple pero efectivo capaz de generar el contorno inicial del ventrículo izquierdo. Este algoritmo se basa principalmente en un proceso de detección de objetos. La región que corresponde a la estructura cardiaca es identificada y entonces un proceso de correlación es usado para encontrar la forma inicial. En la Figura 23 y la Tabla 1 se ilustran los resultados, los cuales demuestran la efectividad del esquema de inicialización desarrollado. Con la forma inicial cerca de la estructura de interés, el algoritmo de segmentación es capaz de ajustarse adecuadamente. El método de inicialización solo requiere del almacenamiento de una base de datos con muestras de parches que contienen la estructura y que describa las posibles variaciones encontradas en las imágenes de ecocardiografía fetal.

Se han presentado comparaciones cuantitativas entre el método propuesto y otros descritos en la literatura. Los métodos de segmentación usados para llevar a cabo las comparaciones fueron AAM clásico, *Snake* y ASM. Los resultados cuantitativos son mostrados en la Tabla 2 y la Figura 27. En la Figura 30 también se pueden observar algunos resultados cualitativos para dos imágenes de prueba. En todos los casos, el método AAM multi-textura desarrollado presenta mejores resultados que los otros métodos empleados para la comparación.

Entre los métodos que muestran resultados pobres se encuentran ASM y *Snake* debido a que se basan en esquemas de detección de bordes y perfiles. Esta característica dificulta su utilización en imágenes de ultrasonido. Es bien conocido que este tipo de imágenes no tienen bordes bien definidos. AAM clásico tiene mejor comportamiento que ASM y *Snake* porque el ajuste se realiza teniendo en cuenta el parche de textura encerrada por la forma o contorno. Aquí se tiene mayor información de la estructura y no solo datos del contorno como en los métodos anteriormente mencionados.

En el caso del modelo propuesto, se usan los coeficientes de Hermite rotados para los mapas de textura. Se combinaron los modelos de textura en un esquema de pesos con el objetivo de incluir más descripciones de la textura de la imagen. Con este esquema se incluyen diferentes características de la imagen, lo cual mejora los resultados de la segmentación en comparación con el método AAM clásico.

Uno de los principales problemas cuando se hace la segmentación de secuencias de imágenes de ultrasonido cardíaco fetal es la variación de la forma y las deformaciones en las estructuras durante el ciclo cardíaco. Los resultados mostrados en la Figura 31 demuestran que el peor desempeño ocurre cuando el ventrículo izquierdo está en la fase de mayor contracción, esto significa al final de la sístole. El ventrículo tiene una forma irregular y las regiones homogéneas de la cavidad no están bien definidas, haciendo que esta estructura sea más difícil de segmentar. La Figura 28 presenta dos imágenes de prueba en las cuales se pueden observar los cambios significativos que sufre la cavidad ventricular entre las fases de sístole y diástole.

El método desarrollado puede ser una herramienta útil para la evaluación del ventrículo izquierdo en secuencias ecocardiográficas fetales. Los resultados obtenidos con el método propuesto, y que fueron reportados en [53], presentan mejor desempeño que otros métodos de la literatura [19] [21] [22] [23] [24]. El coeficiente de DICE promedio obtenido para todas las evaluaciones realizadas fue de 0.8631, y la distancia punto-a-curva promedio lograda fue de 2.027 ± 0.9675 píxeles. Los resultados de la segmentación fueron muy aceptables en imágenes con grandes variaciones en el ventrículo izquierdo.

Por otra parte, se hizo una modificación para mejorar el problema de propagaciones indeseadas que presentaba el algoritmo de estimación de movimiento utilizando flujo óptico basado en la transformada de Hermite rotada [1]. La incorporación de un término de homogeneidad a este método hace que se tenga mayor control en las zonas donde no se genera movimiento o éste sea muy pequeño. Con esto se evita calcular campos de movimientos en zonas donde no existen, los cuales se generan debido a las restricciones y términos incluidos en el algoritmo original. Con esta nueva información incluida en el funcional de estimación, se mejora la versión propuesta en [1] obteniendo un algoritmo con mayor precisión con respecto a la estimación de movimiento en toda la imagen. Las comparaciones fueron realizadas y mostradas en la Figura 34. Además, se puede ver en la Tabla 5 que el desempeño del algoritmo modificado refleja un mejor funcionamiento comparado con otros empleados para el mismo fin.

Otro aspecto importante es que, al igual que en la segmentación, los mejores desempeños son logrados durante la fase de diástole, tal como se muestra en la Figura 34. Esta fase corresponde a las imágenes ubicadas entre la 20 y 40 de la secuencia usada. En esta etapa, los desplazamientos del ventrículo izquierdo son más pequeños.

El método de flujo óptico basado en la transformada de Hermite rotada [1] y la versión modificada propuesta demuestran ser bastante robustos con respecto a los cambios de intensidad y ruido

presente en las imágenes. Por lo cual, constituyen buenas alternativas cuando se trabaja con imágenes de ultrasonido.

Aunque los métodos desarrollados fueron aplicados a imágenes del corazón fetal, específicamente al análisis del ventrículo izquierdo, ellos pueden ser extendidos a otras aplicaciones donde se procesen otros tipos de imágenes, o bien a otras estructuras diferentes en las mismas imágenes de ecocardiografía fetal.

Aunque el método de segmentación propuesto presenta buenos desempeños, tiene la limitación o restricción de que el ajuste de la textura y la forma de la estructura están condicionados por el rango de variación de las muestras de entrenamiento. Por lo tanto, las variaciones que se pueden presentar en la cavidad ventricular entre las fases de sístole y diástole, algunas veces, puede dificultar la obtención de una segmentación precisa si se usa un solo modelo estadístico para describir ambas fases del ciclo cardiaco.

7.1. TRABAJOS FUTUROS

Teniendo en cuenta los resultados presentados en este trabajo, aún quedan abiertos diferentes aspectos que pueden ser desarrollados en futuras investigaciones. Algunos de las mejoras que pueden llevarse a cabo para realizar una segmentación más precisa y abordar algunas de las limitaciones de estos algoritmos son presentados a continuación.

Una de las mejoras que se puede incluir es el desarrollo de un modelo de segmentación multi-textura para las fases de sístole y diástole por separado, debido a que durante el ciclo cardiaco se presentan grandes diferencias en la apariencia de las estructuras cardiacas. Con esto se podría modelar con mejor precisión las variaciones que se pudieran presentar y hacer más robusto el algoritmo.

Por otra parte, uno de los aspectos importantes de esta investigación es realizar una evaluación cuantitativa de la función cardiaca, utilizando parámetros clínicos calculados a partir de los datos obtenidos de la segmentación y la estimación de movimiento. Esto con el objetivo de detectar anomalías fetales en una etapa temprana de gestación. Adicionalmente, la evaluación de estos algoritmos debe ser ampliada para fetos con enfermedades cardiacas.

8. BIBLIOGRAFIA

- [1] E. Moya-Albor, B. Escalante-Ramírez and E. Vallejo, "Optical flow estimation in cardiac CT images using the steered hermite transform," *Signal Processing: Image Communication*, 2012.
- [2] J. Rychik, N. Ayres, B. Cuneo, N. Gotteiner, L. Hornberger and P. Spevak, "American Society of Echocardiography Guidelines and Standards for Performance of the Fetal Echocardiogram," *J Am Soc Echocardiogr*, vol. 17, pp. 803-810, 2004.
- [3] J. Simpson, "Echocardiographic evaluation of cardiac function in the fetus," *Prenat. Diagn.*, vol. 8, no. 13, pp. 1-9, 2013.
- [4] F. S. Molina, C. Faro, A. Sotiriadis, T. Dagklis and K. Nicolaides, "Heart stroke volume and cardiac output by four dimensional ultrasound in normal fetuses," *Ultrasound Obstet. Gynecol.*, vol. 32, no. 2, pp. 181-187, 2008.
- [5] M. Marsousi, A. Eftekhari, A. Kocharian and J. Alirezaie, "Endocardial boundary extraction in left ventricular echocardiographic images using fast and adaptive B-spline snake algorithm," *Int. J. Comput. Assist. Radiol. Surg.*, vol. 5, no. 5, p. 501–513, 2010.
- [6] N. Paragios, M. Jolly, M. Taron and R. Ramara, "Active shape models and segmentation of the left ventricle in echocardiography," *Comput. Scivol.*, vol. 3549, p. 131–142, 2005.
- [7] T. Cootes, G. Edwards and C. Taylor, "Active appearance model," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 23, no. 6, p. 681–685, 2001.
- [8] T. Cootes and C. Taylor, "Constrained active appearance models," *Proc. IEEE Int. Conf. Comput. Vis.*, vol. 1, p. 748–754, 2001.
- [9] G. Hamarneh and T. Gustavsson, "Combining snakes and active shape models for segmenting the human left ventricle in echocardiographic images," *Proc. Comput. Cardio.*, vol. 27, p. 115–118, 2000.
- [10] M. Stegmann, *Generative Interpretation of Medical Images*, Lyngby: PhD thesis, Informatics and Mathematical Modelling, Technical University of Denmark, DTU, 2004.
- [11] G. Edwards, T. Cootes and C. Taylor, "Advances in active appearance models," *Proceedings of the Seventh IEEE International Conference on Computer Vision*, vol. 1, p. 137–142, 1999.
- [12] T. Cootes, A. HU1, C. Taylor and J. Haslam, "The Use of Active Shape Models for Locating Structures in Medical Images," *Image and Vision Computing*, vol. 12, pp. 355-366, 1994.

- [13] J. Ophir, S. Alam, B. Garra, K. F. E. Konofagou, T. Krouskop, C. Merritt, R. Righetti, R. Souchon, S. Srinivasan and T. Varghese, "Elastography: Imaging the Elastic Properties of Soft Tissues with Ultrasound," *Medical Ultrasound*, vol. 29, p. 155–171, 2002.
- [14] T. Cootes, G. Edwards and C. Taylor, "Comparing active shape models with active appearance models," *Proceedings of British Machine Vision Conference*, vol. 1, p. 173–182, 1999.
- [15] J. Bosch, S. Mitchell, B. Lelieveldt, F. Nijland, O. Kamp, M. Sonka and J. Reiber, "Automatic segmentation of echocardiographic sequences by active appearance motion models," *IEEE TransMed. Imag.*, vol. 21, no. 11, p. 1374–1383, 2002.
- [16] M. Kass and D. Terzopoulos, "Snake Active Contour Models," *IEEE International Conference in Computer Vision*, vol. 1, pp. 321-332, 1988.
- [17] S. Nandagopalan, B. Adiga, C. Dhanalakshmi and N. Deepak, "Automatic segmentation and ventricular border detection of 2D echocardiographic images combining K-Means clustering and active contour model," *Proc. Int. Conf. Comput. Netw. Technol.*, vol. 1, pp. 447-451, 2010.
- [18] A. Sarti, C. Corsi, E. Mazzini and C. Lamberti, "Maximum likelihood segmentation of ultrasound images with Rayleigh distribution," *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, vol. 52, no. 6, pp. 947-960, 2005.
- [19] Y. Guo, Y. Wang, S. Nie, J. Yu and P. Chen, "Automatic segmentation of a Fetal echocardiogram using modified active appearance model and sparse representation," *IEEE Transactions on biomedical engineering*, vol. 61, no. 4, pp. 1121-1133, 2014.
- [20] T. Cootes, C. Beeston, G. Edwards and C. Taylor, "A Unified Framework for Atlas Matching Using Active Appearance Models," *Proceedings of the 16th International Conference on Information Processing in Medical Imaging*, vol. 1613, p. 322–333, 1999.
- [21] S. Sampath and N. Sivaraj, "Fuzzy connectedness based segmentation of fetal heart from clinical ultrasound images," *Advanced Computing, Networking and Informatics*, p. 329–337, 2014.
- [22] I. Dindoyal, T. Lambrou, J. Deng and A. Todd-Pokropek, "Level set snake algorithms on the fetal heart," in *Biomedical Imaging: From Nano to Macro, 2007. ISBI 2007. 4th IEEE International Symposium on*, Washington, 2007.
- [23] T. A. Lassige, P. Benkeser, D. Fyfe and S. Sharma, "Comparison of septal defects in 2D and 3D echocardiography using active contour models," *Computerized Medical Imaging and Graphics*, vol. 24, no. 6, p. 377–388, 2000.
- [24] Y. Deng, Y. Wang, Y. Shen and P. Chen, "Active cardiac model and its application on structure detection from early fetal ultrasound sequences," *Computerized Medical Imaging and Graphics*, vol. 36, no. 3, p. 239–247, 2012.

- [25] J. Ophir, I. Cespedes, H. Ponnekanti, Y. Yazdi and X. Li, "Elastography: a quantitative method for imaging the elasticity of biological tissues," *Ultrasonic Imaging*, vol. 13, p. 111–134, 1991.
- [26] J. Bercoff, S. Chaffai, M. Tanter, L. Sandrin, S. Catheline, M. Fink, Gennisson and M. Meunier, "In vivo breast tumor detection using transient elastography," *Ultrasound in Medicine and Biology*, vol. 29, p. 1387–1396, 2003.
- [27] K. Nightingale, M. Palmeri, R. Nightingale and G. Trahey, "On the feasibility of remote palpation using acoustic radiation force," *Journal of the Acoustical Society of America*, vol. 110, p. 625–634, 2001.
- [28] Z. Quian, A. Montillo and D. Metaxas, "Segmenting cardiac MRI tagging lines using gabor filter banks," *Proceedings of International Conference of the Engineering in Medicine and Biology Society*.
- [29] J. Kybic and M. Unser, "Fast parametric elastic image registration," *IEEE Trans. Image Processing*, vol. 12, pp. 1427-1442, 2003.
- [30] M. Ledesma-Carbayo and P. Mahía-Casado, "Cardiac motion analysis from ultrasound sequences using nonrigid registration: Validation against Doppler tissue velocity," *Ultrasound in Medicine and Biology*, vol. 32, no. 4, pp. 483-490, 2006.
- [31] J. Barron, D. Fleet and S. Beauchemin, "Performance of optical flow techniques," *Int. J. Comp. Vis.*, vol. 12, pp. 43-77, 1994.
- [32] M. Sühling, M. Arigovindan, C. Jansen, P. Hunziker and M. Unser, "Myocardial motion analysis from B. mode echocardiograms," *IEEE Trans. Image Processing*, vol. 14, pp. 525-536, 2005.
- [33] C. L. Fennema and W. B. Thomson, "Velocity determination in scenes containing several moving objects," *Computer Graphics and Image Processing*, vol. 9, 1979.
- [34] A. Bruhn, W. J. and Towards, "Ultimate motion estimation: Combining highest accuracy with real-time performance," *Proc. Tenth IEEE International Conference on Computer Vision*, vol. 1, pp. 749-755, 2005.
- [35] B. Horn and B. Schunck, "Determining optical flow," *Artificial Intelligence*, vol. 17, p. 185–203, 1981.
- [36] H.-H. Nagel and W. Enkelmann, "An investigation of smoothness constraints for the estimation of displacement vector fields from image sequences," *IEEE Trans Pattern Anal Mach Intell*, pp. 168-176, 1986.
- [37] D. J. Fleet and A. Jepson, "Computation of component image velocity from local phase information," *International Journal of Computer Vision*, vol. 5, no. 1, 1990.
- [38] M. Strintzis and I. Kokkinidis, "Maximum likelihood motion estimation in ultrasound image sequences," *IEEE Signal Process Lett*, vol. 4, pp. 156-157, 1997.

- [39] B. Cohen and I. Dinstein, "New maximum likelihood motion estimation schemes for noisy ultrasound image," *Pattern Recogn*, vol. 35, pp. 455-463, 2002.
- [40] D. Boukerroui, A. Noble and M. Brady, "Velocity estimation in ultrasound image: a block matching approach," in *Proc. 18th Int. Conf on Inf Process Med. Imaging*, pp. 586-598, 2003.
- [41] J. Revell, M. Mirmehdi and D. McNally, "Computer vision elastography:speckle adaptive motion estimation for elastography using ultrasound sequences," *IEEE Trans Med Imag*, vol. 24, pp. 775-766, 2005.
- [42] M. Alessandrini, A. Basarab, H. Liebgott and O. Bernard, "Myocardial Motion Estimation from Medical Images Using the Monogenic Signal," *IEEE Trans. Image Process*, vol. 22, no. 3, pp. 1084-1095, 2013.
- [43] J. Wang and E. Adelson, "Representing moving images with layers," *IEEE Transactions on Image Processing*, vol. 3, no. 5, pp. 625-638, 1994.
- [44] L. Chen-Hsien, L. Chii-Jeng and S. Yung-Nien, "Ultrasound Motion Estimation using Hierarchical Feature Weighting Algorithm," *Comput Med Imag Grap*, vol. 31, pp. 178-190, 2007.
- [45] T. Helle-Valle, J. Crosby, T. Edvardsen, E. Lyseggen, B. H. Amundsen, H.-J. Smith, B. D. Rosen, J. Lima, A. H. Torp, H. Ihlen and O. A.Smiseth, "New noninvasive method for assessment of left ventricular rotation: Speckle tracking echocardiography," *Circulation*, vol. 112, pp. 3149-3156, 2005.
- [46] T. Hergum, J. Crosby, M. Langhammer and H. Torp, "The efect of including fiber orientation in simulated 3d ultrasound images of the heart," *IEEE Ultrasonics Symposium*, pp. 1991-1994, 2006.
- [47] S. Holm and IntelCorporation, "Block-matching in motion estimation algorithms using Streaming SIMD Extensions 3," *Intel Software Network*, 2003.
- [48] J. Revell, M. Mirmegdi and D. McNally, Ultrasound speckle tracking for strain estimation, Technical Report CSTR-04-005, Univ. of Bristol, 2003.
- [49] Q. Duan, E. Angelini, S. Homma and A. Laine, "Validation of optical-flow for quantification of myocardial deformations on simulated RT 3D ultrasound," *International Symposium on Biomedical Imaging IEEE*, p. 944-947, 2007.
- [50] J. Andrade, L. Cortez, O. Campos, A. Arruda, J. Pinheiro, L. Vulcanis, T. Shiratsuchi, R. Kalil-Filho and G. Cerri, "Left ventricular twist: comparison between two and three-dimensional speckle-tracking echocardiography in healthy volunteers," *European Journal of Echocardiography*, vol. 12, 2011.

- [51] Basarab, W. Aoudi, H. Liebgott, D. Vray and P. Delachartre, "Parametric deformable block matching for ultrasound imaging," in *IEEE International Conference on Image Processing ICIP'07*, San Antonio, USA, 2007.
- [52] H. Basarab, F. Liebgott, A. Morestin, T. Lyschik, R. Higashi and P. Delachartre, "A method for vector displacement estimation with ultrasound images and its application for thyroid nodular disease," *Med Image Anal*, vol. 12, no. 3, pp. 259-274, 2008.
- [53] L. Vargas-Quintero, B. Escalante-Ramírez, L. Camargo Marín, M. Guzmán Huerta, F. Arámbula Cosío and H. Borboa Olivares, "Left ventricle segmentation in fetal echocardiography using a multi-texture active appearance model based on the steered Hermite transform," *Computer Methods and Programs in Biomedicine*, vol. 137, pp. 231-245, 2016.
- [54] J. Hoffman and K. S., "The incidence of congenital heart disease," *J AM Coll Cardiol*, vol. 39, pp. 1890-1900, 2002.
- [55] M. Donofrio and A. Massaro, "Impact of congenital heart disease on brain development and neurodevelopment outcome," *Int J Pediatr*, 2010.
- [56] L. Hornberger, A. Moon-Grady and W. Tworetzky, "Fetal echocardiography and Prenatal Cardiovascular Interventions – An Update," *J Clin Exp Cardiol*, vol. S8, 2012.
- [57] M. Mendoza, C. Cabrera-Arroyo and E. Mendoza-Reyes, "Diagnóstico y pronóstico fetales de la anomalía de Ebstein," *Ginecol Obstet Mex*, vol. 82, pp. 93-104, 2014.
- [58] D. A. Lindsey, "A practical approach to fetal heart scanning," *Seminars in Perinatology*, vol. 24, no. 5, pp. 324-330, 2000.
- [59] C. Comstock, "Normal fetal heart axis and position," *Obstet Gynecol*, vol. 70, p. 255–259, 1987.
- [60] J. Carvalho, L. Allan, R. Chaoui, J. Copel, G. DeVore, K. Hecher, W. Lee, H. Munoz, D. Paladini and B. Tutschek, "Isuog practice guidelines (updated): sonographic screening examination of the fetal heart," *Ultrasound in Obstetrics & Gynecology*, vol. 41, no. 3, p. 348–359, 2013.
- [61] International Society of Ultrasound in Obstetrics & Gynecology, "Cardiac screening examination of the fetus: guidelines for performing the 'basic' and 'extended basic' cardiac scan," *Ultrasound Obstet Gynecol*, vol. 27, p. 107–113, 2006.
- [62] M.-Y. Lee and H.-S. Won, "Technique of fetal echocardiography," *Obstet Gynecol*, vol. 56, no. 4, pp. 217-226, 2013.
- [63] A. Estudillo-Romero and B. Escalante-Ramirez, "Rotation invariant texture features from the steered Hermite transform," *Pattern Recognit Lett*, vol. 32, no. 16, pp. 2150-2162, 2011.
- [64] J.-B. Martens, "The Hermite transform—applications," *IEEE Transactions Acoustics, Speech, Signal Processing*, vol. 38, no. 9, p. 1607–1618, 1990.

- [65] B. Escalante-Ramírez, "The Hermite transform as an efficient model for local image analysis: An application to medical image fusion," *Computers & Electrical Engineering*, vol. 34, no. 2, 2008.
- [66] J.-B. Martens, "The Hermite transform—theory," *IEEE Transactions Acoustics, Speech, Signal Processing*, vol. 38, no. 9, p. 1595–1606, 1990.
- [67] L. Barba-J, E. Moya-Albor, B. Escalante-Ramírez, J. Brieva and E. Vallejo, "Segmentation and optical flow estimation in cardiac CT sequences based on a spatiotemporal PDM with a correction scheme and the Hermite transform," *Computers in biology and medicine*, vol. 69, pp. 189-202, 2016.
- [68] W. T. Freeman and E. H. Adelson, "The Design and Use of Steerable Filters," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 13, no. 9, 1991.
- [69] J. L. Silván-Cárdenas and B. Escalante-Ramírez, "The Multiscale Hermite Transform for Local Orientation Analysis," *IEEE Transactions on Image Processing*, vol. 15, no. 5, 2006.
- [70] Y. Ge, D. D. Yang, J. Lu, B. Li and X. Zhang, "Active appearance models using statistical characteristics of Gabor based texture representation," *J Vis Commun Image Represent*, vol. 24, no. 5, pp. 627-634, 2013.
- [71] P. W. Hawkes, *Advances in Imaging and Electron Physics*, USA: Academic Press, 2003.
- [72] B. Escalante-Ramírez, E. Moya-Albor, L. Barba-J, F. Arambula Cosio and E. Vallejo, "Motion estimation and segmentation in CT cardiac images using the Hermite transform and active shape models," *Proc. SPIE 8856*, vol. 8856, pp. 88561E–1 - 88561E-15, 2013.
- [73] Y. Shi and H. Sun, "Image and Video Compression for Multimedia Engineering: Fundamentals, Algorithms, and Standards," *CRC Press*, pp. 221-248, 2000.
- [74] Y. Correc and E. Chapius, "Fast computation of Delaunay triangulations," *Advances in Engineering Software*, vol. 9, no. 2, p. 77–83, 1987.
- [75] T. Cootes and C. Taylor, "On representing edge structure for model matching," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern*, vol. 1, pp. I-1114, 2001.
- [76] I. Scott, T. Cootes and C. Taylor, "Improving appearance model matching using local image structure," *Information Processing in Medical Imaging*, pp. 258-269, 2003.
- [77] P. Kittipanya-ngam and T. Cootes, "The effect of texture representations on AAM performance," in *18th International Conference on Pattern Recognition, 2006 (ICPR 2006)*, Hong Kong, 2006.

- [78] E. Antonakos, J. Alabort-i Medina, G. Tzimiropoulos and S. Zafeiriou, "Feature-based Lucas-Kanade and active appearance models," *IEEE Trans Image Process*, vol. 24, no. 9, p. 2617–2632, 2015.
- [79] Y. Su, D. Tao, X. Li and X. Gao, "Texture representation in AAM using Gabor wavelet and local binary patterns," in *IEEE International Conference on Systems, Man and Cybernetics, 2009 (SMC 2009)*, USA, 2009.
- [80] S. Ghose, A. Oliver, R. Mart, X. Lladó, J. Freixenet and J. C. Vilanova, "Prostate segmentation with texture enhanced active appearance model," in *2010 Sixth International Conference on Signal-Image Technology and Internet-Based Systems (SITIS), IEEE*, Kuala Lumpur, 2010.
- [81] V. Damerjian, O. Tankyevych, N. Souag and E. Petit, "Speckle characterization methods in ultrasound images - A review," *IRBM*, vol. 35, no. 4, p. 202–213, 2014.
- [82] Wang, B; Liu, D C, "A novel edge enhancement method for ultrasound imaging," in *International Conference on Bioinformatics and Biomedical Engineering*, 2008.
- [83] B. Lucas and T. Kanade, "An iterative image registration technique with an application to stereo vision," *Proc. Seventh International Joint Conference on Artificial Intelligence*, p. 674–679, 1981.
- [84] I. Cohen, "Nonlinear variational method for optical flow computation," *Proc. Eighth Scandinavian Conference on Image Analysis*, vol. 1, pp. 523-530, 1993.
- [85] L. I. Rudin, S. Osher and E. Fatemi, "Nonlinear total variation based noise removal algorithm," *Physica D*, vol. 60, pp. 259-268, 1992.
- [86] T. Brox, A. Bruhn, N. Papenberg and W. J, "High Accuracy Optical Flow Estimation Based on a Theory for Warping," *Proc. 8th European Conference on Computer Vision, Springer*, vol. 4, pp. 25-36, 2004.
- [87] N. Papenberg, A. Bruhn, T. Brox and e. al., "Highly Accurate Optic Flow Computation with Theoretically Justified Warping," *Int J Comput Vision*, vol. 67, pp. 141-158, 2006.
- [88] M. Black and A. P, "Estimating optical flow in segmented images using variable – order parametric models with local deformation," *IEEE Trans Pattern Anal Mach Intell*, vol. 18, pp. 947-952, 1994.
- [89] M. J. Black and P. Anandan, "The Robust Estimation of Multiple Motions: Parametric and Piecewise-Smooth Flow Fields," *Comput Vis Image Underst*, vol. 63, no. 1, pp. 75-104, 1996.
- [90] E. Mémin and P. Pérez, "A multigrid approach for hierarchical motion estimation," *Proceedings of the Sixth International Conference on Computer Vision,,* pp. 933-938, 1998.
- [91] E. Mémin and P. Pérez, "Hierarchical Estimation and Segmentation of Dense Motion Fields," *Int J Comput Vis*, vol. 46, no. 2, pp. 129-155, 2002.

- [92] A. Bruhn, J. Weickert and C. Schnörr, "Lucas/Kanade Meets Horn/Schunck: Combining Local and Global Optic Flow Methods," *Int J Comput Vis*, vol. 61, no. 3, pp. 211-231, 2005.
- [93] B. Escalante-Ramirez, J. L. Silvan-Cardenas and H. Yuen-Zhuo, "Optic flow estimation using the Hermite transform," *SPIE Proceedings*, vol. 5558, pp. 632-643, 2004.
- [94] H. Liu, T. H. Hong, M. Hermn and R. Chellappa, "A general motion model and spatio-temporal filters for computing optical flow," *Int J Comput Vis*, vol. 22, pp. 141-172, 1997.
- [95] J. Bigun, G. H. Granlund and J. Wiklund, "Multidimensional orientation estimation with applications to texture analysis and optical flow," *IEEE Trans Pattern Anal Mach Intell*, vol. 13, no. 8, pp. 775-790, 1991.
- [96] A. Bruhn, J. Weickert and C. Schnorr, "The advantages of local and global optic flow methods," *Pattern Recognition*, vol. 2449, pp. 454-462, 2002.
- [97] A. Bruhn, F. C. Weickert, T. Kohlberger and C. Schnorr, "Variational optic flow computation in real-time," *IEEE Transactionson Image Processing*, vol. 14, no. 5, pp. 608-615, 2003.
- [98] G. Aubert, R. Deriche and P. Kornprobst, "Computing Optical Flow via Variational Techniques," *SIAM J Appl Math*, vol. 60, pp. 156-182, 1999.
- [99] N. Carranza-Herrezuelo, A. Bajo, F. Sroubek, C. Santamarta, G. Cristobal, A. Santos and M. Ledesma-Carbayo, "Motion estimation of tagged cardiac magnetic resonance images using variational techniques," *Computerized Medical Imaging and Graphics*, vol. 34, p. 514-522, 2010.
- [100] M. Alessandrini, H. Liebgott, D. Friboulet and O. Bernard, "Highly realistic simulation of ultrasonic sequences for ground truth validation of motion estimation," *IEEE International Symposium on Biomedical Imaging (ISBI)*, 2012.
- [101] S. Baker, D. Scharstein, J. P. Lewis, S. Roth, M. J. Black and R. Szelisk, "A database and evaluation methodology for optical flow," *Int J Comput Vis*, vol. 92, pp. 1-31, 2011.