

## ARTÍCULO ORIGINAL

# Segmentación del hígado en imágenes de tomografía computarizada

## Liver's segmentation on computed tomography images

Melanie Yusta Gómez<sup>1</sup> Marlen Pérez Díaz<sup>1</sup> Rubén Orozco Morales<sup>1</sup> Xiomara Plasencia Hernández<sup>2</sup>

<sup>1</sup> Universidad Central Marta Abreu de Las Villas, Santa Clara, Villa Clara, Cuba

<sup>2</sup> Hospital Provincial Universitario Oncológico Dr. Celestino Hernández Robau, Santa Clara, Villa Clara, Cuba

### Cómo citar este artículo:

Yusta-Gómez M, Pérez-Díaz M, Orozco-Morales R, Plasencia-Hernández X. Segmentación del hígado en imágenes de tomografía computarizada. **Medisur** [revista en Internet]. 2022 [citado 2025 Mar 20]; 20(2):[aprox. 14 p.]. Disponible en: <http://medisur.sld.cu/index.php/medisur/article/view/5375>

### Resumen

**Fundamento:** la segmentación del hígado utilizando datos de tomografía computarizada es el primer paso para el diagnóstico de enfermedades hepáticas. Actualmente la segmentación de estructuras y órganos, basado en imágenes, que se realiza en los hospitales del país, dista de tener los niveles de precisión que se obtienen de los modernos sistemas 3D, por lo que se requiere buscar alternativas viables utilizando el PDI sobre ordenador.

**Objetivo:** determinar una variante eficaz y eficiente desde el punto de vista computacional en condiciones de rutina hospitalaria, para la segmentación de imágenes hepáticas con fines clínicos.

**Métodos:** se compararon dos métodos modernos de segmentación (Graph Cut y EM/MPM) aplicándolos sobre imágenes de tomografía de hígado. Se realizó un análisis evaluativo y estadístico de los resultados obtenidos en la segmentación de las imágenes a partir de los coeficientes de Dice, Vinet y Jaccard.

**Resultados:** con el método Graph Cut, en todos los casos, se segmentó la región deseada, incluso cuando la calidad de las imágenes era baja, se observó gran similitud entre la imagen segmentada y la máscara de referencia. El nivel de detalles visuales es bueno y la reproducción de bordes permanece fiel a la máscara de referencia. La segmentación de las imágenes por el método de EM/MPM, no siempre fue satisfactoria.

**Conclusiones:** el método de segmentación Graph Cut obtuvo mayor precisión para segmentar imágenes de hígado.

**Palabras clave:** procesamiento de imagen asistido por computador, tomografía computarizada por rayos X, hígado

### Abstract

**Background:** liver segmentation using computed tomography data is the first step for the diagnosis of liver diseases. Currently, the segmentation of structures and organs, based on images, which is carried out in the country's hospitals, is far from having the levels of precision obtained from modern 3D systems, it is necessary to search for viable alternatives using the PDI on a computer.

**Objective:** to determine an effective and efficient variant from the computational point of view in routine hospital conditions, for the segmentation of liver images for clinical purposes.

**Methods:** Two modern segmentation methods (Graph Cut and EM/MPM) were compared by applying them to liver tomography images. An evaluative and statistical analysis of the results obtained in the segmentation of the images from the Dice, Vinet and Jaccard coefficients was carried out.

**Results:** with the Graph Cut method, in all cases, the desired region was segmented, even when the quality of the images was low, great similarity was observed between the segmented image and the reference mask. The level of visual detail is good, and edge reproduction remains true to the reference skin. Image segmentation by the EM/MPM method was not always satisfactory.

**Conclusions:** the Graph Cut segmentation method obtained greater precision to segment liver images.

**Key words:** image processing, computer-assisted, tomography, X-Ray computed, liver

**Aprobado:** 2022-02-01 09:44:06

**Correspondencia:** Melanie Yusta Gómez. Universidad Central Marta Abreu de Las Villas. Villa Clara. Cuba. [melanieyg97@gmail.com](mailto:melanieyg97@gmail.com)

## INTRODUCCIÓN

La segmentación de imágenes médicas ofrece un análisis cuantificado de las características existentes en un determinado órgano o lesión.

Existe una multitud de métodos de segmentación en la literatura. Su uso depende mucho del objeto a segmentar y la tecnología de adquisición. Muchas referencias presentan un compendio de los métodos y técnicas más usados.<sup>(1,2)</sup>

Dada la dificultad de la segmentación del hígado, se han propuesto muchos métodos con diversos grados de éxito.<sup>(3)</sup> Sin embargo, algunos problemas críticos permanecen sin resolver.

En los últimos años, los métodos utilizados más aceptados por la comunidad científica son los que trabajan en términos de la minimización de energía,<sup>(4)</sup> entre los cuales existe preferencia por el método basado en el conjunto de niveles y el método basado en cortes gráficos.<sup>(1,5)</sup>

A pesar de que los modernos tomógrafos están provistos de software para procesar la imagen, constantemente se investiga en métodos de procesamiento para mejorar la calidad de la imagen, que a su vez contribuyen a mejorar los diagnósticos. Los métodos de segmentación de estructuras y órganos son parte de estas mejoras progresivas. El presente estudio se enfoca en la segmentación del hígado a partir de imágenes de

TC. Este aspecto reviste importancia tanto científica como práctica desde el punto de vista clínico, dada la necesidad de obtener segmentaciones muy precisas de este órgano, tanto para propósitos de trasplante como de radioterapia de tumores en el hígado. Por tales razones esta investigación tuvo como objetivo determinar una variante eficaz y eficiente desde el punto de vista computacional en condiciones de rutina hospitalaria, para la segmentación de imágenes hepáticas con fines clínicos.

## MÉTODOS

Se compararon dos métodos modernos de segmentación (*Graph Cut* y EM/MPM) aplicándolos sobre imágenes de tomografía de hígado. Se realizó un análisis evaluativo y estadístico de los resultados obtenidos en la segmentación de las imágenes a partir de los coeficientes de Dice, Vinet y Jaccard.

El método de segmentación basado en *Graph Cut* crea un gráfico de la imagen donde cada píxel es un nodo conectado por bordes ponderados. Cuanto mayor sea la probabilidad de que los píxeles estén relacionados, mayor será el peso. El algoritmo corta la imagen de interés, a lo largo de los bordes débiles, logrando la segmentación de objetos en la imagen.<sup>(6)</sup>

Para el método se define:

- $X = (x_1, \dots, x_p, \dots, x_{|P|})$  como el conjunto de píxeles de la imagen a segmentar en la escala de grises.
- $P = (1, \dots, p, \dots, |P|)$  como el conjunto de índices de la imagen I.
- $N$  como el conjunto de pares no ordenados  $\{p, q\}$  bajo un sistema de vecindad de 4-(8-) donde  $p$  y  $q$  son dos píxeles vecinos.
- $L = (L_1, \dots, L_p, \dots, L_{|P|})$  como un vector binario cuyas componentes especifican asignaciones a píxeles de la imagen. Este valor indica si pertenece a *background* o *foreground* (*foreground* pertenecería a la estructura, y *background* al resto de la imagen). Es decir, este vector define la segmentación de la imagen.
- La función de energía a minimizar es:

- $X = (x_1, \dots, x_p, \dots, x_{|P|})$  como el conjunto de píxeles de la imagen a segmentar en la escala de grises.
- $P = (1, \dots, p, \dots, |P|)$  como el conjunto de índices de la imagen I.
- $N$  como el conjunto de pares no ordenados  $\{p, q\}$  bajo un sistema de vecindad de 4-(8-) donde  $p$  y  $q$  son dos píxeles vecinos.
- $L = (L_1, \dots, L_p, \dots, L_{|P|})$  como un vector binario cuyas componentes especifican asignaciones a píxeles de la imagen. Este valor indica si pertenece a *background* o *foreground* (*foreground* pertenecería a la estructura, y *background* al resto de la imagen). Es decir, este vector define la segmentación de la imagen.
- La función de energía a minimizar es:

(1)

$$E(L) = U(L) + \delta B(L)$$

Donde  $U(L)$  es el término unario, siendo  $U_p$  la penalización que se le da a  $p$ , *background* o *foreground*.

$$U(L) = \sum_{p \in P} U_p(L_p) \tag{2}$$

Y donde  $B(L)$  es el término de frontera, que tendrá una penalización mayor por discontinuidad entre  $p$  y  $q$ .

$$B(L) = \sum_{\{p,q\} \in N} B_{\{p,q\}} \varphi(L_p, L_q) \varphi(L_p, L_q) \begin{cases} 1, L_p = L_q \\ 0, \text{en otro caso} \end{cases} \tag{3}$$

Por último, el coeficiente  $\delta$  especifica la importancia de  $U(L)$  respecto  $B(L)$ .

El objetivo de *Graph Cut* es encontrar la segmentación que minimiza globalmente la energía de todas las posibles segmentaciones satisfaciendo algunas restricciones.

El algoritmo *expectation maximization* /

*maximization of the posterior marginal* (EM/MPM, por sus siglas en inglés) tiene como objetivo minimizar el valor esperado de la cantidad de píxeles mal clasificados. El algoritmo EM/MPM se basa en el algoritmo MPM para la segmentación y el algoritmo EM para la estimación de

parámetros.<sup>(7)</sup>

El algoritmo puede ser resumido en dos pasos. Para esto se considera que el elemento de un campo aleatorio  $X$  en la ubicación espacial  $s \in S$ , se denota como  $X_s$ . El campo de etiqueta se denota como  $X$  y la imagen observada como  $Y$ . Entonces,  $\theta$  es un vector no aleatorio cuyos elementos son los parámetros desconocidos de la función de densidad de probabilidad condicional de  $Y$  dada por  $X$ . Las muestras de los campos aleatorios se denotan como  $x$  y sus imágenes como  $y$ .

Entonces, en el primer paso, el algoritmo MPM se usa para obtener aproximaciones de las funciones de masa de probabilidad condicional marginal de  $X$ , usando las estimaciones de  $\theta$ . O sea, se estima  $p_{X_s|Y}(k|Y, \hat{\theta}^{(p-1)}) \forall s \in S$  y  $k = 1, \dots, L$ , usando una muestra de Gibbs (Geman, 1984 #12), y la siguiente ecuación:

$$p_{X_s|Y}(k|Y, \theta) \approx \frac{1}{n} \sum_{i=1}^n [1 - i(x_s^{(i)}, k)] \quad (4)$$

Donde

- $k$  es el conjunto de valores que puede tomar la variable aleatoria  $X$ ,  $k \in \{1, 2, \dots, L\}$ , y  $L$  es el número de diferentes clases u objetos en la imagen.
- $n$  es el número de iteraciones realizadas para la muestra de Gibbs.

En el segundo paso, el algoritmo EM se usa para actualizar la estimación de  $\theta$  usando los resultados del algoritmo MPM, o sea, se utiliza la estimación de  $p_{X_s|Y}(k|Y, \hat{\theta}^{(p-1)})$  obtenida en el primer paso, para obtener la aproximación de la estimación MPM de X y la aproximación de  $\theta$ , denotados  $\hat{x}_{MPM}^{(p)}$  y  $\hat{\theta}^{(p)}$  respectivamente, utilizando las siguientes ecuaciones.

$$\mu_k^{(p+1)} = \frac{1}{N_k^{(p+1)}} \sum_{s=1}^N y_s p_{X_s|Y}(k|Y, \theta^p) \tag{5}$$

$$\sigma_k^{2(p+1)} = \frac{1}{N_k^{(p+1)}} \sum_{s=1}^N (y_s - \mu_k^{(p+1)})^2 p_{X_s|Y}(k|Y, \theta^p) \tag{6}$$

$$N_k^{(p+1)} = \frac{1}{N_k^{(p+1)}} \sum_{s=1}^N p_{X_s|Y}(k|Y, \theta^p) \tag{7}$$

Donde:

- $p$  es el espacio parámetro de interacción.
- $N$  es el número total de píxeles en la imagen.
- $\mu$  y  $\sigma$  son la media y la varianza respectivamente
- $\theta^{(p)}$  es la estimación de  $\theta$  en la iteración  $pth$

Las imágenes utilizadas se obtuvieron de la base de datos de tomografía computarizada abdominal CHAOS\_Train\_Sets, de *Combined Healty Abdominal Organ Segmentation* (CHAOS, por sus siglas en inglés). Cada conjunto de datos en esta base corresponde a una serie de imágenes DICOM que pertenecen a un solo paciente. Los conjuntos de datos se recopilan de forma retrospectiva y aleatoria del *Picture Archiving and Communication System* (PACS, por

sus siglas en inglés) del DEU Hospital.

La base de datos contiene imágenes de TC de 40 pacientes diferentes. Estos pacientes son potenciales donantes de hígado, ya que tienen hígado sano (sin tumores, lesiones o cualquier otra enfermedad).

Se utilizaron imágenes adquiridas con tres escáneres diferentes: *Philips SecuraCT* con 16


detectores, un *Philips Mx8000 CT* con 64 detectores y un *Toshiba AquilionOne* con 320 detectores (todos equipados con la opción de CT en espiral). La orientación y alineación del paciente es la misma para todos los conjuntos de datos. Cada conjunto de datos consta de imágenes DICOM de 16 bits, con una resolución de 512x512 píxeles, espesor de corte entre 0,7-0,8 mm. y una distancia entre cortes de 3 a 3,2 mm. Esto corresponde a un promedio de 90 cortes por conjunto de datos (es decir, mínimo 77, máximo 105 cortes). En total, se cuenta con 1367 cortes tomográficos (imágenes 2D).

La evaluación de los resultados se realizó mediante la comparación con imágenes de referencia o *groundtruth*. Dentro de las distintas medidas para la evaluación supervisada se seleccionaron, para aplicar en este trabajo, el coeficiente de Jaccard, el coeficiente de Dice y la distancia de Vinet.

## RESULTADOS

Los métodos de segmentación utilizados arrojan diferentes resultados a partir de cuyo análisis se determinará cuál método de segmentación resultó ser el más eficaz en los experimentos realizados.


En la figura 1, se aprecia visualmente la efectividad del método *Graph Cut* para una de las imágenes de la base de datos. Los resultados obtenidos del proceso de segmentación pueden considerarse satisfactorios para las imágenes de TC utilizadas, ya que en todos los casos se segmentó la región deseada, incluso cuando la calidad de las imágenes es baja, se observa gran similitud entre la imagen segmentada y la máscara de referencia, como se aprecia en la figura. El nivel de detalles visuales es bueno y la reproducción de bordes permanece fiel a la máscara de referencia. (Fig. 1).




**Fig. 1** (a) Imagen original. (b) Máscara de referencia. (c) Imagen segmentada mediante el método de *Graph Cut*.

Los resultados obtenidos en la segmentación de las imágenes de TC por el método de EM/MPM, no siempre fueron satisfactorios. Gran parte de las imágenes seleccionadas son correctamente segmentadas como se muestra en la figura 2, donde se puede apreciar una buena similitud entre la imagen segmentada y la máscara de referencia, la reproducción de bordes es buena, al igual que el nivel de detalles. Pero varias

imágenes no fueron segmentadas correctamente como se presenta en la figura 3, esto ocurrió principalmente cuando el hígado presente en las imágenes a segmentar tiene una morfología más compleja o cuando existe una diferencia de contraste muy baja en la imagen. Este resultado cuestiona la eficacia del método para esta tarea en particular. (Fig. 2 y Fig. 3).




**Fig. 2** (a) Imagen original. (b) Máscara de referencia. (c) Imagen segmentada mediante el método de EM/MPM



**Fig. 3.** (a) Imagen original. (b) Máscara de referencia. (c) Imagen segmentada mediante el método de EM/MPM

En la figura 4 se puede observar la evaluación de la calidad de la segmentación con *Graph Cut* y EM/MPM a partir del coeficiente de Dice para las 36 imágenes seleccionadas para la prueba. (En la figura las imágenes son nombradas de la forma ia\_00b, donde a es el número del paciente y b es

el corte seleccionado). Se aprecia que existe una mayor fluctuación entre pacientes para el método EM/MPM que para *Graph Cut*. Es decir, el método *Graph Cut* es más preciso al obtener el contorno del hígado de cada paciente y por tanto más eficaz para la tarea planteada. (Fig. 4).



**Fig. 4.** Comportamiento del coeficiente de Dice para cada una de las imágenes.

En las tablas 1 y 2 se observan las medias por paciente del cálculo del coeficiente de Dice para los métodos *Graph Cut* y EM/MPM respectivamente. La media del coeficiente de Dice revela que en el método *Graph Cut* la segmentación fue buena, pues en todos los pacientes supera el valor de 0,90. En el caso del método de EM/MPM se puede observar un valor bajo en el paciente 5. En este caso fue donde se segmentaron estructuras no deseadas junto con

el hígado. Realizando una valoración visual de los datos obtenidos, con el cálculo de los coeficientes de Dice, (sin haber realizado el análisis estadístico), se puede decir que el método de segmentación que mejores resultados ofreció en este experimento fue *Graph Cut*. En cada uno de los pacientes la media del coeficiente de Dice para este método fue superior que en el método EM/MPM. (Tabla 1 y Tabla 2).

**Tabla 1.** Media para las seis imágenes de cada paciente del coeficiente de Dice (*Graph Cut*)

Pacientes	Valor Mínimo	Valor Máximo	Media	Desviación típica
1	0,862	0,977	0,933	± 0,047
2	0,929	0,980	0,959	± 0,016
3	0,846	0,978	0,935	± 0,050
4	0,877	0,967	0,933	± 0,042
5	0,886	0,975	0,931	± 0,033
6	0,934	0,969	0,954	± 0,014
<b>Total</b>			<b>0,941</b>	<b>± 0,036</b>




**Tabla 2.** Media para las seis imágenes de cada paciente del coeficiente de Dice (EM/MPM)

Pacientes	Valor Mínimo	Valor Máximo	Media	Desviación típica
1	0,706	0,955	0,893	± 0,094
2	0,889	0,944	0,917	± 0,019
3	0,746	0,918	0,837	± 0,067
4	0,846	0,955	0,918	± 0,047
5	0,721	0,973	0,877	± 0,093
6	0,824	0,939	0,897	± 0,040
<b>Total</b>			<b>0,887</b>	<b>± 0,069</b>

La figura 5 muestra la evaluación de la calidad de la segmentación con *Graph Cut* y EM/MPM a partir del coeficiente de Jaccard por cada imagen. Se aprecia igualmente, que existe una mayor

fluctuación por paciente para el método EM/MPM que para *Graph Cut* y que en general este último muestra mayor precisión y por ende eficacia para la tarea prevista. (Fig. 5).



**Fig. 5** Comportamiento del coeficiente de Jaccard para cada una de las imágenes.

En las tablas 3 y 4 se observan las medias por paciente del cálculo del coeficiente de Jaccard para los métodos *Graph Cut* y EM/MPM respectivamente. Realizando una valoración visual de los datos obtenidos con el cálculo de los

coeficientes de Jaccard, al igual que con el coeficiente de Dice, se pueden observar valores bajos para el paciente 5 en el método EM/MPM, mientras que los valores para el método *Graph Cut* superan siempre la media de 0,85. (Tabla 3 y Tabla 4).

**Tabla 3.** Media para las seis imágenes de cada paciente del coeficiente de Jaccard (*Graph Cut*)


Paciente	Valor Mínimo	Valor Máximo	Media	Desviación típica
1	0,757	0,954	0,878	± 0,,081
2	0,868	0,961	0,921	± 0,030
3	0,796	0,951	0,872	± 0,,058
4	0,781	0,936	0,876	± 0,073
5	0,796	0,951	0,872	± 0,058
6	0,868	0,961	0,921	± 0,030
<b>Total</b>			<b>0,897</b>	<b>± 0,055</b>

**Tabla 4.** Media para las seis imágenes de cada paciente del coeficiente de Jaccard (EM/MPM)

Pacientes	Valor Mínimo	Valor Máximo	Media	Desviación estándar
1	0,545	0,964	0,832	± 0,150
2	0,801	0,894	0,847	± 0,033
3	0,594	0,849	0,724	± 0,099
4	0,733	0,915	0,851	± 0,078
5	0,563	0,947	0,791	± 0,142
6	0,803	0,904	0,850	± 0,040
<b>Total</b>			<b>0,887</b>	<b>± 0,69</b>

La figura 6 muestra la evaluación de la calidad de la segmentación con *Graph Cut* y EM/MPM a partir del coeficiente de Vinet. En general, este coeficiente fue más sensible a la variabilidad de

los hígados de la muestra estudiada que los coeficientes de Dice y Jaccard. No obstante a eso, la fluctuación es menor para *Graph Cut* que para EM/MPM. (Fig. 6).



**Fig. 6** Comportamiento de la distancia de Vinet para cada una de las imágenes.

En las tablas 5 y 6 se observan las medias por paciente del cálculo de la distancia de Vinet para los métodos *Graph Cut* y EM/MPM respectivamente. Los resultados obtenidos en el cálculo de la distancia de Vinet se interpretan de forma diferente a los obtenidos con los coeficientes de Dice y Jaccard. Aquí mientras más pequeña es la distancia más precisa será la

segmentación de las imágenes, por existir menos diferencias entre referencia y segmentación. Por consiguiente, realizando una valoración visual de los datos, se puede decir que el método de segmentación *Graph Cut* proporciona distancias más pequeñas y ratifica su mayor eficacia para segmentar hígado. (Tabla 5 y Tabla 6).

**Tabla 5.** Media para las seis imágenes de cada paciente del coeficiente de Vinet (*Graph Cut*)

Pacientes	Valor Mínimo	Valor Máximo	Media	Desviación estándar
1	9,907	16,227	13,614	± 2,418
2	3,426	11,443	7,027	± 3,082
3	12,812	15,505	14,118	± 1,014
4	15,411	19,656	17,914	± 1,499
5	11,293	19,239	14,664	± 2,745
6	7,342	12,634	10,438	± 2,078
<b>Total</b>			<b>12,962</b>	<b>± 4,060</b>

**Tabla 6.** Media para las seis imágenes de cada paciente del coeficiente de Vinet (EM/MPM)

Pacientes	Valor Mínimo	Valor Máximo	Media	Desviación estándar
1	12,567	17,110	14,710	± 1,779
2	3,988	11,952	7,733	± 3,149
3	13,334	19,060	15,286	± 2,103
4	16,032	19,916	18,664	± 1,417
5	11,086	18,313	14,327	± 2,597
6	8,161	12,833	11,303	± 1,855
<b>Total</b>			<b>13,669</b>	<b>± 4,028</b>

Para realizar el análisis estadístico de los resultados se empleó el software SPSS-22, el método que presentó los mejores rangos para todos los coeficientes es *Graph Cut* (mayor para Dice y Jaccard y menor para Vinet) respectivamente.

## DISCUSIÓN

De los métodos de segmentación seleccionados e implementados con MATLAB en el presente estudio, *Graph Cut* y EM/MPM, el que mostró mayor precisión en la segmentación de imágenes de TC de hígado fue *Graph Cut*.

Según los coeficientes de Dice y Jaccard y la distancia de Vinet, se encontraron diferencias significativas en la calidad de la segmentación

con ambos métodos, siendo superior en *Graph Cut*.

Los métodos de corte gráfico demuestran un gran potencial por la ventaja de obtener óptimos globales y por su eficiencia práctica (utilizando buenos procesadores). Cuando se trata de segmentación hepática, otros autores<sup>(8,9,10)</sup> han apreciado que a veces el modelo de corte de gráfico estándar falla, bajo la circunstancia de ataduras seriamente borrosas e intensidades similares entre el hígado y sus órganos vecinos. Además, el modelo es sensible a los parámetros de la función de energía que son solo de información interactiva o estimación empírica. El tipo de imprecisiones que se ha mencionado no fue observado durante la implementación del *Graph Cut* en la presente investigación, a partir de la variante descrita, que supera el método estándar.

Masuda y cols.<sup>(11)</sup> proponen el método basado en la mejora del contraste adaptativo y EM / MPM para detectar tumores en imágenes de TC. El método propuesto resultó adecuado para imágenes de bajo contraste. Los resultados obtenidos fueron buenos, lo que coincide con los resultados obtenidos en esta investigación.

### Conflicto de intereses

Los autores declaran que no existe conflicto de intereses.

### Contribuciones de los autores

Conceptualización: Melanie Yusta Gómez, Marlen Pérez Díaz, Rubén Orozco Morales, Xiomara Plasencia Hernández.

Curación de datos: Melanie Yusta Gómez.

Análisis formal: Melanie Yusta Gómez, Marlen Pérez Díaz.

Investigación: Melanie Yusta Gómez.

Metodología: Marlen Pérez Díaz.

Software: Rubén Orozco Morales.

Supervisión, Marlen Pérez Díaz, Rubén Orozco Morales.

Validación: Marlen Pérez Díaz, Rubén Orozco Morales.

Visualización: Melanie Yusta Gómez.

Redacción – borrador original: Melanie Yusta Gómez, Xiomara Plasencia Hernández.

Redacción, revisión y edición: Marlen Pérez Díaz, Melanie Yusta Gómez.

### Financiación

Universidad Central Marta Abreu de las Villas. Villa Clara. Cuba.

### REFERENCIAS BIBLIOGRÁFICAS

1. Pham DL, Xu C, Prince JL. Arobo. Current methods in medical image segmentation. *Annu Rev Biomed Eng.* 2000 ; 2: 315-37.
2. Sharma N, Aggarwal LM. Automated medical image segmentation techniques. *J Med Phys.* 2010 ; 35 (1): 3-14.
3. Heimann T, Van Ginneken B, Styner MA, Arzhaeva Y, Aurich V, Bauer C, et al. Comparison and evaluation of methods for liver segmentation from CT datasets. *IEEE Trans Med Imaging.* 2009 ; 28 (8): 1251-65.
4. DeLong A, Osokin A, Isack HN, Boykov Y. Fast approximate energy minimization with label costs. *International Journal of Computer Vision.* 2012 ; 96 (1): 1-27.
5. Chen Y, Zhao W, Wang ZJPIC. Level set segmentation algorithm based on image entropy and simulated annealing. In: 1st International Conference on Bioinformatics and Biomedical Engineering, 2007 [Internet]. Wuhan: IEEE; 2007. [ cited 7 Dic 2021 ] p. 999-1003. Available from: <https://ieeexplore.ieee.org/document/4272743>.
6. Chen Y, Wang Z, Hu J, Zhao W, Wu Q. The domain knowledge based graph-cut model for liver CT segmentation. *Biomedical Signal Processing and Control.* 2012 ; 7 (6): 591-8.
7. Comer ML, Delp EJ, editors. Parameter estimation and segmentation of noisy or textured images using the EM algorithm and MPM estimation. 1st International Conference on Image Processing, 1994 [Internet]. Austin: IEEE; 1994. [ cited 7 Dic 2021 ] p. 650-54. Available from: <https://ieeexplore.ieee.org/document/413651>.
8. Christ PF, Elshaer MEA, Ettlinger F, Tatavarty S,

Bickel M, Bilic P, et al., editors. Automatic liver and lesion segmentation in CT using cascaded fully convolutional neural networks and 3D conditional random fields. In: International Conference on Medical Image Computing and Computer-Assisted Intervention, 2016 [Internet]. Ithaca: Cornell University; 2016. [ cited Dic 12 ] Available from: <https://arxiv.org/abs/1610.02177>.

9. Esneault S, Hraiech N, Delabrousse E, Dillenseger JL, editors. Graph cut liver segmentation for interstitial ultrasound therapy. In: 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society; 2007 [Internet]. New Jersey: IEEE; 2007. [ cited 12 Dic 2021 ] p. 5247-50. Available from: <https://ieeexplore.ieee.org/document/4353525>.

10. Massoptier L, Casciaro S, editors. Fully

automatic liver segmentation through graph-cut technique. In: 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society; 2007 [Internet]. New Jersey: IEEE; 2007. [ cited 12 Dic 2021 ] p. 5243-6. Available from: <https://ieeexplore.ieee.org/abstract/document/4353524>.

11. Masuda Y, Tateyama T, Xiong W, Zhou J, Wakamiya M, Kanasaki S, et al., editors. Liver tumor detection in CT images by adaptive contrast enhancement and the EM/MPM algorithm. In: 8th IEEE International Conference on Image Processing; 2011 [Internet]. New Jersey: IEEE; 2007. [ cited 12 Dic 2021 ] p. 1421-4. Available from: <https://ieeexplore.ieee.org/document/6115708>.