

C Caracterización en función del volumen de hematomas epidurales, subdurales e intraparenquimatosos

Characterization of the volume of epidural, subdural and intraparenchymate hematomas

Miguel Vera, MgSc. PhD^{1,2*}, Yoleidy Huérfano, MgSc¹, Julio Contreras, MgSc², María Vera, BSc³, Williams Salazar, MD³, Sandra Vargas, MgSc², Gerardo Chacón, MgSc, PhD², Jhoel Rodríguez MgSc².

¹Grupo de Investigación en Procesamiento Computacional de Datos (GIPCD-ULA). Universidad de Los Andes-Táchira, Venezuela. E-mail de correspondencia: m.avera@unisimonbolivar.edu.co

²Grupo de Investigación Altos Estudios de Frontera (ALEF). Universidad Simón Bolívar, Cúcuta, Colombia.

³Hospital Central de San Cristóbal- Táchira, Venezuela.

131

Resumen

Mediante este trabajo se propone la comparación entre tres técnicas utilizadas para obtener el volumen ocupado por hematomas epidurales, subdurales e intraparenquimatosos, en imágenes de tomografía computarizada multicapa (MSCT). La determinación de este volumen es de vital importancia puesto que, de acuerdo con la literatura, dicho volumen es un predictor invaluable para decidir la conducta a seguir respecto a la presencia de los hematomas mencionados. Las técnicas consideradas se basan en determinación de: a) Longitudes (LT), b) Áreas (AT) y c) Volúmenes explícitos (VCT). La LT parte de una hipótesis geométrica y estima el volumen a partir de las dimensiones del hematoma (largo y ancho) y del espesor de las capas que conforman las imágenes de MSCT que contienen cualquiera de los mencionados hematomas. Adicionalmente, mediante la AT, un neurocirujano desarrolla un proceso manual para obtener las áreas de cada una de las capas en la que aparece el hematoma considerado. Usando tales áreas se puede calcular el mencionado volumen. Por otra parte, la VCT produce la segmentación del hematoma mediante la aplicación de 4 etapas desarrolladas en el dominio 3D. Ellas son: pre-procesamiento, segmentación, pos-procesamiento y entonación de parámetros. La etapa de pre-procesamiento se divide en dos fases. En la primera, denominada definición de un volumen de interés (VOI), se emplea un algoritmo de umbralización simple el cual permite, fundamentalmente, acotar cada uno de los hematomas candidatos. En la segunda fase, identificada como filtrado, se aplica un banco de fil-

tros para disminuir el impacto de los artefactos y atenuar el ruido presente en las imágenes. Los filtros que conforman esta fase son: el filtro de erosión morfológica (MEF), el filtro de mediana (MF) y un filtro basado en la magnitud del gradiente. Por otra parte, durante la etapa de segmentación se implementa un algoritmo de agrupamiento, denominado crecimiento de regiones (RG), el cual es aplicado a las imágenes pre-procesadas. A fin de compensar el efecto del MEF, las segmentaciones preliminares de los hematomas son sometidos a la etapa de posprocesamiento la cual se basa en la aplicación de un filtro de dilatación morfológica (MDF). Durante la entonación de parámetros, el coeficiente de Dice (Dc) es utilizado para comparar las segmentaciones de los hematomas, obtenidas automáticamente, con la segmentación de los hematomas generadas, manualmente, por un neurocirujano. La combinación de parámetros que generan el Dc más elevado, permite establecer los parámetros óptimos de cada una de los algoritmos computacionales que conforman la técnica no lineal propuesta. Los resultados obtenidos permiten reportar un Dc superior a 0.86 lo cual indica una buena correlación entre las segmentaciones generadas por el experto neurocirujano y las producidas por la técnica computacional desarrollada. Finalmente, la VCT permite el cálculo del volumen del hematoma considerando el número de vóxeles que conforman el hematoma segmentado automáticamente.

Palabras clave: Tomografía cerebral, Hematomas, Segmentación, Volumen del hematoma.

The study proposes the comparison between three techniques used to obtain the volume occupied by epidural, subdural and intraparenchymal hematomas, in multi-layer computed tomography (MSCT) images. The determination of this volume is of vital importance since, according to the literature, this volume is an invaluable predictor for deciding the behavior to be followed regarding the presence of the aforementioned hematomas. The techniques considered are based on the determination of: a) Lengths (LT), b) Areas (AT) and c) Explicit volumes (VCT). The LT starts from a geometric hypothesis and estimates the volume from the dimensions of the hematoma (length and width) and the thickness of the layers that make up the MSCT images that contain any of the aforementioned hematomas. Additionally, through the TA, a neurosurgeon develops a manual process to obtain the areas of each of the layers in which the hematoma is considered. Using such areas can calculate the aforementioned volume. On the other hand, the VCT produces the segmentation of the hematoma through the application of 4 stages developed in the 3D domain. They are: pre-processing, segmentation, post-processing and intonation of parameters. The pre-processing stage is divided into two phases. In the first one, called the definition of a volume of interest (VOI), a simple thresholding algorithm is used which allows, fundamentally, to limit each of the candidate hematomas. In the second phase, identified as filtering, a filter bank is applied to reduce the impact of the artifacts and attenuate the noise present in the images. The filters that make up this phase are: the morphological erosion filter (MEF), the median filter (MF) and a filter based on the magnitude of the gradient. On the other hand, during the segmentation stage a grouping algorithm is implemented, called growth of regions (RG), which is applied to the pre-processed images. In order to compensate for the effect of the MEF, the preliminary segmentations of the hematomas are subjected to the post-processing stage, which is based on the application of a morphological dilation filter (MDF). During the intonation of parameters, the coefficient of Dice (Dc) is used to compare the segmentations of the bruises, obtained automatically, with the segmentation of the hematomas generated, manually, by a neurosurgeon. The combination of parameters that generate the highest Dc, allows to establish the optimal parameters of each of the computational algorithms that make up the proposed nonlinear technique. The obtained results allow to report a Dc superior to 0.86 which indicates a good correlation between the segmentations generated by the expert neurosurgeon and those produced by the developed computational technique. Finally, the VCT allows the calculation

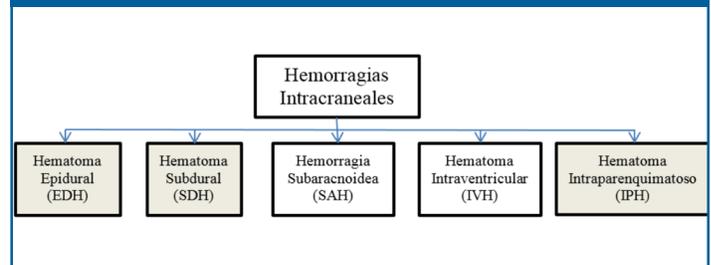
of the volume of the hematoma considering the number of voxels that make up the segmented hematoma automatically.

Keywords: Brain Tomography, Hematomas, Segmentation, Hematoma volume.

Introducción

La segmentación de estructuras anatómicas del cerebro humano, presentes en imágenes adquiridas por cualquier modalidad imagenológica, constituye el punto de partida para el diagnóstico de un elevado número de enfermedades que afectan el cerebro. Las hemorragias intracraneales pueden clasificarse de varias maneras^{1,2} (Ver Figura 1).

Figura 1. Diagrama de bloques mediante el cual se destaca en color gris las hemorragias intracraneales consideradas en el presente trabajo

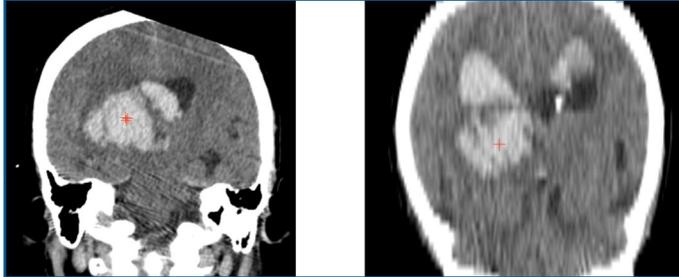


Tal y como lo indica la Figura 1, entre las hemorragias intracraneales se encuentran los hematomas epidurales (EDH), subdurales (SDH) e intraparenquimatosos (IPH). Normalmente, los EDH son ocasionados por traumatismos físicos que ocasionan la laceración de la arteria meníngea media (o alguna de sus ramas) y se pueden definir como una hemorragia intracraneal o sangre acumulada que se forma por encima de la membrana duramadre que rodea el cerebro¹. Por otra parte, los SDH son ocasionados por la laceración del tejido cerebral o sus vasos y se localizan por debajo de la membrana duramadre que rodea el cerebro¹. Por último, las IPH espontáneas no aneurismáticas se localizan, usualmente, en los ganglios de la base del cerebro y se debe primordialmente a procesos de hipertensión arterial mal controlada².

Por otra parte, las neuroimágenes digitales vienen acompañadas de diversas imperfecciones tales como ruido^{3,4} y artefactos⁵. Estas imperfecciones se convierten en verdaderos desafíos, cuando se implementan estrategias computacionales para la generación de la morfología (normal o anormal) de las mencionadas estructuras³. La Figura 2, generada con base en imágenes de tomografía computarizada multicapa (MSCT), ilustra la presencia del ruido

Poisson (vista axial), el volumen parcial (vista axial) y el artefacto escalera (vista coronal).

Figura 2. Representación gráfica de una de las hemorragias intracraneales consideradas, en este caso la IPH, en la que se aprecian algunas imperfecciones, en imágenes de MSCT cerebral: a) Vista axial (Ruido Poisson. b) Vista coronal (artefacto escalera)



Adicionalmente, al revisar el estado del arte relativo a la segmentación de IPH se hallaron los trabajos que se describen a continuación. En ese sentido, recientemente Kamnitsas et al.⁶, reportan una técnica automática, basada en redes neurales convolucionales que aplican aprendizaje profundo, para la segmentación de lesiones ocupantes de espacio que incluyen EDH, SDH e IPH presentes en imágenes médicas multimodalidad. Ellos reportan un coeficiente de Dice [7] superior a 0.89 en la segmentación de este tipo de hematomas.

En⁸, Prakash et al. desarrollaron una técnica para la segmentación de hemorragias intracerebrales, incluida hemorragia intracranial intraparenquimatosa, usando conjuntos de nivel regularizados. Ellos reportan un Dc superior a 0.84 al segmentar los EDH, SDH e IPH presentes en 200 bases de datos de tomografía computarizada.

Por otra parte, el presente trabajo presenta una técnica computacional no lineal para la segmentación de las hemorragias intracraneales de tipo EDH, SDH e IPH. La mencionada técnica considera las etapas de pre-procesamiento, segmentación, pos-procesamiento, entonación de parámetros y cálculo del volumen de las hemorragias intracraneales ya definidas.

Materiales y métodos

Descripción de las bases de datos

Las bases de datos (DB) utilizadas fueron suministradas por el Hospital Central de San Cristóbal-Táchira-Venezuela. Fueron adquiridas mediante la modalidad de MSCT correspondientes a las estructuras anatómicas presentes en la cabeza de 3 pacientes. Sus características numéricas se presentan mediante la tabla 1.

Además, se cuenta con la segmentación manual de los hematomas presentes en las tres DB, generadas por un neurocirujano, las cuales representan el ground truth que servirán como referencia para validar los resultados.

Descripción de la técnica computacional no lineal propuesta, para la segmentación automática de los hematomas epidurales.

Mediante la Figura 3, se presenta un diagrama esquemático que sintetiza los métodos que conforman la técnica propuesta, en la presente investigación, para segmentar los mencionados hematomas.

Tabla 1. Características generales de las bases de datos consideradas en el presente trabajo

Etiqueta de la DB	Número de vóxeles	Dimensiones del vóxel (mm ³)	Género del paciente	Edad del paciente	Tipo de hematoma cerebral
DB1	512x512x40	0.6191 x 0.6191 x 3.2456	Masculino	21	EDH
DB2	512x512x20	0.4589 x 0.4589 x 6.2784	Masculino	18	SDH
DB3	512x512x40	0.3964 x 0.3964 x 3.6785	Femenino	54	IPH

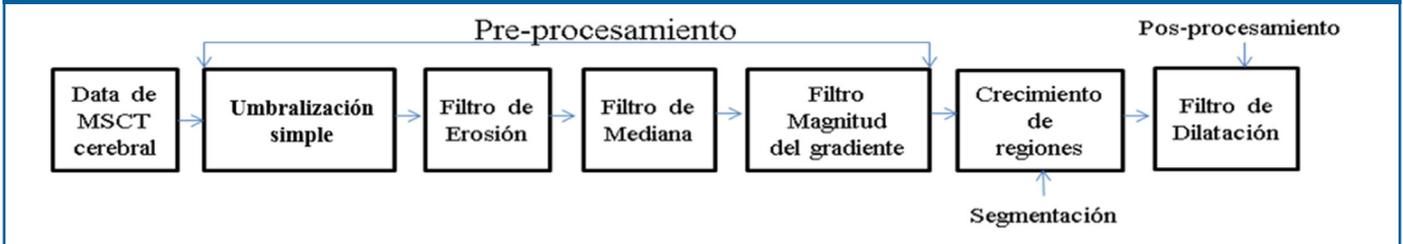
Etapa de pre-procesamiento

- Fase de definición de un volumen de interés (VOI) que contiene cada hematoma considerado:

En la figura 3, la fase para establecer un volumen de interés corresponde con el bloque denominado Umbralización. Los algoritmos de umbralización son, generalmente,

de estructura simple y permiten clasificar, eficientemente, los elementos de una imagen considerando uno o varios umbrales. Tales umbrales pueden seleccionarse considerando tanto el histograma de una imagen como la posición, la intensidad o una vecindad arbitraria del elemento objeto de estudio denominado, frecuentemente, elemento actual⁹.

Figura 3. Diagrama de bloques de la técnica computacional no lineal (NLCT) propuesta para la segmentación de los hematomas epidurales, subdurales e intraparaquimatosos.



En el presente trabajo se consideró una umbralización simple la cual se basa en la elección de un valor para cierto umbral. Este umbral permite realizar la discriminación entre la estructura anatómica de interés y el resto de estructuras presentes en una imagen. Usualmente, el referido umbral se elige considerando el histograma de la imagen. Uno de los criterios que se aplica para realizar la referida discriminación es el siguiente: Si la intensidad o nivel de gris del elemento actual es igual o menor que el valor del umbral seleccionado, el nivel de gris (GL) del elemento actual permanece inalterado; mientras que si tal intensidad es mayor que GL del elemento actual se hace corresponder, generalmente, con el menor nivel de gris presente en la imagen que se está procesando^{9,10}.

- Fase de filtrado: En el diagrama de bloques, presentado mediante la figura 3, esta fase corresponde con los filtros de erosión morfológica, de mediana y magnitud del gradiente. A continuación se describen estos filtros.

o Filtro de erosión morfológica (MEF):

La morfología matemática está basada en la teoría de conjuntos, debido a ello, los objetos presentes en una imagen pueden ser tratados como conjuntos de puntos. Generalmente, es posible definir operaciones entre dos conjuntos constituidos por elementos pertenecientes a los referidos objetos y a un conjunto denominado elemento estructurante (SE)¹¹. Los elementos estructurantes pueden visualizarse como vecindades del elemento objeto de estudio las cuales poseen morfología (forma) y tamaño variable¹². La morfología matemática se implementa, en la práctica, mediante diversos filtros morfológicos cuyos operadores básicos son la erosión y la dilatación¹³. Estos operadores son filtros espaciales no lineales que pueden ser aplicados sobre imágenes binarias, en escala de grises o a color. En particular, La erosión (\ominus) de una imagen bidimensional (I), compuesta por niveles

de grises, utilizando un elemento estructurante bidimensional (B) se define mediante la Ecuación 1^{14,15}.

$$\ominus B)(x, y) = \min_{(s,t) \in B} [I(x + s, y + t) - B(s, t)]. \quad (1)$$

siendo min el nivel de gris mínimo contenido en B.

De acuerdo con la ecuación 1, para aplicar el filtro u operador de erosión morfológico se recorre la imagen considerada con un SE o vecindad de tamaño arbitrario, reemplazando el nivel de gris de cada uno de los elementos de tal imagen por el nivel de gris mínimo, contenido en la mencionada vecindad.

Para efectos del presente trabajo, se consideró un elemento estructurante esférico y se deja como parámetro, para controlar el desempeño del MEF, el tamaño del SE.

o Filtro de Mediana (MF):

El filtro de mediana (MF) también es de tipo no lineal. Normalmente, se utiliza para minimizar el ruido de tipo impulsivo presentes en los niveles de gris de los píxeles vecinos del vóxel objeto de estudio. El parámetro que controla el funcionamiento del MF es el tamaño de la ventana de observación o vecindad. Para filtrar una imagen, se elige una vecindad de tamaño arbitrario, usualmente impar, se ordenan los niveles de gris de los vóxeles contenidos en la ventana de observación y se determina con ellos la medida estadística denominada mediana. Finalmente, se hace coincidir el nivel de gris del vóxel actual con el valor de la mediana obtenida repitiéndose este procedimiento, iterativamente, para cada vóxel que conforma la imagen considerada¹⁶.

Este tipo de filtro se caracteriza por la conservación de los bordes de los objetos presentes en la imagen y tiene la ventaja de que el valor final del vóxel es un valor real presente en la imagen y no un promedio. Además, el fil-

tro de la mediana es menos sensible a valores extremos. Uno de los principales inconvenientes es que el tiempo de cómputo aumenta substancialmente a medida que se incrementa el tamaño de la vecindad¹⁷.

o Filtro de Magnitud del Gradiente (GMF):

El papel de este filtro es detectar los bordes de las estructuras presentes en las imágenes (I). 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 imagen¹⁸. Esta técnica calcula la magnitud del gradiente usando las primeras derivadas parciales direccionales de una imagen. El modelo matemático 3D clásico, para obtener una imagen filtrada por magnitud del gradiente (IGM) se presenta mediante la Ecuación 2.

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

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 ruido¹⁸, por ello, se recomienda filtrar la imagen inicialmente para mejorar el rendimiento del detector con respecto al ruido.

Etapa de segmentación

La ubicación de la semilla, para inicializar el crecimiento de regiones¹⁶ (RG), se calcula usando máquinas de soporte vectorial de mínimos cuadrados (LSSVM)¹⁹ como se describe en la referencia²⁰. Para aplicar el RG, a las imágenes pre-procesadas, se hicieron las siguientes consideraciones: a) A la vecindad inicial, que se construye a partir de la semilla, se le asigna forma cúbica cuyo lado depende de un escalar arbitrario r. El parámetro r requiere de un proceso de entonación. b) Como criterio pre-definido, se elige el modelado mediante la Ecuación 3.

$$|I(x) - \mu| < m\sigma \quad (3)$$

siendo: I(x) la intensidad del vóxel semilla, μ y σ la media aritmética y la desviación estándar de los niveles de gris de la vecindad inicial y m un parámetro que requiere entonación.

Etapa de posprocesamiento

Con el propósito de compensar el efecto producido por el filtro de erosión morfológica, se introduce una etapa de posprocesamiento la cual se basa en la aplicación de

un filtro de dilatación morfológica (MDF), considerando la imagen binaria derivada de la etapa de segmentación.

Las imágenes binarias son aquellas que tienen dos niveles de gris, generalmente blanco y negro. El efecto de la dilatación morfológica es ampliar las regiones de la imagen de color blanco. La cantidad de ampliación depende del tamaño y forma del SE. En particular, la dilatación (\oplus) de una imagen bidimensional binaria (Ib), utilizando un elemento estructurante bidimensional (B), se define como el resultado de operar la Ib con los valores del SE bajo la operación lógica OR. Para efectos del presente trabajo, se consideró un elemento estructurante esférico y se deja como parámetro, para controlar el desempeño del proceso de dilatación, el tamaño del SE.

Etapa 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.

- Los filtros de erosión, mediana y dilatación tienen como parámetro el tamaño del elemento estructurante. Con el propósito de reducir el número de posibles combinaciones, se consideró un enfoque isotrópico para establecer el rango de valores, que controlan el tamaño del SE, el cual viene dado por las combinaciones, impares, dadas por las siguientes ternas ordenadas: (1,1,1), (3,3,3), (5,5,5), (7,7,7) y (9,9,9).
- Los parámetros de las LSSVM, σ^2 y γ , se entonan suponiendo que la función de costo es convexa y desarrollando ensayos basados en los siguientes pasos:
- Para entonar el parámetro γ se fija arbitrariamente el valor de σ^2 y se asignan, sistemáticamente, valores al parámetro γ . El valor de σ^2 se fija inicialmente en 2.5. Ahora, se varía γ considerando el rango [0,100] y un tamaño de paso de 0.25.
- Un proceso análogo se aplica para entonar el parámetro σ^2 , es decir, se le asigna a γ el valor óptimo obtenido en el paso anterior y, se considera un tamaño de paso de 0.25 para asignarle a σ el rango de valores contenidos en el intervalo [0,50].
- Los parámetros óptimos de las LSSVM son aquellos valores de γ y σ^2 que corresponden al error relativo porcentual mínimo, calculado considerando las coordenadas manuales de la semilla de referencia, establecidas por el neurocirujano y las automáticas generadas por la LSSVM.

- Durante la entonación de los parámetros del RG, cada una de las segmentaciones automáticas del IPH correspondientes a la DB descrita, se compara con la segmentación manual de la IPH generada por un neurocirujano, considerando el Dc. 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.

El Dc es una métrica que permite comparar segmentaciones de una misma imagen 2D o 3D, obtenida por diversas metodologías. En el contexto médico, usualmente, el Dc es considerado para establecer que tan similares son, espacialmente, la segmentación manual (RD) y la segmentación automática (RP) que genera la morfología de cualquier estructura anatómica. Adicionalmente, el Dc 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 Dc son números reales comprendidos entre 0 (mínimo) y 1 (máximo). Entre más cercano a 1 se encuentre el valor del Dc, mejor será el desempeño del procedimiento que no es manual. El modelo matemático que define el Dc, viene dado por la Ecuación 4.

$$Dc = \frac{2|RD \cap RP|}{|RD| + |RP|} \quad (4)$$

La Tabla 2, presenta la información relativa a los parámetros obtenidos luego de aplicar la etapa de entonación.

Tabla 2. Parámetros óptimos para los algoritmos computacionales que conforman la NLCT, para la segmentación de los hematomas considerados.

MEF (Tamaño)	MF (Tamaño)	RG (r,m)	MDF (Tamaño)
(3,3,3)	(5,5,5)	(10,6)*	(5,5,5)
(5,5,5)	(3,3,3)	(8,2.5)**	(3,3,3)
(5,5,5)	(3,3,3)	(8,2.5)***	(3,3,3)

Valores correspondientes al máximo valor del coeficiente de Dice (Dc): *Dc=0.9023 (EDH), **Dc=0.8876 (SDH) y ***Dc=0.8698 (IPH).

Caracterización de los hematomas considerados mediante la determinación del volumen respectivo.

A continuación se describen los procesos asociados con la caracterización de los hematomas considerados usando las técnicas basadas en medición de: a) Longitudes (LT), b) Áreas (AT) y c) Volúmenes explícitos (VCT). La descripción de las técnicas se basa en la descripción presentada en la referencia²¹.

a) Cálculo del volumen mediante LT

La LT asume que el hematoma, candidato a ser caracterizado, tiene forma elipsoidal. Esta técnica genera el volumen del hematoma dividiendo entre 2 la multiplicación de las longitudes A, B y C, siendo A y B las longitudes de los ejes mayor y menor del hematoma, respectivamente. Tales longitudes se miden en la imagen bidimensional (capa) con la "piscina" de sangre, vinculada con el hematoma,

de mayor área. La longitud C se obtiene al multiplicar el número de capas, en las que está presente el hematoma, por el espesor (E) de cada capa.

b) Cálculo del volumen mediante AT

Mediante la AT, un neurocirujano puede obtener el área total del hematoma (TAH), usando un proceso manual para delinearlo, capa por capa, para luego generar el volumen del hematoma multiplicando el TAH por el espesor E. El TAH viene dado por la suma de todas las áreas en las que está presente el hematoma.

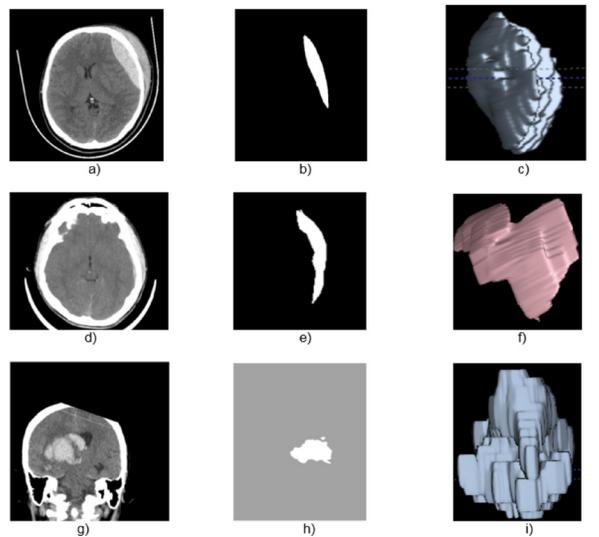
c) Cálculo del volumen mediante la VCT

La VCT permite el cálculo del volumen del hematoma, candidato a ser caracterizado, multiplicando las dimensiones del vóxel por el número de vóxeles que conforman el hematoma segmentado automáticamente.

Resultados

La Figura 4, muestra una vista 2-D tanto del IPH original, como de las versiones procesadas luego de aplicar la técnica NLCT.

Figura 4. a) Imagen Original DB1, b) Vista 2D del EHD, c) Vista 3D del EDH, d) Imagen Original DB2, e) Vista 2D del SHD, f) Vista 3D del SDH, g) Imagen Original DB3, h) Vista 2D del IPH, i) Vista 3D del IPH



Por otra parte, la tabla 3, muestra los valores para el volumen generados mediante LT, AT y VCT.

Es importante señalar que, una de las utilidades de estos volúmenes es que definen, en alto porcentaje, la conducta a seguir respecto al paciente²¹. Adicionalmente, los hematomas que superan el umbral de los 30 cm³, son susceptibles de ser intervenidos quirúrgicamente²². En este caso, los pacientes 1 y 3 de acuerdo con la la LT debería ser llevado al quirófano; mientras que los resultados generados por AT y VCT imposibilitarían esa intervención. Además,

las tres técnicas indican que el paciente 2 no debe ser operado puesto que el volumen del SDH es muy inferior.

El análisis visual de la información revela que, en las bases consideradas, la LT siempre sobre estimó el volumen de cada hematoma en concordancia con las referencias^{21,22}.

Tabla 3. Valores obtenidos, mediante la aplicación de cada técnica, para el volumen que ocupa cada uno de los hematomas considerados.

Volumen (cm ³) de los hematomas segmentados			
Técnica	EDH	SDH	IPH
LT	40.30	9.27	32.89
AT	34.96	7.09	27.76
VCT	37.03	7.33	28.09

Conclusiones

Se ha presentado una técnica computacional no lineal cuya entonación permite una segmentación precisa de EDH, SDH e IPH, presente en imágenes de tomografía computarizada, ya que el Dc obtenido es comparable con el reportado en las referencias^{6,8}.

En el futuro inmediato, se tiene previsto realizar una validación completa que permita analizar el desempeño de la técnica propuesta ante la variabilidad inter-sujeto y explorar la utilidad de la NLCT en la cuantificación del volumen que ocupan los mencionados hematomas.

Las segmentaciones generadas, automáticamente, por la técnica computacional propuesta permite calcular el volumen de cada hematoma considerado. Este volumen es vital al momento de decidir si un paciente es intervenido quirúrgicamente o no para abordar el hematoma que aqueja su estado de salud.

Agradecimientos

Los autores agradecen por el apoyo financiero a la Universidad Simón Bolívar de Cúcuta-Colombia (a través del proyecto código 2016-16.

Referencias

1. Stippler M. Craniocerebral trauma. In: Daroff RB, Jankovic J, Mazziotta JC, Pomeroy SL, eds. *Bradley's Neurology in Clinical Practice*. 7th ed. Philadelphia, PA: Elsevier; 2016:chap 62.
2. Mezzadri J., Goland J., y Sokolovsky M. *Introducción a la Neurocirugía*. Capítulo: Patología vascular II. Ediciones Journal. Segunda edición. 2011.
3. Vera M. Segmentación de estructuras cardiacas en imágenes de tomografía computarizada multi-corte. Ph.D. dissertation, Universidad de los Andes, Mérida-Venezuela, 2014.

4. Maiera A, Wigström 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.
5. Kroft L, De Roos A, Geleijns J. Artifacts in ECG-synchronized MDCT coronary angiography. *American Journal of Roentgenology*.2007;189(3):581–91.
6. Kamnitsas K., Lediga C., Newcombe V., Simpson J., Kaneb A., Menon D., Rueckert D., Glocker B. Efficient Multi-Scale 3D CNN with fully connected CRF for Accurate Brain Lesion Segmentation. *Medical Image Analysis*, Vol 23, pp.1603-1659, 2017.
7. Dice, L. Measures of the amount of ecologic association between species. *Ecology*, vol. 26, n. 3, pp. 297-302. 1945.
8. Prakash K., Zhou S., Morgan T., Hanley D., Nowinski W. Segmentation and quantification of intra ventricular/cerebral hemorrhage in CT scans by modified distance regularized level set evolution technique. *Int J Comput Assist Radiol Surg*. 2012; 7(5): 785-798.
9. Sezgin M., Sankur B. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, vol. 13, pp. 146-165, 2004.
10. Pham D., Xu C., Prince J. Current methods in medical image segmentation, *Annual Review of Biomedical Engineering*. vol. 2, pp. 315–337, 2000.
11. Serra J. *Image Analysis Using Mathematical Morphology*. London, England: Academic Press, 1982.
12. Pratt W. *Digital Image Processing*. USA: John Wiley & Sons Inc, 2007.
13. Mukhopadhyay S., Chanda B. A multiscale morphological approach to local contrast enhancement. *Signal Processing*, vol. 80, no. 4, pp. 685–696, 2000.
14. Yu Z., Wei G., Zhen C., Jing T., Ling L. Medical images edge detection based on mathematical morphology. En *Proceedings of the IEEE Engineering in Medicine and Biology 27th Annual Conference, Shanghai–China, September 2005*, pp. 6492–6495.
15. Chen T., Wu Q., Rahmani R., Hughes J. A pseudo top-hat mathematical morphological approach to edge detection in dark regions. *Pattern Recognition*. 2002; 35(1):199–210.
16. Passariello G., Mora F. *Imágenes Médicas, Adquisición, Análisis, Procesamiento e Interpretación*. Venezuela: Equinoccio Universidad Simón Bolívar. 1995.
17. Fischer M., Paredes J., Arce G. Weighted median image sharpeners for the world wide web. *IEEE Transactions on Image Processing*. 2002;11(7):717-27.
18. Suykens JA, Vandewalle J. Least squares support vector machine classifiers. *Neural processing letters*. 1999;9(3):293-300.
19. Vera M., Molina V., Huérfano Y., Vera M., Del Mar A., Salazar W., Wilches S., Graterol M., Rojas J., Garicano C., Peña A., Contreras J., Arias V., y Chacón J. (2016). Segmentación automática tridimensional de estructuras ventriculares cerebrales en imágenes de resonancia magnética. *Latinoamericana de Hipertensión*. 11(2), 20-24.
20. Hu T., Yan L., Yan Peng., Wang X., Yue G. Assessment of the ABC/2 Method of Epidural Hematoma Volume Measurement as Compared to Computer-Assisted Planimetric Analysis. *Biological Research for Nursing*. 2016, 18(1) 5-11.
21. Freeman, W., Barrett, K., Bestic, J., Meschia, J., Broderick, D., Brott, T. Computer-assisted volumetric analysis compared with ABC/2 method for assessing warfarinrelated intracranial hemorrhage volumes. 2008, *Neurocritical Care*, 9, 307–312.