

Métodos de segmentación de imágenes cardíacas: Fundamentos y alcance

Medical Imaging Segmentation Methods: Foundations and Scope

Yoleidy Huérfano, MgSc¹, Miguel Vera, MgSc. PhD^{2*}, Atilio Del Mar, MD³, José Chacón, MgSc, PhD², María Vera, MD¹, Nahid Bautista, MgSc², María Sofía Martínez, MD⁴, Joselyn Rojas, MD, MgSc^{4,7}, Julio Contreras, MgSc⁵, Modesto Graterol Rivas, MgSc, PhD⁶, Sandra Wilches, MgSc⁵, Miguel Aguirre, MD, MgSc⁴, Marcos Cerda, MgSc⁵, Carlos Garicano, MDS, Juan Diego Hernández Ing, MgSc⁴, Víctor Arias, Ing⁵ Rosemily Graterol, MgSc⁶, Maricarmen Chacín, MD, MgSc⁴, Armando Peña, MgSc⁵, Valmore Bermúdez, MD, MPH, MgSc, PhD⁴, Antonio Bravo, MgSc, PhD⁸

¹Grupo de Investigación en Procesamiento Computacional de Datos (GIPCD-ULA) Universidad de Los Andes-Táchira, Venezuela.

²Grupo de Investigación en Ingeniería Biomédica del Caribe (INGEBIOCARIBE), Universidad Simón Bolívar, Colombia.

E-mail de correspondencia: veramig@gmail.com*.

³Instituto de Bioingeniería y Diagnóstico Sociedad Anónima (IBIDSA), San Cristóbal, Venezuela. e-mail: atiliodelmar@yahoo.com

⁴Centro de Investigaciones Endocrino-Metabólicas "Dr. Félix Gómez" (CIEM). Facultad de Medicina. Universidad del Zulia, Venezuela.

⁵Grupo de Investigación Altos Estudios de Frontera (ALEF), Universidad Simón Bolívar, Cúcuta, Colombia.

⁶Centro de Estudios de la Empresa. Universidad del Zulia, Venezuela

⁷Pulmonary and Critical Care Medicine Department. Brigham and Women's Hospital. Harvard Medical School. Boston, MA. USA 02115.

⁸Coordinación de Investigación Industrial, Decanato de Investigación, Universidad Nacional Experimental del Táchira, San Cristóbal, Venezuela.

e-mail: antonio.j.bravo@gmail.com

Resumen

La segmentación de estructuras cardíacas es un problema de gran interés para la comunidad médica internacional y, en particular, para los especialistas en cardiología ya que la segmentación de tales estructuras es útil para la cuantificación y el monitoreo de la función cardiovascular. Por otra parte, la segmentación de imágenes cardíacas constituye un verdadero desafío, debido a que: 1) el corazón realiza movimientos no rígidos de naturaleza compleja, 2) la presencia de bajo contraste entre el fluido sanguíneo y los tejidos que componen dichas estructuras, y 3) la presencia de artefactos y de ruido. Por estas razones, mediante el presente trabajo se presenta una revisión de los diversos métodos utilizados para la segmentación de imágenes cardíacas, en las diversas modalidades de imagenología. Adicionalmente, se presenta una aproximación al problema de segmentación de las estructuras cardíacas y se analizan los fundamentos teóricos de los métodos de segmentación más utilizados en el área médica.

Palabras clave: Ecocardiografía, Tomografía axial computarizada, enfermedad arterial coronaria, métodos de segmentación, insuficiencia cardíaca.

Abstract

Cardiac structures segmentation is a great interest issue to medical community, particularly, in cardiology since the segmentation of heart structures is useful for quantification and monitoring of cardiovascular function. Moreover, segmentation of cardiac imaging is a real challenge, because three main technical problems: 1) not rigid and complex nature of cardiac movements' production, 2) low contrast between blood fluid and cardiac tissues, and 3) the presence of artifacts and noise. For these reasons, through this work, a review of several methods for segmenting cardiac imaging by several image techniques is presented. Additionally, an approach to cardiac structures segmentation problem is displayed and cardiac segmentation methods theoretical foundations are analyzed.

Keywords: ecocardiography, computed axial tomography, coronary artery disease, segmentation methods, heart failure.

El principal objetivo del presente trabajo es realizar una revisión y un análisis del estado del arte de los métodos de segmentación de imágenes cardíacas usando diversas modalidades de imagenología médica. En los últimos años, en el contexto de la medicina, se ha desarrollado un gran interés por la segmentación de imágenes médicas, particularmente, las de tipo cardíaco debido a dos motivaciones centrales. Por una parte, está el alto índice de muertes que anualmente producen las enfermedades de índole cardíaca, según lo reporta la Organización Mundial de la Salud, ente que ubica este tipo de enfermedades, como la primera causa de muerte en el mundo¹. Y por la otra, como un dato de referencia fundamental, es necesario indicar la invaluable utilidad que la segmentación de imágenes cardíacas representa para la comunidad médica internacional, debido a que la información derivada de dicha segmentación, permite la valoración y el monitoreo de la función cardiovascular². La Sección 1, plantea el problema de la segmentación de las estructuras cardíacas; mientras que en la Sección 2, se presentan los principios teóricos que fundamentan los métodos de segmentación y se describen algunas metodologías desarrolladas para la segmentación de las estructuras cardíacas. Finalmente, se construyen las conclusiones derivadas del proceso de revisión de las referidas técnicas de segmentación.

1. Breve descripción del problema de segmentación de imágenes cardíacas

En el contexto médico, es rutinario extraer información muy útil de las imágenes adquiridas mediante diversas modalidades imagenológicas tales como Ultrasonido (US), Resonancia magnética (MRI), Tomografía computarizada convencional (CT) y multicapa (MSCT), Tomografía computarizada por emisión de positrones (PET), Tomografía por emisión de fotones simples (SPECT), entre otras. Habitualmente, los médicos especialistas fijan su atención en una escena, órgano, objeto ó región particular y hacen uso de su experiencia para establecer un diagnóstico. Muchas veces estos especialistas deben desarrollar un proceso de delineación del órgano que se desea estudiar (segmentación manual) para obtener parámetros de interés clínico que fundamenten su diagnóstico. Durante el desarrollo de la segmentación manual los médicos deben procesar un número importante de capas o imágenes cuya agrupación ordenada y sistemática conforman la estructura del órgano sujeto a análisis.

Formalmente, la segmentación de imágenes es una técnica de procesamiento digital de imágenes que permite obtener una descripción precisa de la forma

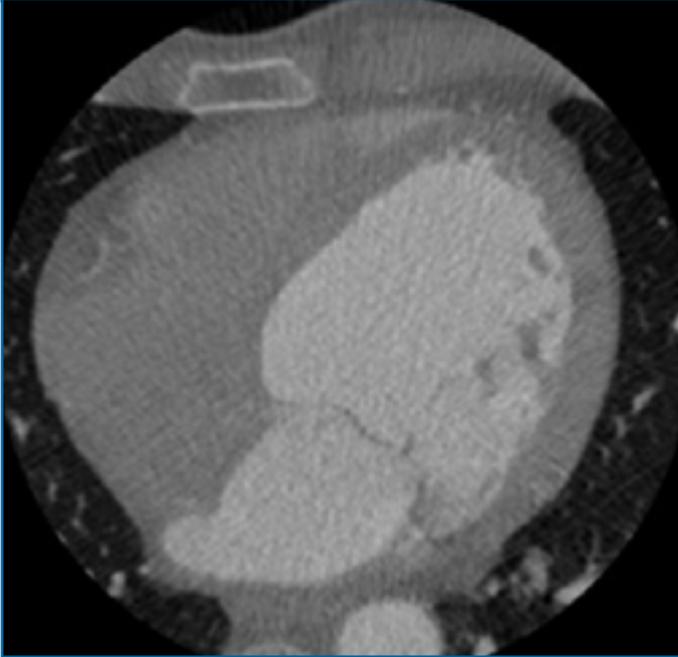
de los objetos presentes en una escena. La segmentación es también la partición de una imagen en muchas regiones no solapadas³. Luego de aplicar el proceso de segmentación, es posible generar tantas regiones independientes como objetos presentes en la imagen considerada.

Adicionalmente, es importante señalar que la segmentación de imágenes médicas constituye un problema abierto ya que cada modalidad de imagenología genera enormes cantidades de información la cual, típicamente, contiene una serie de imperfecciones debido a múltiples factores entre los que se pueden mencionar: ruido, artefactos, no-homogeneidad de los tejidos que conforman el cuerpo humano, entre otros

Además, la segmentación de estructuras presentes en imágenes cardíacas constituye un problema desafiante debido a diversas razones, entre las que cabe señalar: complejidad y diversidad de los movimientos no rígidos que presenta el corazón², el bajo contraste entre el fluido sanguíneo y los tejidos que componen las estructuras cardíacas, la presencia de artefactos (el paciente, durante el proceso de adquisición de las imágenes, puede moverse, respirar de manera no controlada o toser) y por la generación de ruido aleatorio (como el producido por la línea de alimentación de los equipos de adquisición de las imágenes)⁴. Como consecuencia de ello, todas las modalidades imagenológicas generan imágenes con múltiples imperfecciones lo cual constituye el principal obstáculo a superar cuando se pretende extraer la morfología de cualquier órgano o escena de interés.

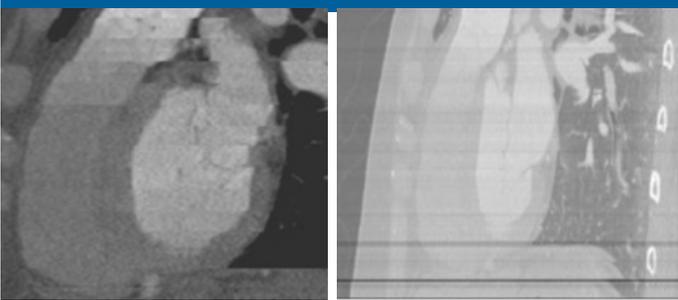
Sólo con el propósito de describir las mencionadas imperfecciones será considerada, a manera de ejemplo, las imágenes derivadas de tomografía computarizada multicapa (MSCT). La MSCT produce imágenes en las que se aprecia, con facilidad, un tipo de ruido denominado Poisson el cual es de naturaleza no aditiva y se caracteriza por ser dependiente de la intensidad que posee cada vóxel en la imagen. En tales imágenes, el ruido Poisson se manifiesta mediante la aparición de intensidades aleatorias, de aspecto granuloso, que se producen por efectos inherentes a la naturaleza del fenómeno de emisión de fotones de rayos X y al equipo usado durante la adquisición⁵. La figura 1, muestra este tipo de ruido en una imagen cardíaca de MSCT.

Figura 1: Vista axial de una imagen cardiaca de MSCT, en la que se observa el aspecto granular indicativo de la presencia de ruido Poisson.



De manera complementaria, en el ámbito del procesamiento digital de imágenes, el termino artefacto es atribuido, teóricamente, a una discrepancia sistemática entre las intensidades pertenecientes a las imágenes obtenidas luego de un proceso de reconstrucción y los verdaderos valores para los coeficientes de atenuación de los objetos presentes en la imagen real⁶. Particularmente, las imágenes cardiacas de MSCT sincronizadas con la onda R del ECG, son fuertemente sensitivas a cambios del latido cardiaco. En este sentido, debido a fallos en tal sincronización se pueden producir tanto la superposición de capas como artefactos generados por el movimiento del corazón. Además, la adquisición de imágenes en fases inconsistentes del ciclo cardiaco puede generar artefactos que pueden ser visualizados en vistas axiales de tales imágenes⁷, tal y como lo muestra la figura 2 en la cual se destacan los dos artefactos (escalera y banda oscura) que aparecen con mayor frecuencia en las imágenes de

Figura 2



Imágenes cardiacas de MSCT, en las que se puede observar: a) Bandas horizontales de diversas tonalidades que afectan la calidad de la imagen (Artefacto banda oscura). b) Discontinuidades dramáticas del contorno que delimita las estructuras cardiacas (Artefacto escalera).

Por otra parte, diversas técnicas han sido propuestas para reducir el efecto del ruido y de los artefactos durante la generación de las imágenes de MSCT. La mayoría de estas técnicas están orientadas hacia la disminución del impacto en la calidad de tales imágenes tanto del ruido como de los artefactos relacionados con el paciente como, por ejemplo, los artefactos producidos por movimientos voluntarios o involuntarios del paciente o aquellos generados por objetos localizados en su cuerpo^{8,9,10}. Sin embargo, a pesar de los esfuerzos de los desarrolladores de software y de las casas fabricantes de tomógrafos para corregir tal impacto, aún persisten ciertos factores que habilitan su generación y por ende su aparición notoria en las imágenes de MSCT afectando la calidad de las mismas.

La situación descrita en el párrafo anterior, debería promover la creación de técnicas computacionales, aplicables pos adquisición, que permitan abordar el problema de los artefactos y de la presencia de ruido en las imágenes de MSCT de manera que se pueda elevar la calidad de tales imágenes y posibilitar un apoyo clínico que facilite a los cardiólogos la emisión de diagnósticos precisos, prescribir tratamientos efectivos y, de ser necesario, planificar intervenciones quirúrgicas.

Adicionalmente, como se verá en la próxima sección, en un intento por dar alternativas de solución al problema de segmentación de las estructuras cardiacas, se ha desarrollado una serie de algoritmos para generar segmentaciones automáticas o semiautomáticas, las cuales requieren diversos grados de interacción por parte del usuario.

A pesar de este gran esfuerzo, no existe una metodología robusta y eficiente que haya sido validada clínicamente y que permita resolver el problema de la segmentación en imágenes cardiacas para cada una de las diversas modalidades de adquisición de imágenes, ya mencionadas.

Por esta razón, en la actualidad, se sigue promoviendo el desarrollo de investigaciones tendientes a abordar, efectivamente, los problemas descritos. En este sentido, como un esquema general, derivado de la revisión de las referencias bibliográficas especializadas en el área, se puede afirmar que el algoritmo de segmentación más efectivo se obtiene configurando cuidadosamente, combinaciones de componentes y ajustando los parámetros de estos componentes de acuerdo tanto con la modalidad usada, como con los atributos de las estructuras cardiacas, candidatas a ser segmentadas¹¹.

2. Métodos de segmentación de imágenes: fundamentos y aplicaciones en imágenes cardiacas

Los métodos de segmentación cardiaca desempeñan un papel fundamental en el análisis de las imágenes cardiacas, el diagnóstico de enfermedades cardiacas, el modelamiento geométrico de dichas estructuras y en la construcción de modelos biomecánicos utilizados

en la simulación de cirugías cardíacas¹². Debido a ello, la segmentación manual, semi-automática y automática ha sido ampliamente desarrollada en procesamiento de imágenes médicas cardíacas.

En el trabajo clásico de Pham et al.¹³, se propone una clasificación para diversos métodos utilizados en la segmentación de imágenes médicas. Mediante ella se agrupan los métodos de la siguiente forma: A. Métodos de umbralización, B. Métodos basados en crecimiento de regiones, C. Métodos de aprendizaje, D. Métodos de agrupamiento, E. métodos físicos y F. Métodos guiados por atlas.

Así, el problema de la segmentación de estructuras cardíacas ha sido abordado mediante distintas técnicas como, por ejemplo: 1) Los métodos de crecimiento de regiones para extraer contornos prominentes y discontinuidades entre regiones no homogéneas de una imagen. 2) Los métodos guiados por atlas que han sido empleados para separar regiones de acuerdo a sus características visuales (2). Particularmente, Sun et al.¹⁴ introdujeron un modelo Bayesiano para segmentar recursivamente objetos presentes en secuencias de imágenes cardíacas obtenidas por resonancia magnética. En este método, la segmentación del ventrículo izquierdo o en cada instante cardíaco se basa no solo en la información del instante actual sino también en la información que suministra la predicción pasada y futura de los contornos estimados inicialmente.

Otra metodología que también ha sido aplicada en la segmentación de imágenes, es la basada en modelos de contornos activos tipo serpiente. Este modelo representa una curva parametrizada que permite segmentar objetos, permitiendo deformaciones que tienden hacia las zonas de bajo potencial y aislando contornos en la imagen; las optimizaciones de este algoritmo se iniciaron con la configuración de la suavidad con la que la curva tiende hacia los contornos. Este modelo posee limitaciones, ya que depende de las condiciones iniciales, de la parametrización de la curva, la habilidad para manejar estructuras con múltiples componentes y la estimación de las propiedades geométricas de la curva¹⁵.

Adicionalmente, son extensas y muy variadas las investigaciones que se han desarrollado a nivel mundial tratando de producir técnicas capaces de segmentar las estructuras presentes en imágenes cardíacas generándose diversas aplicaciones prácticas como, por ejemplo, la presentada por Yamamoto et al.¹⁶, quienes desarrollaron una herramienta para la visualización 4D de las estructuras cardíacas presentes en secuencias de imágenes obtenidas por MSCT. Esta herramienta permite calcular, de manera semi-automática, la fracción de eyección y una curva del volumen cardíaco para la estimación del movimiento y el volumen del ventrículo izquierdo. Este modelo, también incluye el uso de una herramienta de selección de una región de interés.

A. Métodos de Umbralización

Los métodos de umbralización requieren ajustar el umbral de detección a un nivel que permita separar el fondo de una imagen del resto de los objetos presentes en la misma de una forma óptima. A continuación se presenta una síntesis de los métodos de umbralización considerados en los trabajos de Palmn et al.¹³ y Sezging et al.¹⁷.

Métodos basados en la forma del histograma: En este caso, los picos, los valles y las curvaturas de los histogramas correspondientes a las imágenes son analizados.

Métodos basados en agrupamientos: En ellos, las muestras de nivel de gris son agrupadas en dos regiones -el fondo y los objetos que no pertenecen a él- o alternativamente estas muestras son modeladas como una mezcla de funciones gaussianas.

Métodos basados en entropía: En estos, se utilizan como métodos de segmentación la entropía tanto del fondo como de los objetos y la entropía cruzada entre la imagen binarizada y la original.

Métodos basados en los atributos de los objetos: Estos métodos establecen una medida de similitud entre las imágenes binarizadas y las imágenes en nivel de gris, tales como similitud de la forma difusa y coincidencia de los bordes, entre otros.

Métodos espaciales: utilizan una distribución de probabilidad de alto orden, así como la correlación entre los píxeles para realizar la segmentación.

Métodos locales: Estos métodos adaptan el valor de un umbral sobre cada píxel a características locales de la imagen.

Umbralización básica: Se compara la intensidad de cada píxel de una imagen con un nivel de gris de referencia (que se establece de acuerdo con cada aplicación particular). A este nivel de referencia, usualmente, se denomina umbral de referencia. Luego se aplica uno o más criterios que permite generar la imagen umbralizada. Uno de los criterios más utilizados es el siguiente: si la intensidad del píxel considerado supera el valor de referencia se le asigna el máximo nivel de gris presente en la imagen; en caso contrario, al píxel considerado se le asigna el mínimo nivel de gris presente en la imagen. Este tipo de umbralización es, frecuentemente, usado como un paso inicial en otros algoritmos de umbralización¹⁸.

Umbralización de banda: Este método es similar a la umbralización básica solo que utiliza dos valores umbrales (uno superior y uno inferior), y asigna al píxel sometido a estudio el nivel de gris máximo, presente en la imagen, si el valor de intensidad del píxel está comprendido entre los umbrales, en caso contrario le asigna el nivel de gris mínimo de la imagen considerada¹⁸.

Umbralización por Percentiles: Este método se utiliza normalmente como un paso preliminar en la umbralización básica. El umbral es calculado como el valor de intensidad (nivel de

gris) obtenido de la sumatoria acumulativa de las intensidades de los píxeles más cercanos al percentil considerado¹⁹.

Umbralización óptima: Este tipo de umbralización selecciona un valor umbral estadísticamente óptimo basado en los contenidos de la imagen. Una aplicación de este tipo de umbralización lo constituye el método de Otsu. Para encontrar el umbral óptimo, este método minimiza la varianza intraclases, definida como una suma pesada de las varianzas de las dos clases representadas por el fondo de una imagen y los objetos presentes en ella. El método de Otsu es muy dependiente de establecer el nivel de umbral óptimo para generar segmentaciones de buena calidad²⁰.

Umbralización adaptativa: Esta umbralización divide la imagen en regiones y cada región es umbralizada a partir de un valor umbral que depende del contenido de cada región (el umbral se adapta). El valor umbral de una región se selecciona como la suma pesada del valor de intensidad promedio de la región y un valor umbral global. Normalmente, este valor global es seleccionado por un método de umbralización óptima¹³.

Como un ejemplo de aplicación de las técnicas de umbralización descritas se puede describir el trabajo de Silva et al.²¹. Estos investigadores presentan un algoritmo semiautomático para segmentar el ventrículo izquierdo en imágenes de MSCT. La investigación se desarrolla mediante dos fases. Por una parte, estiman, para cada instante del ciclo cardiaco, una región de interés adecuada que contenga el Ventrículo izquierdo y por la otra, realizan un sub-muestreo de los niveles de gris de los píxeles, presentes en el epicardio, estableciendo así un adecuado intervalo de intensidad. Aplicando un método de umbralización por banda y apoyándose en los resultados obtenidos de las fases descritas, logran segmentar tanto el epicardio como el endocardio; no obstante, los referidos investigadores no reportaron parámetros que permitan inferir la calidad y eficiencia de su algoritmo, tales como sensibilidad y especificidad.

B. Métodos basados en el crecimiento de regiones

El crecimiento de regiones es una técnica que permite extraer (de una imagen) regiones que son conectadas de acuerdo a un criterio predefinido. Este criterio puede estar basado en los contornos o en la información de la intensidad de la imagen²². En su forma más simple, este método requiere un punto semilla que puede ser seleccionado manual o automáticamente, de forma de extraer todos los píxeles conectados a la semilla.

Con la finalidad de aplicar el crecimiento de regiones, teóricamente, se debe cumplir que: a) La unión de todas las regiones debe generar la imagen completa. b) La intersección de dos regiones cualesquiera debe ser vacía. c) Un píxel es agregado a una región, si y solo si, ese píxel cumple con ciertos criterios predefinidos como²³: 1. Comparar el nivel de gris de la semilla, con el nivel de gris de cada

píxel presente en la imagen. Si la diferencia absoluta de estos niveles es menor o igual a cierto umbral, el píxel objeto de estudio es agregado a la región, en caso contrario no es agregado; 2. Comparar el nivel de gris de la semilla, con el nivel de gris promedio de los píxeles presentes en una vecindad de la semilla. Si la diferencia absoluta de estos niveles es menor o igual a cierto umbral, el píxel objeto de estudio es agregado a la región, en caso contrario no es agregado; 3. Este criterio es similar al anterior. La diferencia, con respecto al segundo criterio, es que el umbral se calcula como el producto de una constante (proporcionada por el usuario) y la varianza de la intensidad de los píxeles, que conforman una vecindad de la semilla²⁴.

Son varios los trabajos de segmentación que han sido desarrollados utilizando entre sus componentes el crecimiento de regiones. Así por ejemplo, Okuyama et al.²⁵, introdujeron un algoritmo semiautomático 3D basado en crecimiento de regiones para obtener el contorno ventricular izquierdo y medir parámetros asociados con dicha estructura, tales como la masa, fracción de eyección y función ventricular. El método fue aplicado a 50 bases de datos de imágenes obtenidas mediante tomografía computarizada multicapa y al comparar los resultados con un estudio de cateterismo cardiaco presentó una sensibilidad del 96%.

Una solución factible para la segmentación del ventrículo izquierdo en imagen es de MSCT y para la estimación de su movimiento fue desarrollada por Bravo et al.². Este método se basa en la aplicación de máquinas de soporte vectorial, el algoritmo de crecimiento de regiones y un algoritmo 2D de correspondencia no rígida, el cual fue utilizado para hacerle seguimiento a los marcadores anatómicos detectados con la máquina de soporte vectorial. Para el proceso de segmentación del referido ventrículo, el error de posición promedio fue de 1.38 mm, el cual es más pequeño que el error de posición promedio de 1.85 mm reportado por Assen et al.²⁶. El algoritmo de estimación del movimiento es validado, inicialmente, usando data sintética correspondiente a superficies del ventrículo izquierdo, adquiridas de una base de imágenes reales bajo la modalidad de SPECT. El error promedio de posición obtenido para el algoritmo de estimación de movimiento sobre 42 imágenes fue de 2.69 mm.

C. Métodos basados en máquinas de aprendizaje

Los algoritmos basados en máquinas de aprendizaje son aquellos que permiten aprender de la experiencia con respecto a alguna clase de tareas y una medida de desempeño²⁷. Generalmente, existen dos tipos de esquemas de aprendizaje en este tipo de métodos: 1) El aprendizaje supervisado, en el cual la salida ha sido dada mediante un proceso de etiquetaje o la máquina de aprendizaje tiene algún conocimiento a priori de la data; y 2) un aprendizaje no supervisado donde la máquina de aprendizaje no recibe ninguna información a priori acerca de la data o de la salida esperada.

Las principales tareas que puede desempeñar una máquina de aprendizaje son la caracterización y agrupación de los datos de entrada (Proceso de Clasificación) y la realización de aproximaciones funcionales de los datos de entrada (Proceso de predicción o regresión)²⁸. En cuanto a la categorización de los métodos basados en máquinas de aprendizaje, Tan et al.²⁹, propusieron la siguiente clasificación: a) sistemas de aprendizaje basados en decisiones, b) sistemas de aprendizaje estadístico y c) sistemas de aprendizaje adaptativo.

a. Sistemas basados en árboles de decisiones: El núcleo más representativo de los sistemas de aprendizaje basado en decisiones, está constituido por los árboles de decisión. Ellos permiten crear un modelo basado en la estructura de un árbol. Los nodos en el árbol representan atributos, con ramas que representan posibles valores de selección de esos atributos. Una hoja representa una clase que finaliza en una serie de nodos y ramas. La determinación de la clase de un ejemplo, para su clasificación se hace obteniendo la ruta de los nodos y las ramas hacia las hojas terminales³⁰. Por otra parte, las redes neurales artificiales representan un paradigma de los sistemas basados en aprendizaje estadístico y pueden ser usadas para la segmentación de imágenes. En imagenología médica, este tipo de redes se ha implementado como un detector de marcadores anatómicos cardiacos, es decir, se ha empleado como un clasificador que funciona en base a una distribución de «pesos», los cuales son determinados durante el proceso de entrenamiento. Luego, se aplica el proceso de validación que consiste en el uso de las referidas redes para clasificar imágenes que no han sido empleadas durante el proceso de entrenamiento. Las redes neurales artificiales también pueden ser usadas de una manera no supervisada desarrollando la función de un método de agrupamiento¹³.

b. Sistemas de aprendizaje estadístico: Como una evolución de este tipo de redes, surgen las máquinas de soporte vectorial (SVM), las cuales constituyen una metodología basada en la teoría de aprendizaje estadístico creada por Vapnik³¹. Esta técnica utiliza para la toma de decisiones el principio de minimización del riesgo estructural³¹. Las SVM son herramientas eficientes de regresión y de clasificación no paramétricas³². En problemas de clasificación las SVM son usadas para construir una función discriminante para separar las clases usando los vectores más cercanos a la superficie de decisión²⁸. Una variante de las SVM, denominada máquinas de soporte vectorial de mínimos cuadrados (LSSVM), puede ser obtenida empleando análisis discriminante de Fischer y reemplazando el sistema de INECUACIONES original, que modela a toda SVM, por un sistema de ECUACIONES equivalente, el cual puede ser resuelto más eficientemente que el sistema original³³. Adicionalmente, a diferencia de otros sistemas de clasificación basados en máquinas de aprendizaje, como las redes neurales artificiales, la LSSVM utiliza la minimización del riesgo estructural, el cual eleva a niveles óptimos la

capacidad de generalización de esas máquinas, haciendo posible que las LSSVM se desempeñen, adecuadamente, en el proceso de validación superando en este aspecto a las referidas redes neurales³⁴.

c. Sistemas de aprendizaje adaptativo: En este caso se presenta el algoritmo de aprendizaje adaptativo y supervisado (AdaBoost) que toma un conjunto de muestras vectorizadas y etiquetadas, una distribución de pesos y un clasificador, denominado débil, para generar, mediante el proceso de entrenamiento, un clasificador fuerte, luego de que el algoritmo itera T veces³⁵. En cada iteración t el AdaBoost entrena un clasificador débil para que clasifique las referidas muestras. De acuerdo a la forma como este tipo de clasificador se desempeñe, el algoritmo redistribuye los pesos asignándole menos peso a las muestras bien clasificadas y un peso mayor a las muestras mal clasificadas. De esta forma, se tiene un criterio para que el siguiente clasificador se enfoque en estas últimas muestras repitiendo, iterativamente, este proceso hasta que se obtenga un alto desempeño del clasificador³⁶. Como un excelente ejemplo de aplicación de estos métodos basados en máquinas de aprendizaje, Zheng et al.⁴, presentan un algoritmo automático, eficiente y robusto para segmentar volúmenes de imágenes cardiacas obtenidos con la modalidad CT. Para ello, se emplean filtros direccionables y una técnica denominada aprendizaje en espacios marginales, que detectan de manera independiente cada una de las cámaras del corazón en un número elevado de bases de datos, formulando la segmentación de las cavidades cardiacas como un problema de aprendizaje, estructurado en dos etapas: localización de las estructuras anatómicas y delineación de los contornos de dichas estructuras.

La técnica de aprendizaje marginal es utilizada para resolver el problema de búsqueda de la transformación de similitud que permitirá establecer la localización de las cuatro cavidades cardiacas. Luego de determinar la pose de las referidas cavidades, estiman la delineación de los contornos que rodean la forma de cada cavidad cardiaca usando para ello algoritmos basados en máquinas de aprendizaje. La robustez del algoritmo desarrollado es evaluada en extensas bases de datos de MSCT. Por otra parte, ellos reportan una velocidad de segmentación, de las cuatro cámaras, de cuatro segundos por volumen cardiaco usando un procesador core-dual 3.2 MHz. Por su parte, Fleureau et al.³⁷, desarrollaron un método de segmentación 3D, semiautomático el cual fue aplicado para extraer las cavidades cardiacas, en secuencias de imágenes de MSCT. El método asoció agentes básicos a los objetos de interés. Cada agente asociado aprendió la región correspondiente a cada imagen usando, para ello, una máquina de soporte vectorial. Las cavidades cardiacas fueron obtenidas maximizando la región asociada con cada agente. El método desarrollado permitió discriminar las mencionadas estructuras cardiacas, sin embargo, el método no fue validado clínicamente.

Adicionalmente, Vera et al.³⁸, realizaron una investigación que permitió obtener un método, para la segmentación del ventrículo izquierdo, utilizando detección de marcadores anatómicos y modelos deformables. El modelo propuesto es aplicado a angiogramas humanos. Algunos marcadores anatómicos, localizados en el ventrículo izquierdo, son detectados por máquinas de soporte vectorial. La etapa de entrenamiento es desarrollada usando ventanas de 31x31 píxeles, las cuales incluyeron patrones que representaban tanto marcadores como no marcadores. La máquina de soporte vectorial usó un núcleo de base radial y el principio de minimización del riesgo estructural como regla de inferencia. Durante la fase de entrenamiento no se registraron falsos positivos y durante la fase de reconocimiento se reportó una tasa de aciertos del 97.94%. La localización estimada de los marcadores anatómicos se usó para construir un contorno aproximado del miocardio. Este contorno aproximado es un modelo deformable que luego es optimizado usando algoritmos genéticos. Luego se realiza una comparación de los contornos obtenidos mediante el método desarrollado y los trazados por dos cardiólogos, reportándose un error máximo de 4.93% sobre un total de 178 imágenes empleadas.

D. Métodos de Agrupamiento

Los métodos de agrupamiento son técnicas de clasificación no supervisadas, es decir, no requieren que se les informe acerca de la respuesta o salida deseada. En este sentido, este tipo de métodos realiza un proceso iterativo que intenta caracterizar cada una de las clases de acuerdo a la similitud existente entre los píxeles que integran cada una de ellas para realizar la segmentación.

Una técnica representativa de este tipo de método es el algoritmo denominado K-medias. Este algoritmo agrupa los datos iterativamente calculando, por ejemplo, el atributo denominado "intensidad promedio para cada clase" y segmentando la imagen mediante la clasificación de los píxeles de acuerdo a su similitud con respecto a este atributo⁹. De esta manera, la mencionada técnica permite particionar una imagen en K grupos. Dicho algoritmo se basa en la aplicación de los siguientes pasos: 1.- Se eligen los centros de los K grupos, bien sea de manera aleatoria o aplicando alguna heurística. 2.-Se asigna cada píxel presente en la imagen al grupo, de manera que la distancia entre el centro del grupo y ese píxel sea mínima. 3.- Se recalculan los centros de los grupos tomando como criterio, por ejemplo, el promedio de la intensidad de los píxeles que pertenecen al grupo. 4.- Se repiten los pasos 2-3 hasta que el algoritmo converja, es decir, hasta que los píxeles no cambien de grupo³⁹.

E. Métodos basados en Leyes Físicas

En este apartado se consideran las técnicas más importantes que ejemplifican adecuadamente, lo que representan los métodos basados en leyes físicas. Ellos son los Modelos de Forma Activa, los Modelos Deformables y los Conjuntos de Nivel.

1. Modelos de Forma Activa (ASM): Los Modelos de Forma Activa (ASM), se caracterizan por ser modelos estadísticos que poseen la habilidad de representar las formas de objetos específicos que están presentes en el conjunto de imágenes de entrenamiento⁴⁰.

En esta técnica, el paso fundamental es la generación de la Forma Media, obtenida luego de aplicar el análisis Procrustes, el cual consiste en efectuar un conjunto de transformaciones geométricas (traslaciones, rotaciones y escalamiento) sobre un grupo de contornos extraídos, manualmente, de las imágenes de entrenamiento⁴⁰. Posteriormente, se aplica un Análisis de Componentes Principales (PCA) que permite obtener a partir de esta forma media, un conglomerado de formas candidatas a evolucionar para segmentar contornos similares⁴⁰. Para ello, estas formas serán deformadas, iterativamente, con el propósito de segmentar las estructuras presentes en imágenes que conforman un conjunto especial denominado conjunto de validación, conformado por imágenes no empleadas durante el entrenamiento. Estas imágenes de validación normalmente deben ser muy similares a las imágenes de entrenamiento. Para que un modelo forma activa evolucione el algoritmo trabaja en función del denominado modelo de puntos distribuidos que, en síntesis, representa la pose original del contorno elegido para ser deformado. Cada uno de los marcadores del referido contorno va cambiando iterativamente de posición hasta que se cumpla uno o más criterios de parada que pueden ser el número de iteraciones o la minimización de una medida de distancia, que puede ser la Euclídea o la de Mahalanobis⁴⁰. Adicionalmente, Zhang et al.⁴¹, propusieron un método basado en la combinación de Modelos de Forma Activa y de Modelos de Apariencia Activa (AAM) para realizar la segmentación tanto del ventrículo izquierdo como del derecho usando bases de datos 4D de MRI tanto sanos como patológicos, alcanzando 90% y 100% de sensibilidad y especificidad respectivamente, lo cual es una muestra de la alta calidad de la segmentación llevada a cabo. Por otra parte, Chen et al.⁴², han propuesto una técnica basada en modelos de apariencia activa y level set, para segmentar la RA en imágenes de MRI. En esta investigación, los parámetros de forma y del análisis de componentes principales se optimizaron utilizando un modelo energético basado en histogramas globales. Sin embargo, ya que los parámetros de forma abarcan un espacio mucho más pequeño, no puede capturar los detalles finos de los objetos presentes en las imágenes consideradas. Por lo tanto, realizaron una segunda etapa de segmentación, basada en level set, para refinar la segmentación generada mediante el modelo de apariencia activa.

2. Modelos Deformables: Los Modelos Deformables son modelos físicos de objetos que se deforman atendien-

do las leyes de la mecánica de Newton, en particular, las leyes que fundamentan la teoría de la elasticidad expresadas mediante la dinámica de Lagrange. Este tipo de modelo es usado, en análisis de imágenes, como una poderosa herramienta para el manejo, reconocimiento, reconstrucción y visualización de curvas no rígidas, superficies y sólidos. Los modelos deformables. Se basan en dos tipos de fuerzas, las propias de la imagen a segmentar, denominadas fuerzas Internas y las fuerzas externas calculadas a partir del contorno a deformar. La función de ambos tipos de fuerza es deformar las curvas o superficies con el propósito de segmentar una región mediante la delineación de sus bordes. Si por ejemplo, se desea delinear el contorno de un objeto en una imagen, se debe colocar el modelo a deformar (generalmente una curva o superficie cerrada) muy cerca del referido contorno y luego el algoritmo itera hasta que se produzca su convergencia siguiendo un criterio basado en la suavidad, curvatura y energía derivadas de la información que las fuerzas aportan acerca del contorno a delinear⁴³.

Una aplicación de este tipo de método la presentan Mongnat et al.¹², combinando los modelos deformables con un conjunto de restricciones, tanto espaciales como temporales, con el propósito de segmentar imágenes cardíacas 4D generadas aplicando la modalidad SPECT ya discutida. A fin de calcular las fuerzas tanto externas como internas que rigen el modelo deformable, ellos consideraron restricciones espaciales, basadas tanto en la forma como en la suavidad y curvatura de los contornos a segmentar; mientras que, para establecer las restricciones temporales, se apoyaron en la posición promedio de las estructuras a segmentar a lo largo de la trayectoria que describen en su movimiento. Ellos también compararon imágenes de 5 pacientes que exhibían una perfusión sanguínea normal en el endocardio, contra las imágenes de un paciente con problemas de perfusión reflejadas en zonas isquémicas presentes en el tejido cardíaco. La precisión del algoritmo desarrollado es estimada sobre una secuencia SPECT de imágenes sintéticas para las cuales se dispone de una segmentación manual del ventrículo izquierdo realizada por un cardiólogo. Por último, cabe destacar que el error promedio obtenido al segmentar el ventrículo izquierdo fue del 4% respecto a la citada segmentación manual.

Por su parte, Ecabert et al.⁴⁴, reportaron un modelo para la segmentación automática del corazón en imágenes 3D adquiridas mediante CT. En primer lugar, la pose del corazón es obtenida estimando su localización en la imagen utilizando una implementación 3D de la transformada generalizada de Hough. Luego, pose es corregida haciendo corresponder el modelo con la imagen mediante el empleo de una transformación de similaridad global. Para la compleja inicializa-

ción de la superficie de multicompartimiento se utiliza una transformación afin para cada región anatómica del modelo; mientras que la adaptación del modelo es realizada incrementando progresivamente los grados de libertad de las deformaciones permitidas. Finalmente, una adaptación deformable es llevada a cabo, con el propósito de hacer más precisa la correspondencia del modelo con los contornos anatómicos del corazón del paciente analizado. Ellos indicaron que el error promedio de correspondencia entre superficies fue de 0.82mm y fue obtenido mediante validación cruzada aplicada sobre un total de 28 imágenes.

Adicionalmente, Oost et al.¹⁸, describieron una técnica para la segmentación automática del ventrículo izquierdo, en imágenes de Angiografía, usando para ello AAM y programación dinámica. Para ello, construyen un modelo basado en un AAM multivista, el cual se basó en el acoplamiento de información relativa a la forma y la textura de las fases finales, tanto diastólica como sistólica, del ciclo cardíaco completo. Para compensar el exceso de restricciones asociadas con el modelo generado inicialmente, ellos utilizaron programación dinámica, incorporando en una función de costo la intensidad de la imagen y algunos atributos del movimiento ejecutado por el ventrículo izquierdo. Mediante la investigación desarrollada hicieron un estudio comparativo entre un algoritmo inicializado manualmente y un algoritmo totalmente automático alcanzando ambos métodos una sensibilidad del 83%. Por su parte, Tan et al.²⁹, propusieron un esquema de segmentación basado en modelos de forma activa para la delineación del ventrículo izquierdo en imágenes obtenidas por la modalidad de SPECT. Este esquema reduce significativamente la labor intensiva que debe realizarse para la cuantificación de la perfusión del miocardio en este tipo de imágenes. El método es semiautomático y se ha aplicado para obtener la referida perfusión con un 94% de aciertos sobre bases de datos de validación.

De la misma manera, un método semiautomático para la segmentación del Ventrículo izquierdo usando modelos de forma activa, fue desarrollado por Assen et al.²⁶. Este método tiene la ventaja de ser independiente de la modalidad de adquisición de las imágenes y fue aplicado sobre secuencias de imágenes cardíacas obtenidas por CT y MRI. Como métrica para valorar la calidad del método fue utilizada la distancia punto a punto, obteniéndose un error promedio de 1.85 mm. También, Lynch et al.⁴⁵, desarrollaron un método de segmentación del ventrículo izquierdo a partir de imágenes obtenidas por resonancia magnética. Este método incorpora conocimiento a priori relacionado con el movimiento ventricular para guiar un modelo deformable paramétrico de la cavidad cardíaca. La deformación del modelo fue inicialmente controlada mediante

una formulación basada en conjuntos de nivel, pasando luego a refinar la evolución de dichos conjuntos mediante el uso del algoritmo de expectación maximización. El método fue validado usando seis bases de datos, obteniéndose un coeficiente de correlación de 0.76 respecto a una segmentación manual usada como referencia.

Moreno et al.⁴⁶, también han abordado el problema de segmentación del corazón, proponiendo un método automático que toma en cuenta la posición del corazón, respecto a los pulmones. Este conocimiento a priori, es representado en un formalismo basado en lógica difusa y se utiliza tanto para definir una región de interés como para manejar la evolución de un modelo deformable. El método desarrollado ha sido aplicado a imágenes cardíacas de CT sin contraste, obteniéndose una sensibilidad de 0.83 y una especificidad bastante regular de 0.68, lo cual indica que el método debe ser afinado.

Zhuang et al.⁴⁷, propusieron un método automático basado en técnicas de registro de tipo local afín y deformaciones libres dotadas de control adaptativo para segmentar el corazón en imágenes de resonancia magnética (MRI) cardíaca. La técnica de registro ofrece la correspondencia de sub-estructuras anatómicas como las cuatro cámaras y los grandes vasos del corazón, mientras que las deformaciones libres afinan los detalles locales utilizando un esquema de optimización. Ellos validaron el método propuesto analizando 37 volúmenes cardíacos correspondientes a la fase diastólica final. Tales volúmenes exhiben una amplia diversidad de morfología y anatomía patológica con un error cuadrático medio de 2.14 ± 0.63 mm y un coeficiente de Dice promedio de 0.84, para la segmentación del ventrículo izquierdo (LV). Una de las características mejorables del enfoque presentado por estos investigadores es el elevado costo computacional por volumen, el cual supera las 2 horas. Este tiempo es típico en los procesos de segmentación basados en técnicas clásicas de registro.

Existe otra técnica, basada en operadores morfológicos y splines, para la segmentación precisa de la arteria pulmonar principal (MPA) y la determinación de parámetros tales como la longitud, área y perímetro circunferencial medio de la MPA. Estos parámetros se pueden utilizar para detectar enfermedades que causan aumento de la presión arterial pulmonar, y permitir mediciones de serie normalizadas para evaluar la progresión o la respuesta a diversos tratamientos. La técnica fue desarrollada utilizando 4 estudios CT de tórax normal y luego probado en 20 estudios normales de CT torácica. Los resultados se compararon con la segmentación manual y medición por un radiólogo torácico. La técnica muestra una alta correlación entre

los parámetros obtenidos automáticamente con los parámetros determinados de forma manual.

Por último, Oberg et al.⁴⁸, proponen una metodología basada en modelos de forma activa para segmentar el ventrículo derecho en imágenes de tomografía computarizada. Ellos utilizan diversas métricas entre las que se destaca el coeficiente de Dice (Dc) y reportan para el Dc valores superiores a 0.9 cuando comparan las segmentaciones manuales con las generadas por el método desarrollado.

3. Conjuntos de Nivel: Los conjuntos de nivel constituyen un método iterativo que permite el control de la evolución de los modelos de contornos activos tipo serpiente para la segmentación de curvas. Esta técnica puede manejar cambios topológicos permitiendo la estimación de las propiedades geométricas de dichas curvas. El contorno resultante es obtenido como el conjunto de nivel cero de una función de alto orden dimensional llamada "funcional de conjunto de nivel". Este funcional evoluciona bajo el control de una ecuación diferencial implícita. Durante el proceso, el contorno en evolución puede extraerse del conjunto de nivel cero a partir de la salida correspondiente. La ventaja de usar los conjuntos de niveles es su utilidad al realizar la segmentación en contornos difíciles de segmentar por exhibir cambios topológicos complejos, ya que estos son modelados adecuadamente por la referida ecuación diferencial⁴⁷. Normalmente, esta técnica se emplea en la segmentación de imágenes basándose en atributos de la misma como, por ejemplo, el nivel de gris promedio o el gradiente de la imagen sometida a estudio. Generalmente, para la aplicación de esta técnica un contorno es inicializado por el usuario. El contorno inicializado evoluciona hasta que converge, asumiendo la forma del contorno o superficie que se desea segmentar¹⁵. Adicionalmente, dado un flujo y una curva inicial, la función de conjuntos de niveles es construida y actualizada de acuerdo a la ecuación de movimiento en todos los píxeles del dominio de la imagen. Por lo general, para recuperar la posición actual de la curva, se usa el algoritmo de Marcha Rápida, buscando los valores de cruce por cero. El mencionado algoritmo es un método numérico que permite, entre otras cosas, estimar de manera eficiente las derivadas de primer y segundo orden del funcional que modela los Conjuntos de Nivel. En este sentido, el referido algoritmo hace posible la disminución de la complejidad computacional requerida para el cálculo de la función de deformación de los Conjuntos de nivel en el dominio de la imagen⁴⁹. Como un ejemplo de implementación de la técnica de Conjuntos de Nivel debe citarse el trabajo desarrollado por Dydenko et al.⁵⁰, quienes presentan una formulación basada en Conjuntos de Nivel usando conocimiento a priori tanto de las formas (presentes en una escena de interés) como del movimiento de

estructuras anatómicas, para registrar y segmentar las estructuras cardíacas presentes, en una secuencia de imágenes de ecocardiografía. Para el registro de las formas incorporadas, se plantea a priori un problema de transformación afín en el cual se aplica la minimización de la referida transformación mediante un criterio basado en la localización de puntos críticos globales. Luego, la segmentación se desarrolla a través del frente de propagación del Conjunto de Nivel, restringido mediante la forma registrada a priori. Las segmentaciones automáticas obtenidas mediante la formulación descrita son muy similares a los obtenidos, por un cardiólogo, quien desarrolló una segmentación manual de las estructuras cardíacas presentes en las imágenes ecocardiografías consideradas.

4. Métodos guiados por Atlas: Este tipo de métodos constituyen una poderosa herramienta para la segmentación de imágenes médicas cuando está disponible una plantilla, un estándar o Atlas, de la estructura que se desea segmentar. Este Atlas es generado mediante información recabada acerca de la anatomía de la dicha estructura. La referida plantilla es usada como un marco referencial para segmentar volúmenes de imágenes que no se hayan utilizado para generarla. Conceptualmente, los métodos basados en plantillas son implementados en el dominio que en el espacio de características de la misma. El uso de transformaciones tanto lineales como no lineales, permite colocar en correspondencia el Atlas con la imagen que se requiere segmentar¹⁸.

En este sentido, Kirisli et al.⁵¹, presentaron un algoritmo guiado por multi-atlas para segmentar, automáticamente las cuatro cavidades cardíacas en imágenes de angiografía computarizada. El error promedio obtenido para el proceso global de segmentación, fue aproximadamente de 1 mm, lo cual indica claramente que el mencionado algoritmo exhibió una alta precisión, la cual fue valorada con las bases de datos provenientes de 8 pacientes. Adicionalmente, se evaluó la robustez del método desarrollado aplicándolo exitosamente, a 243 bases de datos distintas de las usadas para generar el atlas o plantilla de referencia.

AGRADECIMIENTOS

Los autores agradecen por el apoyo financiero al Consejo de Desarrollo Científico Humanístico Tecnológico y de las Artes (CDCHTA) de la Universidad de Los Andes-Venezuela, (a través del proyecto código NUTA-C-29-15-07-C), a la Universidad Simón Bolívar y al Decanato de Investigación de la Universidad Nacional Experimental del Táchira, San Cristóbal-Venezuela.

Conclusiones

A

pesar de la cantidad y calidad de las metodologías desarrolladas para abordar el problema de la segmentación de las estructuras cardíacas más relevantes, tales como los ventrículos, las aurículas y los grandes vasos, aún no se ha podido generar una técnica que por sus atributos permita su incorporación definitiva en el desarrollo de actividades rutinarias en el ámbito clínico, tales como el apoyo a la planeación de cirugías, el diagnóstico y el monitoreo clínico de enfermedades.

Lo anterior puede ser debido a que las metodologías de segmentación reportadas en la literatura especializada, todavía poseen serias limitaciones, tales como la falta de eficiencia, robustez y/o reproducibilidad y todavía no han sido sometidas a los respectivos procesos de validación médica apuntalada por un riguroso protocolo clínico.

De acuerdo a este panorama, el tema de la segmentación cardíaca se sigue manteniendo como un problema de carácter abierto, lo cual, indudablemente constituye un gran reto que puede servir de elemento motivante para que los investigadores del área cardiovascular se propongan elevar la calidad de sus modelos, a fin de generar metodologías que puedan ser incorporadas, en un futuro inmediato, a algunos equipos de adquisición de imágenes cardíacas en las diversas modalidades de imagenología médica.

References

1. World Health Organization. The world health report 2002: reducing risks, promoting healthy life. Switzerland: WHO Library; 2002
2. Bravo A, Mantilla J, Clemente J, Vera M, Medina R. Left ventricle segmentation and motion analysis in multi-slice computerized tomography. In: Gonzalez FA, Romero E, Editores. Biomedical Image Analysis and Machine Learning Technologies: Applications and Techniques. 1 edition. Hershey: Medical Information Science Reference; 2010:307–22.
3. Shapiro LG, Stockman GC. Computer Vision. 1 edition. Upper Saddle River, NJ: Pearson; 2001.
4. Zheng Y, Barbu A, Georgescu B, Scheuering M, Comaniciu D. Four-Chamber Heart Modeling and Automatic Segmentation for 3-D Cardiac CT Volumes Using Marginal Space Learning and Steerable Features. IEEE Transactions on Medical Imaging. 2008;27(11):1668–81.
5. Maiera A, Wigstrm L, Hofmann H, Hornegger J, Zhu L, Strobel N, Fahrig R. Three-dimensional anisotropic adaptive filtering of projection data for noise reduction in cone beam CT. Medical Physics. 2011;38(11):5896–909.
6. Hsieh J. Image artifacts: appearances, causes, and corrections. In: Computed tomography: principles, design, artifacts, and recent advances. Bellingham: SPIE Press; 2003:167–240.
7. Kroft L, de Roos A, Geleijns J. Artifacts in ECG-synchronized MDCT coronary angiography. American Journal of Roentgenology. 2007;189(3):581–91.
8. De Man B, Nuyts J, Dupont P, Marchal G, Suetens P. Reduction of metal streak artifacts in X-ray computed tomography using a transmission maximum a posteriori algorithm. IEEE Transactions on Nuclear Science. 2000;47(3): 977–81.
9. Kalender W, Hebel R, Ebersberger J. Reduction of CT artifacts caused by metallic implants. Radiology. 1987;164(2):576–77.
10. Lemmens C, Faul D, Nuyts J. Suppression of metal artifacts in CT using a reconstruction procedure that combines MAP and projection completion. IEEE Transactions on Medical Imaging. 2009;28(2): 250–60.

11. Vera M. Segmentación de estructuras cardiacas en imágenes de tomografía computarizada multi-corte [Tesis doctoral]. Mérida-Venezuela: Universidad de los Andes, 2014.
12. Mongnat J, Delingette H. 4d deformable models with temporal constraints: application to 4d cardiac image segmentation. *Medical Image Analysis*. 2005;9: 87-100.
13. Pham D, Xu C, Prince J. Current methods in medical image segmentation. *Annual Review of Biomedical Engineering*. 2000;2:315-37.
14. Sun W, Cetin M, Chan R, Willsky A. Learning the dynamics and time-recursive boundary detection of deformable objects. *IEEE Transactions on Image Processing*. 2008;17(11):2186-200.
15. Paragios N, Chen Y, Faugeras O. *Handbook of Mathematical Models in Computer Vision*. Boston:Springer US;2006.
16. Yamamoto S, Hamada S, Miyamoto M, Masumoto J, Komizu M, Moriyama N. A new approach towards volumetric assessment of left ventricular function with msct. *Biomedical Imaging and Intervention Journal*. 2006;2(3):50-56.
17. Sezgin M, Sankur B. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*. 2004;13:146-65.
18. Oost E, Koning G, Sonka M, Reiber JH, Lelieveldt BP. Automated contour detection in x-ray left ventricular angiograms using multiview active appearance models and dynamic programming. *IEEE transactions on medical imaging*. 2006;25(9):1158-71.
19. Doyle W. Operation useful for similarity invariant pattern recognition. *Journal of the Association for Computing Machinery*. 1962;9:259-67.
20. Otsu N. A threshold selection method from gray level histograms. *Automatica*. 1975;11(285-296):23-27.
21. Silva S, Sousa B, Madeira J, Silva A. Left Ventricle Segmentation from Heart MDCT. *Pattern Recognition and Image Analysis*. 2009; 5524:306-13.
22. Passarielo G, Mora F. *Imágenes Médicas, Adquisición, Análisis, Procesamiento e Interpretación*. Venezuela:Equinoccio Universidad Simón Bolívar;1995.
23. Pratt W. *Digital image processing*. Hoboken, NJ: John Wiley & Sons; 2007.
24. Petrou M, Bosdogianni P. *Image processing*. Chichester:Wiley;1999.
25. Okuyama T, Ehara S, Shirai N, Sugioka K, Ogawa K, Oe H, et al. Usefulness of three-dimensional automated quantification of left ventricular mass, volume, and function by 64-slice computed tomography. *Journal of Cardiology*. 2008; 52(3):276-284.
26. Assen H, Danilouchkine M, Dirksen M, Reiber J, Lelieveldt B. A 3-D active shape model driven by fuzzy inference: application to cardiac CT and MR. *IEEE Transactions on information technology in biomedicine*. 2008;12(5):595-605.
27. Mitchell T. *Machine Learning*. New York: McGraw-Hill; 1997.
28. Schölkopf B, Smola A. *Learning with kernels*. Cambridge:MIT Press;2002.
29. Tan A, Gilbert D. *Conferences in research and practice in information technology*. IEEE Medical Imaging. 2003;19:219-22.
30. Kohavi R, Quinlan J. *Data mining tasks and methods: Classification: decision-tree discovery*. NY:Oxford University Press, Inc.;2002.
31. Vapnik V. *The Nature of Statistical Learning Theory*. New York:Springer Verlag;1995.
32. Osuna E, Freund R, Girosit F. Training support vector machines: an application to face detection. In: *Computer vision and pattern recognition, 1997 Proceedings*. IEEE computer society conference;1997:130-136.
33. Suykens J, Gestel T, Brabanter J. *Least Squares Support Vector Machines*. UK:World Scientific Publishing Co;2002.
34. Oren M, Papageorgiou C, Sinha P, Osuna E, Poggio T. Pedestrian detection using wavelet templates. In: *IEEE Comput. Soc;1997:193-200*.
35. Schapire R, Singer Y. Improved Boosting Algorithms Using Confidence-rated Predictions. *Machine Learning*. 1999;37(3):297-336.
36. Freund Y, Schapire RE. A decision-theoretic generalization of on-line learning and an application to boosting. En: Vitányi P, Editor. *Computational Learning Theory*. UK:Springer; 1995:23-37.
37. Fleureau J, Garreau M, Hernández AI, Simon A, Boulmier D. Multi-object and ND segmentation of cardiac MSCT data using SVM classifiers and a connectivity algorithm. *IEEE Transactions on Computers in Cardiology*. 2006;33:817-20.
38. Vera M, Bravo A, Medina R. Myocardial border detection from ventriculograms using support vector machines and real-coded genetic algorithms. *Comput Biol Med*. abril de 2010;40(4):446-455.
39. Kanungo T, Mount DM, Netanyahu NS, Piatko CD, Silverman R, Wu AY. An efficient k-means clustering algorithm: Analysis and implementation. *IEEE Trans Pattern Anal Mach Intell*. 2002;24(7):881-92.
40. Cootes T, Taylor C, Cooper D, Graham J. Active shape models- their training and application. *Comput. Vis. Image Underst*. 1995;61(1):38-59.
41. Zhang H, Wahle A, Johnson RK, Scholz TD, Sonka M. 4-D Cardiac MR Image Analysis: Left and Right Ventricular Morphology and Function. *IEEE Trans Med Imaging*. 2010;29(2):350-64.
42. Chen S, Kohlberger T, Kirchberg KJ. Advanced level set segmentation of the right atrium in MR. In: Wong KH, Holmes DR, editores. *Proceedings of the SPIE The International Society for Optical Engineering, Volume 7964*. Lake Buena Vista: 2011: 89-92.
43. Radeva P, Serrat J, Marti E. A snake for model-based segmentation. In: *Computer Vision, 1995 Proceedings, Fifth International Conference*. IEEE; 1995:816-21.
44. Ecabert O, Peters J, Schramm H, Lorenz C, von Berg J, Walker MJ, et al. Automatic Model-Based Segmentation of the Heart in CT Images. *IEEE Trans Med Imaging*. 2008;27(9):1189-201.
45. Lynch M, Ghita O, Whelan PF. Segmentation of the Left Ventricle of the Heart in 3-D+t MRI Data Using an Optimized Nonrigid Temporal Model. *IEEE Trans Med Imaging*. 2008;27(2):195-203.
46. Moreno A, Takemura CM, Colliot O, Camara O, Bloch I. Using anatomical knowledge expressed as fuzzy constraints to segment the heart in CT images. *Pattern Recognit*. 2008;41(8):2525-40.
47. Zhuang X, Rhode KS, Razavi RS, Hawkes DJ, Ourselin S. A Registration-Based Propagation Framework for Automatic Whole Heart Segmentation of Cardiac MRI. *IEEE Trans Med Imaging*. 2010;29(9):1612-25.
48. Oberg J. *Segmentation of the right ventricle in cardiac CT images [Master's thesis]*. Lund, Suecia: Lund University.
49. Osher S. *Level set methods*. In *Geometric level set methods in imaging, vision, and graphics*. New York: Springer New York; 2003: 3-20.
50. Dydenko I, Jamal F, Bernard O, D'hooge J, Magnin IE, Friboulet D. A level set framework with a shape and motion prior for segmentation and region tracking in echocardiography. *Medical Image Analysis*. 2006;10(2):162-77.
51. Kirisli HA, Schaap M, Klein S, Neeffjes LA, Weustink AC, Van Walsum T, et al. Fully automatic cardiac segmentation from 3D CTA data: a multi-atlas based approach. En: Dawant BM, Haynor DR, editores. *Proceedings of SPIE Medical Imaging*;2010:304-762.

Manuel Velasco (Venezuela) **Editor en Jefe** - Felipe Alberto Espino Comercialización y Producción

Reg Registrada en los siguientes índices y bases de datos:

SCOPUS, EMBASE, Compendex, GEOBASE, EMBiology, Elsevier BIOBASE, FLUIDEX, World Textiles,

OPEN JOURNAL SYSTEMS (OJS), REDALYC (Red de Revistas Científicas de América Latina, el Caribe, España y Portugal),

LATINDEX (Sistema Regional de Información en Línea para Revistas Científicas de América Latina, el Caribe, España y Portugal)

LIVECS (Literatura Venezolana para la Ciencias de la Salud), LILACS (Literatura Latinoamericana y del Caribe en Ciencias de la Salud)

PERIÓDICA (Índices de Revistas Latinoamericanas en Ciencias), REVENCYT (Índice y Biblioteca Electrónica de Revistas Venezolanas de Ciencias y Tecnología)

SCIELO (Scientific Electronic Library Online), SABER UCV, DRJI (Directory of Research Journal Indexing)

CLaLIA (Conocimiento Latinoamericano y Caribeño de Libre Acceso), EBSCO Publishing, PROQUEST.



Esta Revista se publica bajo el auspicio del
Consejo de Desarrollo Científico y Humanístico
Universidad Central de Venezuela.

