

Segmentación automática de la arteria aorta ascendente y la válvula aórtica en imágenes de tomografía computarizada cardiaca

Automatic segmentation of the ascending aorta and aortic valve in computed tomography images

Miguel Vera, MgSc. PhD^{1,2*}, Yoleidy Huérfano, MgSc¹, Julio Contreras-Velásquez, MgSc², Atilio Del Mar, MD³, Johel Rodríguez, MgSc², Nahid Bautista, MgSc², Sandra Wilches-Durán, MgSc², Modesto Graterol-Rivas, MgSc, PhD², Daniela Riaño-Wilches, BSc⁴, Joselyn Rojas, MD, MSc⁵, Valmore Bermúdez, MD, MSc, MPH, PhD^{2,6}

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

²Grupo de Investigación Altos Estudios de Frontera (ALEF), Universidad Simón Bolívar, Cúcuta, Colombia. E-mail de correspondencia: veramig@gmail.com*.

³Instituto de Bioingeniería y Diagnóstico Sociedad Anónima (IBDSA), San Cristóbal, Venezuela.

⁴Facultad de Medicina, Universidad de los Andes, Bogotá, Colombia.

⁵Pulmonary and Critical Care Medicine Department. Brigham and Women's Hospital. Harvard Medical School. Boston, MA. USA 02115.

⁶Centro de Investigaciones Endocrino-Metabólicas "Dr. Félix Gómez" Facultad de Medicina. Universidad del Zulia, Venezuela.

M

ediante el presente trabajo se propone una técnica para la segmentación automática del conjunto anatómico constituido por la arteria aorta ascendente + la válvula aórtica (AAAV) en 10 imágenes cardiacas tridimensionales (3-D) de tomografía computarizada multi-corte, pertenecientes a un mismo sujeto. La mencionada técnica consta de las etapas de pre-procesamiento y segmentación. La etapa de pre-procesamiento incluye dos fases: la primera, minimiza tanto el ruido Poisson como el impacto del artefacto escalera, se emplea una técnica denominada realce por similitud global, este tipo de realce consiste en la aplicación de un banco de filtros, suavizadores y un detector de bordes, cuyo propósito es generar una imagen en la cual se agrupa la información de las estructuras anatómicas, que conforman las imágenes originales; la segunda fase, considerando las imágenes filtradas, se utiliza información a priori acerca de la localización de la válvula aórtica y un paradigma de aprendizaje, basado en máquinas de soporte vectorial, para definir una región de interés

que aísla la AAAV de estructuras anatómicas vecinas. Por otra parte, para generar la morfología 3-D de la TAA, se aplica una etapa de segmentación la cual considera las imágenes filtradas y un algoritmo de agrupamiento basado en crecimiento de regiones. La estrategia propuesta genera las segmentaciones 3-D de la AAAV en todas las imágenes que conforman el ciclo cardiaco completo del sujeto considerado. Para cuantificar el desempeño de la referida técnica se consideró el coeficiente de Dice obteniéndose una buena correlación entre las segmentaciones automáticas y las manuales generadas por un cardiólogo. Las segmentaciones generadas automáticamente pueden ser útiles en la detección de ciertas patologías que afectan tanto la arteria aorta como estructuras anatómicas, asociadas con ella, tales como la válvula aorta y el ventrículo izquierdo.

Palabras clave: Arteria aorta, Válvula aórtica, Tomografía computarizada, Realce por similitud global, Máquinas de soporte vectorial, Segmentación

The present work proposes a technique for the automatic segmentation of the anatomic set consisting of the ascending aorta + aortic valve (AAAV) in 10 three-dimensional (3-D) cardiac images of multi-cut computed tomography, belonging to the same subject. The mentioned technique consists of the stages of pre-processing and segmentation. The pre-processing stage includes two phases: the first, minimizes both Poisson noise and the impact of the staircase artifact, we use a technique called global similarity enhancement, this type of enhancement consists of the application of a bank of filters, softeners And a border detector, whose purpose is to generate an image in which the information of the anatomical structures, which make up the original images, is grouped together; the second phase, considering the filtered images, uses a priori information about the location of the aortic valve and a learning paradigm, based on vector support machines, to define a region of interest that isolates AAAV from neighboring anatomical structures. On the other hand, to generate the 3-D morphology of the TAA, a segmentation stage is applied which considers the filtered images and a clustering algorithm based on regions growth. The proposed strategy generates the 3-D segmentations of AAAV in all the images that make up the complete cardiac cycle of the subject considered. In order to quantify the performance of the referred technique, the Dice coefficient was considered, obtaining a good correlation between the automatic segmentations and the manual ones generated by a cardiologist. Automatically generated segmentations may be helpful in detecting certain pathologies that affect both the aorta and anatomical structures associated with it, such as the aorta and left ventricle.

Keywords: Aortic Artery, Aortic Valve, Computed Tomography, Global Similarity Enhancement, Vector Support Machines, Segmentation

El corazón se divide en dos mitades laterales, análogamente constituidas: corazón derecho, en el cual circula la sangre venosa, y corazón izquierdo, vinculado con la sangre arterial¹. Cada uno de estos corazones se subdivide a su vez en dos mitades, situadas una encima de otra: la cavidad superior llamada aurícula y la cavidad inferior denominada ventrículo. Cada aurícula está conectada con el ventrículo correspondiente, a través de una válvula².

La parte superior del corazón está conectada al resto del aparato circulatorio a través de vasos sanguíneos que conducen sangre hacia el corazón y conducen sangre del corazón al cuerpo. La aorta es la arteria principal que conduce la sangre oxigenada desde el ventrículo izquierdo a otras partes del cuerpo; mientras que la arteria pulmonar conduce la sangre para su oxigenación desde el ventrículo derecho a los pulmones.

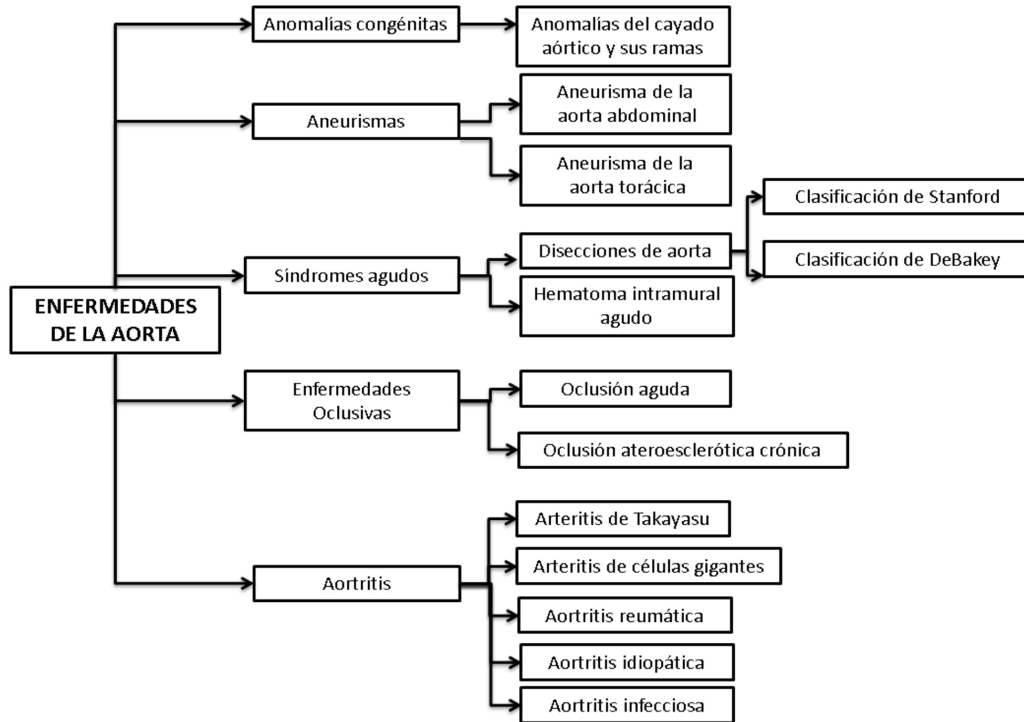
Muchos de los problemas derivados de las enfermedades del corazón, se deben a las deficiencias en las válvulas cardíacas, en particular las enfermedades de la válvula aórtica^{3, 4, 5}, las cuales se muestran en la Figura 1.

La principal razón por la cual se recurre a la segmentación de las válvulas cardíacas, y de los grandes vasos sanguíneos asociados a ellas, es porque posibilita el diagnóstico de diversas enfermedades cardíacas, sin necesidad de aplicar un método invasivo extremo, como lo sería intervenir quirúrgicamente a un paciente para determinar la condición de dichas válvulas.

La segmentación de estructuras cardíacas es uno de los procesos que mayor auge ha cobrado en la actualidad debido, entre otras razones, a la presencia de una sociedad altamente tecnificada. Así mismo, a escala mundial, el uso de técnicas de segmentación cada vez más complejas ha permitido la generación automática de cada una de las estructuras anatómicas que conforman ese vital órgano del cuerpo humano denominado corazón.

Adicionalmente, el hecho que las enfermedades del corazón constituyan la principal causa de muerte en el mundo⁶, aunado a los enormes costos que representan la inversión en salud de las personas aquejadas, por una o más enfermedades cardiovasculares, constituyen un potente aliciente para estimular el desarrollo de investigaciones que generen apoyos clínicos para el abordaje de: a) El diagnóstico temprano de las mencionadas enfermedades y b) La planificación de procedimientos de rutinas clínicas tendientes a elevar la calidad de vida de los pacientes cardíacos.

Figura 1: Síntesis de las enfermedades que experimenta la arteria aorta



Además la realización de tales segmentaciones se hace aún más difícil debido a que las imágenes provenientes de un estudio clínico, generadas mediante cualquier modalidad, poseen imperfecciones tales como ruido, artefactos y bajo contraste, que afectan la calidad de la información presente en las imágenes tridimensionales, particularmente, en imágenes de tomografía computarizada multi-capa (MSCT) cardíaca⁷.

Una síntesis de las investigaciones orientadas hacia la segmentación de la arteria aorta y la válvula aórtica se presentan a continuación.

Zheng et al.⁸, proponen la segmentación automática de la aorta con el propósito de detectar marcadores anatómicos necesarios para el reemplazo de la válvula aórtica. En este sentido, ocho puntos de referencia ubicados en la válvula aórtica fueron detectados, automáticamente, mediante un enfoque de segmentación basado en aprendizaje discriminativo. Bajo la guía de los puntos de referencia detectados los médicos pueden desplegar la prótesis valvular correctamente. Ellos reportan que su propuesta es robusta bajo las variaciones del agente de contraste y es computacionalmente eficiente ya que emplea alrededor de 1.4 segundos para procesar una imagen tridimensional completa.

Sasa et al.⁹, consideran imágenes de MSCT para presentar un modelo completo y modular de las válvulas del corazón que comprenden la anatomía de las válvulas aórtica, mitral, tricúspide y pulmonar, así como sus variaciones morfológicas, funcionales y patológicas. Introducen un modelo multi-lineal de forma restringido, condicionado

por medidas anatómicas, para representar la compleja variación espacio-temporal de las válvulas del corazón. La localización global de las válvulas y el movimiento se computan dentro del espacio de aprendizaje marginal y aprendizajes de trayectoria espectral. Para estimar la precisión del modelo completo de las válvulas, se mide la distancia euclídea de las segmentaciones generadas automáticamente con las generadas manualmente y reportan, para la mencionada distancia, un valor promedio global de 1.24 ± 0.91 mm.

Elattar et al.¹⁰ segmentan, automáticamente, la raíz aórtica en 20 imágenes de angiografía por tomografía computarizada (CTA) de pacientes candidatos para implantación de válvula aórtica transcáteter (TAVI). En este sentido, para extraer la raíz aórtica de los volúmenes CTA, implementan un algoritmo de segmentación totalmente automatizado que, en primer lugar, detecta el volumen de interés y determina la línea central a través de la aorta ascendente y la línea central de la raíz aórtica; posteriormente, se enmascaran las altas intensidades debidas a calcificaciones. El método fue validado mediante el cálculo del coeficiente de Dice (Dc). El método segmentó, exitosamente, la raíz aórtica en los 20 casos. El algoritmo propuesto mostró resultados precisos en comparación con las segmentaciones manuales ya que el Dc fue de 0.95 ± 0.03 .

Pouch et al.¹¹, proponen realizar una segmentación y modelado geométrico de la válvula aórtica en 11 imágenes ecocardiográficas 3D. Este trabajo integra modelos de modelado intermedio y técnicas de fusión multi-atlas para delinear y describir cuantitativamente la geometría de la

válvula aórtica en las mencionadas imágenes. La relevancia clínica del método es su capacidad para capturar la geometría de la válvula aórtica con mínima interacción del usuario. Los resultados obtenidos, basados en indicadores estadísticos, demuestran consistencia entre las mediciones derivadas de las segmentaciones automatizadas y manuales.

Descripción de las bases de datos

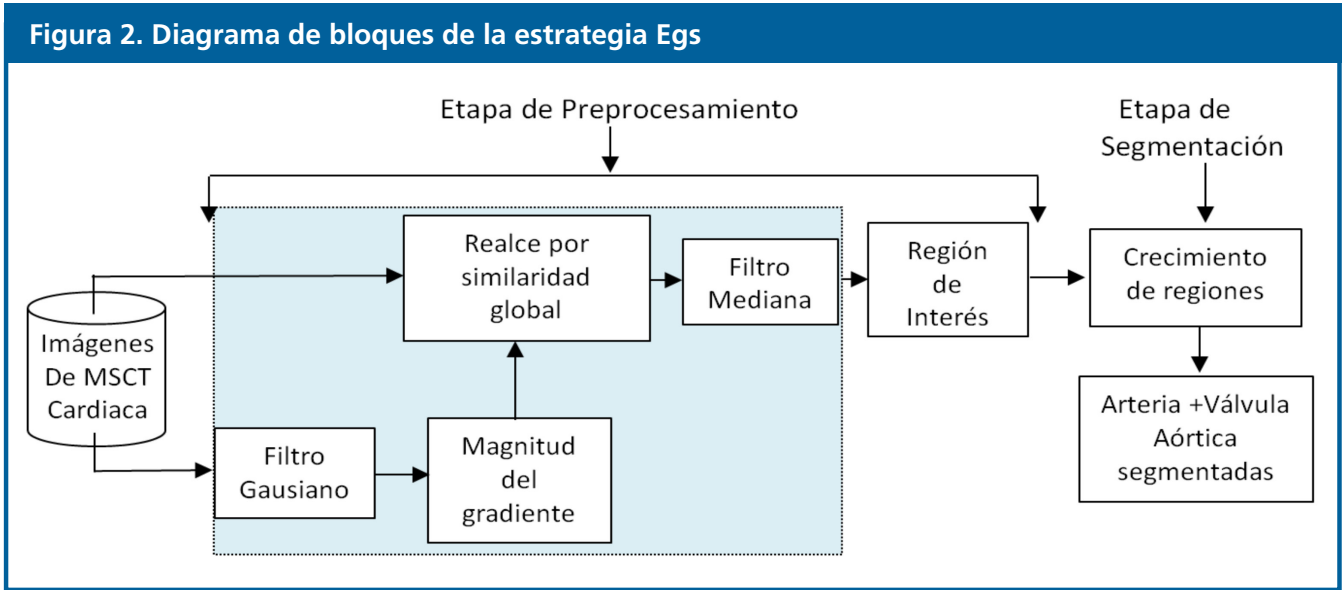
La base de datos (DB) utilizada fue suministrada por el Instituto de Bioingeniería y Diagnóstico Sociedad Anónima (IBIDSA), San Cristóbal, Venezuela, y está constituida por imágenes de MSCT cardiaca de un paciente. La DB posee 10 instantes que representan un ciclo cardiaco completo. Cada instante tiene 324 imágenes de resolución espacial 512x512 píxeles, muestreadas a 12 bits por píxel, con vóxeles de tamaño 0.4297 mm x 0.4297 mm x 0.4000 mm.

También se cuenta con las segmentaciones manuales del ciclo cardiaco completo, generadas por un cardiólogo, las cuales representan los ground truth del conjunto conformado por la arteria aorta ascendente + válvula aórtica (AAAV) que servirán como referencia para validar los resultados.

Descripción de la estrategia propuesta para la segmentación de la aurícula izquierda

La Figura 2 muestra la estrategia propuesta para generar la morfología de la arteria aórtica + la válvula aórtica. Debido a que tal estrategia está basada en un tipo de realce por similitud global, en el presente artículo, será utilizando el acrónimo Egs para hacer referencia a ella.

Es importante señalar que, en el contexto de Egs, las técnicas que conforman las etapas de filtrado y segmentación se implementaron considerando las siguientes herramientas de software: Lenguaje C++¹², Matlab¹³, Insight toolkit (ITK)¹⁴, y Visualization toolkit (VTK)¹⁵.



Etapas de preprocesamiento

En el presente trabajo, la etapa de preprocesamiento consta de las fases de filtrado y de definición de una región de interés. Tales fases se describen a continuación:

Fase de filtrado

A continuación se describen, brevemente, las consideraciones de orden práctico que se establecen en la figura 2 para la aplicación de la fase de filtrado, compuesta por los filtros Gaussiano, magnitud del gradiente, realce por similitud global (GSE) y mediana.

- a) Obtener una imagen gaussiana (I_g): Para generar I_g, la imagen original (I_o) es suavizada mediante la aplicación de un filtro gaussiano cuya función es abordar el problema del ruido. El filtro gaussiano está caracterizado como una técnica espacial lineal que se ha utilizado

clásicamente para minimizar el ruido presente en imágenes. Existe una relación entre la cantidad de ruido que se atenúa mediante la aplicación de este filtro y el desenfoco de la imagen⁷. Este tipo de filtro emplea una distribución gaussiana discreta la cual puede expresarse mediante una máscara o kernel gaussiano, de tamaño arbitrario. Si se pretende suavizar, por ejemplo, una imagen 3-D los escalares que conforman el referido kernel pueden obtenerse de acuerdo con la Ecuación 1.

$$G(i, j, k) = \frac{1}{(\sqrt{2\pi})^3 \sigma_i \sigma_j \sigma_k} e^{-\left(\frac{i^2}{2\sigma_i^2} + \frac{j^2}{2\sigma_j^2} + \frac{k^2}{2\sigma_k^2}\right)} \quad (1)$$

Siendo: $0 \leq i, j, k \leq (n - 1)$, n el tamaño del kernel gaussiano, σ_i , σ_j y σ_k las desviaciones estándar para cada dimensión espacial.

En la práctica, en el presente trabajo, el filtrado gaussiano se implementa mediante la convolución de la imagen original con el referido kernel gaussiano⁷. Los parámetros de este filtro son: la desviación estándar de cada una de las dimensiones espaciales y el radio (r) que define el tamaño (n) de la máscara, dado por la Ecuación 2.

$$n = 2r + 1, \quad (2)$$

Siendo r un escalar arbitrario

b) Generar una imagen gradiente (I_{GM}): A cada imagen I_g se le aplica un filtro basado en el cálculo de la magnitud del gradiente¹⁶. El papel de este filtro es detectar los bordes de las estructuras presentes en las imágenes. La magnitud del gradiente se utiliza ampliamente en el análisis de imágenes, principalmente, para identificar los contornos de objetos y la separación de regiones homogéneas. La detección de bordes es la detección de discontinuidades significativas en el nivel de gris o color de una imagen¹⁶. Esta técnica calcula la magnitud del gradiente usando las primeras derivadas parciales direccionales de una imagen. El modelo matemático 3-D clásico, para obtener una imagen filtrada por magnitud del gradiente se presenta mediante la Ecuación 3.

$$I_{GM} = \sqrt{\left(\frac{\partial I}{\partial i}\right)^2 + \left(\frac{\partial I}{\partial j}\right)^2 + \left(\frac{\partial I}{\partial k}\right)^2}$$

donde: i, j, k representa las direcciones espaciales en las que se calcula el gradiente.

En la práctica, la magnitud del gradiente de la imagen en cada posición del vóxel, objeto de estudio, se calcula utilizando un enfoque basado en diferencias finitas. Teóricamente, el filtro de magnitud del gradiente basado en los valores de intensidad es muy susceptible al ruido¹⁶, por ello, se recomienda filtrar la imagen inicialmente para mejorar el rendimiento del detector con respecto al ruido.

- c) Aplicar una función de similaridad global: Los volúmenes de entrada de esta función son las imágenes I_o e I_{GM} . La finalidad de la similaridad global es abordar el problema de los artefactos. Para ello, se considera la información proveniente de los niveles de gris de vóxeles vecinos, del vóxel actual, en los volúmenes de entrada. La mencionada función produce una imagen de similaridad global (I_{GS}) la cual se calcula mediante el valor absoluto de la resta aritmética de los vóxeles correspondientes a I_{GM} e I_o ^{7, 17}. El tamaño óptimo de la vecindad 3-D para cada uno de los filtros fue obtenido de manera heurística como se explica en la sección denominada etapa de entonación de parámetros.
- d) Generar una imagen mediana (I_m): La presencia de un filtro de mediana (que se comporta como un filtro suavizador) al final de la fase de filtrado se justifica por

el hecho de que las imágenes de tomografía, consideradas en la presente investigación, son portadoras de ruido Poisson. Además, la incorporación de un filtro que refuerza bordes (magnitud del gradiente), puede realzar componentes de alta frecuencia vinculadas con ruido lo cual exige la consideración de un filtro suavizador. Para entonar el filtro de mediana se hace coincidir, sistemáticamente, el parámetro denominado tamaño de vecindad con todos y cada uno de los casos establecidos para tal filtro, es decir, su parámetro se hace variar considerando los tamaños: $(3 \times 3 \times 3)$, $(5 \times 5 \times 5)$ y $(7 \times 7 \times 7)$.

Fase de definición de una región de interés (ROI)

La similitud de los niveles de gris de los vóxeles que conforman las estructuras del corazón izquierdo tales como ventrículo izquierdo (LV), aurícula izquierda (LA), válvula aórtica (AV) y arteria aórtica (AA); exige la colocación de superficies que faciliten la segmentación de la válvula aórtica. Tales superficies reciben el nombre de planos. Particularmente, el plano que fue considerado para aislar la AAV se denomina plano aórtico. En el contexto de la estrategia Egs, considerando las imágenes filtradas, la fase de definición de una ROI se basa en los siguientes aspectos:

- i) Se aplica una técnica de reducción de tamaño, basada en transformada wavelet¹⁸, cuyo parámetro se hace coincidir con el factor de reducción óptimo, obtenido en Vera⁷. Esto permite generar imágenes sub-muestreadas de 64×64 píxeles a partir de imágenes filtradas de 512×512 , es decir, el mencionado factor fue de 8.
- ii) Sobre las imágenes sub-muestreadas un cardiólogo selecciona puntos de referencia dados por: la unión de la válvula aórtica con el LV (P1) y un punto adicional dado por el ápex del LV (P2). Para ambos puntos se identifican las coordenadas manuales que establecen sin ambigüedad su ubicación espacial en cada imagen considerada.
- iii) Se implementa una máquina de soporte vectorial de mínimos cuadrados (LSSVM) para reconocer y detectar a P1 y P2. Para ello se desarrollan los procesos de:
 - a) Entrenamiento. Se selecciona como conjunto de entrenamiento vecindades circulares de radio 10 píxeles, trazadas manualmente por un cardiólogo, que contienen tanto los puntos P1 y P2 (marcadores), como regiones que no contienen los referidos puntos (no marcadores). Para los marcadores el centro de sus respectivas vecindades coincide con las coordenadas manuales de P1 y P2, establecidas anteriormente. Tales vecindades son construidas sobre la vista axial de una imagen sub-muestreada de 64×64 píxeles para P1 y otra para P2. La principal razón por la cual se elige una única imagen, por cada punto de referencia, es porque se desea generar una LSSVM con alto grado de selectividad, que detecte sólo aquellos píxeles que

posean un alto grado de correlación con el patrón de entrenamiento.

Luego, cada vecindad es vectorizada, y considerando sus niveles de gris, se calculan los atributos: media (μ), varianza (σ^2), desviación estándar (σ) y mediana (me). Así, tanto los marcadores como los no marcadores se describen mediante vectores (V_a) de atributos estadísticos, dado por: $V_a = [\mu, \sigma^2, \sigma, me]$.

Adicionalmente, la LSSVM es entrenada considerando como patrón de entrenamiento los vectores V_a y entonando los valores de los parámetros que controlan su desempeño, μ y σ^2 . Este enfoque, basado en atributos, permite que la LSSVM realice su trabajo con mayor eficiencia, que cuando se utiliza el enfoque basado en vectores de mayor tamaño, que sólo considera el nivel de gris de los elementos de una imagen.

El conjunto de entrenamiento se construye con una relación de 1:10, lo cual significa que por cada marcador se incluyen 10 no marcadores. La etiqueta +1 se asigna a la clase conformada por los marcadores; mientras la etiqueta -1 se asigna a la clase de los no marcadores, es decir, el trabajo de entrenamiento se hace con base en una LSSVM binaria.

Durante el entrenamiento, se genera un clasificador dotado de una frontera de decisión para detectar los patrones de entrada a la LSSVM como marcadores o no marcadores. Posteriormente, debido a la presencia de falsos positivos y negativos, se aplica un proceso que permite incorporar al conjunto de entrenamiento los patrones que la LSSVM clasifica, inicialmente, de manera inapropiada. En este sentido, se consideró, un toolbox denominado LS-SVMLAB y la aplicación Matlab para implementar un clasificador LSSVM basado en un kernel gaussiano de base radial con parámetros σ^2 y g .

b) Validación: Las LSSVM entrenadas se utilizan para detectar a P1 y P2, en imágenes no usadas durante el entrenamiento. Para ello, se ejecutan las siguientes tareas:

- I) Reconocimiento de P1: Una LSSVM entrenada busca este punto de referencia, en la vista axial, desde la primera imagen ubicada en la base del corazón, hasta la imagen que representa la mitad del volumen considerado.
- II) Reconocimiento del P2: Una LSSVM entrenada empieza a buscar el ápex desde la imagen que representa la mitad de la base de datos (ecuador del corazón) hasta la última imagen que conforma dicha base.

El proceso de validación efectuado con LSSVM permite identificar, automáticamente, las coordenadas para P1 y P2 las cuales son multiplicadas por un factor de 8 unidades, a fin de poder ubicarlas, en las imágenes de

tamaño original. De esta forma, las referidas coordenadas se utilizan para establecer la dirección (normal) del plano aórtico y la colocación del referido plano en la base del LV. Luego, mediante un proceso de discriminación, se seleccionan los puntos de las bases de datos procesadas que sean de interés, de acuerdo con la estructura anatómica del corazón izquierdo que se desee segmentar, en este caso, la AAAV.

Etapa de segmentación

A fin de obtener la segmentación de la arteria aorta + la válvula aórtica a las imágenes filtradas les fue aplicado un algoritmo, basado en técnicas de agrupamiento, que considera un enfoque basado en crecimiento de regiones¹⁹. El crecimiento de regiones (RG) es una técnica que permite extraer de una imagen regiones que son conectadas de acuerdo a un criterio predefinido. El RG requiere de un vóxel semilla que puede ser seleccionado manual o automáticamente, de forma que se pueda extraer todos los vóxeles conectados a la semilla¹⁹. En este artículo, la mencionada semilla es detectada mediante el uso de una LSSVM siguiendo un procedimiento que se describe posteriormente. Adicionalmente, para efectos del presente trabajo, se consideró como criterio predefinido el dado por la Ecuación 4.

$$|I(x,y,z) - \mu| > m \cdot \sigma \quad (4)$$

Siendo: $I(x,y,z)$ el nivel de gris del vóxel objeto de estudio, μ y σ la media aritmética y la desviación estándar de los niveles de gris de la vecindad (de tamaño arbitrario r), seleccionada alrededor del vóxel semilla y m un número natural arbitrario.

Como se aprecia, el desempeño del RG depende, operativamente, de 2 parámetros. Ellos son: aquel que controla el tamaño de la vecindad inicial (r) y el parámetro m que controla la amplitud del rango de intensidades considerado para aceptar o rechazar un vóxel en una región. Tales parámetros deben someterse a un proceso de entonación¹⁹.

Selección de la semilla para el RG

En el contexto de la estrategia Egs, considerando las imágenes filtradas, la selección de la semilla para inicializar el RG se basa en los siguientes aspectos:

- i) Sobre las imágenes sub-muestreadas un cardiólogo selecciona las coordenadas manuales que establecen sin ambigüedad la ubicación espacial, en cada imagen considerada, del centroide de la arteria aorta + la válvula aórtica. A este centroide se le asigna la etiqueta P3.
- ii) Se implementa una LSSVM para reconocer y detectar a P3. Para ello se desarrollan los procesos de:
 - a) Entrenamiento. Se selecciona como conjunto de entrenamiento vecindades circulares de radio 20 píxeles, trazadas manualmente por un cardiólogo, que contienen tanto a P3 (marcadores), como regiones que no

contienen a P3 (no marcadores). Para los marcadores el centro de sus respectivas vecindades coincide con las coordenadas manuales de P3, establecidas anteriormente. Tales vecindades son construidas sobre la vista axial de una imagen sub-muestreada de 64x64 píxeles para P3. La principal razón por la cual se elige una única imagen, por cada punto de referencia, es porque se desea generar una LSSVM con alto grado de selectividad, que detecte sólo aquellos píxeles que posean un alto grado de correlación con el patrón de entrenamiento.

Luego, cada vecindad es vectorizada y, considerando sus niveles de gris, se calculan los atributos: media (μ), varianza (σ^2), desviación estándar (σ) y mediana (me). Así, tanto los marcadores como los no marcadores se describen mediante vectores (V_a) de atributos estadísticos, dado por: $V_a = [\mu, \sigma^2, \sigma, me]$. Adicionalmente, la LSSVM es entrenada considerando como patrón de entrenamiento los vectores V_a y entonando los valores de los parámetros que controlan su desempeño, g y σ^2 . Este enfoque, basado en atributos, permite que la LSSVM realice su trabajo con mayor eficiencia, que cuando se utiliza el enfoque basado en vectores de mayor tamaño, que sólo considera el nivel de gris de los elementos de una imagen.

El conjunto de entrenamiento se construye con una relación de 1:10, lo cual significa que por cada marcador se incluyen 10 no marcadores. La etiqueta +1 se asigna a la clase conformada por los marcadores; mientras la etiqueta -1 se asigna a la clase de los no marcadores, es decir, el trabajo de entrenamiento se hace con base en una LSSVM binaria.

Durante el entrenamiento, se genera un clasificador dotado de una frontera de decisión para detectar los patrones de entrada a la LSSVM como marcadores o no marcadores. Posteriormente, debido a la presencia de falsos positivos y negativos, se aplica un proceso que permite incorporar al conjunto de entrenamiento los patrones que la LSSVM clasifica, inicialmente, de manera inapropiada. En este sentido, se consideró, un toolbox denominado LS-SVMLAB y la aplicación Matlab para implementar un clasificador LSSVM basado en un kernel gaussiano de base radial con parámetros σ^2 y g .

b) Validación: Las LSSVM entrenadas se utilizan para detectar a P3, en imágenes no usadas durante el entrenamiento. Para ello, una LSSVM entrenada empieza a buscar a P3 desde la imagen que representa la mitad de la base de datos (ecuador del corazón) hasta la última imagen que conforma dicha base.

El proceso de validación efectuado con LSSVM permite identificar, automáticamente, las coordenadas para P3 las cuales son multiplicadas por un factor de 8 uni-

dades, a fin de poder ubicarlas, en las imágenes de tamaño original obteniéndose de esta forma la mencionada semilla.

Etapas de entonación de parámetros: Obtención de parámetros óptimos

Esta etapa permite la obtención de los parámetros óptimos que garantizan un buen desempeño de la estrategia propuesta. Para ello, se modifican los parámetros asociados con la técnica que se desee entonar recorriendo, sistemáticamente, los valores pertenecientes a ciertos rangos tal y como se describe a continuación:

- a) Para entonar el filtro gaussiano se debe considerar un parámetro identificado como desviación estándar (σ). En el contexto del presente trabajo, se hace uso de un enfoque isotrópico que asigna el mismo valor de desviación a cada una de las direcciones en las que se aplica el filtro gaussiano y se considera como σ el valor de la desviación estándar de la imagen original. El otro parámetro del filtro gaussiano, vinculado con el tamaño de la vecindad se fijó en $3 \times 3 \times 3$, debido a que ese fue el tamaño de vecindad óptimo, para este filtro, reportado en⁷.
- b) Los parámetros de las LSSVM, g y σ^2 , se entonan suponiendo que la función de costo es convexa y desarrollando ensayos basados en los siguientes pasos:
 - o Para entonar el parámetro g se fija arbitrariamente el valor de σ^2 y se asignan, sistemáticamente, valores al parámetro g . El valor de σ^2 se fija inicialmente en 25. Ahora, se varía g considerando el rango [0,100] y un tamaño de paso de 0.25.
 - o Un proceso análogo se aplica para entonar el parámetro σ^2 , es decir, se le asigna a g el valor óptimo obtenido en el paso anterior y, se considera un tamaño de paso de 0.25 para asignarle a σ^2 el rango de valores contenidos en el intervalo [0,50].
 - o Los parámetros óptimos de las LSSVM son aquellos valores de g y σ^2 que corresponden al error relativo porcentual mínimo, calculado considerando las coordenadas manuales y automáticas de los puntos de referencia. Éstas últimas coordenadas son generadas por la LSSVM.
- c) Durante la entonación de los parámetros del RG, cada una de las segmentaciones automáticas de la aurícula izquierda correspondiente al instante diástole final se compara, usando el coeficiente de Dice (Dc) [20], con la segmentación manual de la AA AV generada por un cardiólogo. Los valores óptimos para los parámetros del RG (r y m) se hacen coincidir con aquel experimento que genera el valor más alto para el Dc. Para r y m se considera el rango de valores establecido en^{7,17}, para aplicaciones prácticas que consideran imágenes médicas. En este sentido, m toma valores que pertene-

cen a los números reales comprendidos entre 0 y 10, mientras que r considera valores enteros entre 1 y 20.

El D_c es una métrica que permite comparar segmentaciones de una misma imagen 3-D obtenida por diversas metodologías⁷. En el contexto cardiaco, usualmente, el D_c es considerado para establecer que tan similares son, especialmente, la segmentación manual (RD) y la segmentación automática (RP) que genera la morfología de cualquier estructura cardiaca. Adicionalmente, el D_c es máximo cuando se alcanza un perfecto solapamiento entre RD y RP pero es mínimo cuando RD y RP no se solapan en absoluto. Además, los valores esperados para el D_c son números reales comprendidos entre 0 (mínimo) y 1 (máximo). Entre más cercano a 1 se encuentre el valor del D_c , mejor será el desempeño del procedimiento que no es manual. El modelo matemático que define el D_c , viene dado por la Ecuación 5.

$$D_c = \frac{2|RD \cap RP|}{|RD| + |RP|} \quad (5)$$

En este punto, es necesario enfatizar que en el contexto del presente trabajo, el proceso de entonación para un filtro particular se detiene cuando se identifican los valores de sus parámetros, asociados con la segmentación que genera el D_c de mayor valor. Es decir, la obtención de parámetros óptimos para los filtros se hace de manera indirecta.

Resultados

Resultados cuantitativos

Respecto a las LSSVM entrenadas se obtuvieron, como parámetros óptimos para g y σ^2 los valores 1.50 y 1.00, respectivamente. Estos valores están asociados con un error relativo porcentual mínimo de 2.54 %. Los parámetros óptimos del crecimiento de regiones fueron: $m=8.50$ y $r=2$ y corresponden a un D_c máximo de 0.9012 obtenido para un filtro de mediana de tamaño (5x5x5).

Resultados cualitativos

La Figura 3, presenta una vista 2-D (axial) relativa a: a) Imagen original. b) Imagen filtrada, en la cual se ha identificado la arteria aorta + válvula aórtica. En esta figura, se observa una importante disminución del ruido y un agrupamiento adecuado de las estructuras anatómicas presentes en la imagen.

Por otra parte, la Figura 4 muestra la vista 3-D de los 10 instantes que conforman el ciclo cardiaco completo del paciente considerado (validación intra-sujeto).

En la Figura 4, se aprecia una buena representación de la AAAV para la cual se obtuvo un D_c promedio de 0.8937 ± 0.7897 . Este valor para el coeficiente de Dice expresa una adecuada correlación entre las segmentaciones manuales,

generadas por un cardiólogo, y las automáticas producidas por la técnica propuesta en la presente investigación.

Figura 3: Vista 2D axial para: a) Imagen original. b) Imagen filtrada.





Figura 4. Representación 3-D de las segmentaciones de la aorta torácica correspondiente a un ciclo cardiaco completo.



Conclusiones

Se ha presentado la estrategia Egs cuya entonación permite una segmentación adecuada del conjunto anatómico compuesto por la arteria aorta ascendente + la válvula aórtica y que además permite generar un D_c promedio elevado. En un corto plazo, se tiene previsto realizar una validación inter-sujeto, considerando un número importante de bases de datos, para establecer la robustez de la Egs.

Las segmentaciones obtenidas, automáticamente, pueden ser útiles para determinar si el paciente sufre o no enfermedades tales como aneurismas, aterosclerosis, arterosclerosis, estenosis y/o enfermedades propias de la válvula aórtica. Además, la segmentación 3-D de la AAAV, mediante la aplicación de Egs, puede ser considerada para el diseño de modelos 3-D que permitan la planificación de cirugías y/o procesos terapéuticos asociados con las enfermedades que afectan el mencionado conjunto anatómico.

Referencias

1. Latarjet M, Ruíz A. Anatomía Humana. Volumen 2. Buenos Aires, Argentina: Editorial Panamericana; 1983.
2. Guyton A, Hall J. Textbook of Medical Physiology. USA: Elsevier Saunders; 2006.
3. Griep R, Ergin M, Galla J, Lansman S, McCullough J, Nguyen K, Klein J, Spielvogel D. Natural History of Descending Thoracic and Thoracoabdominal Aneurysms. Ann Torca Durg. 1999; 67(6):1927-30.
4. Coady M, Graeme L, Elefteriades J. Surgical Intervention Criteria for

- Thoracic Aortic and Thoracoabdominal Aneurysms. *Ann Thoracic Surg.* 1999; 67(6):1922-28.
5. Estrera A, Rubenstein F, Miller C, Huynh T, Letsou G, Safi H. Descending Surgical thoracic aortic aneurysm: surgical approach and treatment using the adjuncts cerebrospinal fluid drainage and distal aortic perfusion. *Ann Thoracic Surg* 2001; 72(2):481-6.
 6. World Health Organization (WHO). Global status report on non communicable diseases. Tech. Rep. 2010. Geneva; 2011.
 7. Vera, M. Segmentación de estructuras cardiacas en imágenes de tomografía computarizada multi-corte, Ph.D. dissertation. [Tesis doctoral]. Mérida-Venezuela: Universidad de los Andes; 2014.
 8. Zheng Y, Matthias J, Liao R, Boese J, Kirschstein U, Georgescu B, Zhou S K, Kempfert J, Walther T, Brockmann G, Comaniciu D. "Automatic aorta segmentation and valve landmark detection in c-arm ct: Application to aortic valve implantation," in *Medical Image Computing and Computer-Assisted Intervention*. 2010; vol 6361: pp. 476–483
 9. Sasa R, Ionasec D, Vitanovski I, Voigt Y, Wang B, Georgescu N, Navab, D Comaniciu. "Complete valvular heart apparatus model from 4d cardiac ct," *Medical Image Analysis*. 2012; 16(5): pp. 1003–1014.
 10. Elattar M A, Wiegerinck E M, Planken R N, van Assen H C, Baan J, Marquering H. Automatic segmentation of the aortic root in CT angiography of candidate patients for transcatheter aortic valve implantation. *Medical & Biological Engineering & Computing*. 2014; 52(7): 611–618.
 11. Pouch A, Wang H, Takabe M, Jackson B , Sehgal C , Gorman J, Gorman III R , Yushkevich P. Automated segmentation and geometrical modeling of the tricuspid aortic valve in 3D echocardiographic images. Published in final edited form as: *Med Image Comput Assist Interv*. 2013; 16(01): 485–492.
 12. Stroustrup B, *The C++ Programming Language*. Addison–Wesley; 2000.
 13. Chapman S, *MATLAB Programming for Engineers*. New York: Thomson; 2004.
 14. Johnson H, McCormick M, Ibáñez L. Insight Software Consortium. Insight Segmentation and Registration Toolkit (ITK). <http://www.itk.org/>, 3 ed. Updated for ITK version 4.5. (2009).
 15. Schroeder W, Martin K, Lorensen B, *The Visualization Toolkit, An Object-Oriented Approach to 3D Graphics*. ciudad? Prentice Hall; 2001.
 16. Pratt W. *Digital Image Processing*. USA: John Wiley & Sons Inc; 2007.
 17. Huérfano Y. Segmentación de estructuras del corazón derecho en imágenes de tomografía computarizada cardiaca, [Tesis de Maestría]. Universidad Nacional Experimental Del Táchira: Táchira-Venezuela; 2017.
 18. Meyer Y. *Wavelets and Operators*. USA: Cambridge University Press; 1999.
 19. Passarielo G, Mora F. *Imágenes Médicas, Adquisición, Análisis, Procesamiento e Interpretación*. Venezuela: Equinoccio Universidad Simón Bolívar; 1995.
 20. Dice L, Measures of the amount of ecologic association between species. *Ecology*. 1945; 26(3): pp. 297-302.

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)

CLaCaLIA (Conocimiento Latinoamericano y Caribeño de Libre Acceso), EBSCO Publishing, PROQUEST, **SCIENCE CITATION INDEX EXPANDED (SciSearch)**



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



cdch-ucv.net



publicaciones@cdch-ucv.net

www.revistahipertension.com.ve

www.revistadiabetes.com.ve

www.revistasindrome.com.ve

www.revistaavft.com.ve