

INTEGRACIÓN DE CLUSTERING DIFUSO Y  
MODELOS DEFORMABLES PARA LA  
SEGMENTACIÓN DE IMÁGENES MÉDICAS

CARMEN ESCUDERO LEOZ Y MANUEL CORRALES

**Directora** Mariana del Fresno  
**Codirector** José Ignacio Orlando



Propuesta de trabajo final para la carrera de Ingeniería de Sistemas

---

## INTRODUCCIÓN Y MOTIVACIÓN

---

Los últimos avances tecnológicos en materia de captura y procesamiento de imágenes digitales han impactado de manera considerable en el área de la medicina, favoreciendo la exploración y análisis de modalidades médicas ampliamente difundidas en la práctica clínica, tales como las Tomografías Computadas (CT), las Resonancias Magnéticas (MRI), entre otras [Bankman, 2008].

Entre los numerosos aspectos a tener en cuenta para el desarrollo de aplicaciones de asistencia al diagnóstico o seguimiento de tratamientos médicos, uno de los más importantes tiene que ver con disponer de algoritmos de segmentación que permitan detectar regiones de interés dentro de la imagen o serie de imágenes involucradas en el estudio, para su posterior análisis [Pham et al., 2000].

La segmentación constituye una de las etapas más importantes dentro del pipeline de Procesamiento de Imágenes debido a que sus resultados condicionan significativamente las etapas posteriores relacionadas con la visualización y el análisis de información derivada. En general, la segmentación consiste en la identificación de regiones de interés en una imagen, con propósitos que varían de acuerdo a la aplicación particular. En la práctica médica, por ejemplo, consiste en un proceso clave para la detección de órganos (tales como el corazón, el hígado, el cerebro, etc.) o para distinguir tejidos (en el caso del cerebro, por ejemplo, materia gris, materia blanca y líquido cefalorraquídeo) [Yi et al., 2009] o lesiones patológicas (como tumores, hemorragias, etc.) [Deng et al., 2010].

Desde hace algunos años la segmentación constituye uno de los temas de investigación más difundidos en el área del procesamiento de imágenes médicas, y permanece en continua evolución [Corona et al., 2013, Qian et al., 2013, Del Fresno et al., 2009]. Existen numerosas soluciones computacionales para abordar este tipo de problemas, tanto automáticas como semiautomáticas o interactivas. En general, los algoritmos de segmentación pueden clasificarse según dos propiedades básicas: discontinuidad y similitud. Los primeros se caracterizan por la utilización de operadores derivativos, que permiten detectar cambios abruptos en los bordes entre los objetos; los basados en similitud, por su parte, intentan determinar regiones homogéneas en la imagen a partir de la integración de elementos con características similares [Deng et al., 2010]. Estos últimos pueden resultar triviales al aplicarse a imágenes simples en las que los objetos son homogéneos y contrastan significativamente con el resto. Sin embargo, en imágenes como las utilizadas en el ámbito médico, donde las estructuras suelen ser más complejas, esta tarea se vuelve mucho más difícil. Habitualmente, las imágenes médicas presentan inconvenientes tales como ruido, distorsiones, intensidades variables, artefactos, transiciones difusas entre objetos, etc., que provocan fallas en los métodos más tradicionales y obligan al desarrollo de estrategias más robustas.

El problema de la segmentación de imágenes tridimensionales (3D) se relaciona con el de la generación de mallas geométricas asociadas a las regiones de interés [Lorensen and Cline, 1987]. Las técnicas tradicionalmente utilizadas en el estado del arte suelen tener un comportamiento general aceptable, pero a menudo ocasionan

inconvenientes en casos en los que no hay una clara definición de los bordes en la imagen. Además, suelen generar mallas con un número innecesariamente elevado de polígonos (lo que perjudica la visualización utilizando técnicas de renderización o eleva significativamente el costo computacional de los cálculos o simulaciones que se realicen sobre ellas) o con irregularidades tales como huecos o regiones no conexas, a menudo no asociadas con las características del órgano o tejido real. Esto contribuye a la necesidad de algoritmos que permitan obtener mallas de superficie geoméricamente regulares y optimizadas.

Entre las distintas alternativas propuestas, los métodos de segmentación difusa se caracterizan por no brindar una segmentación unívoca, si no establecer probabilísticamente el nivel de confianza con el que un punto de la imagen pertenece a una determinada región de interés [Chuang et al., 2006]. En particular, los mismos proveen como resultado una imagen o volumen difuso por cada región de interés, donde cada punto representa la probabilidad de que el mismo pertenezca al objeto que se intenta detectar. Entre los enfoques de segmentación difusa más utilizados se distingue el de Fuzzy C-Means, que permite obtener los mapas probabilísticos de C regiones de interés a partir de la información característica de los mismos [Chaira, 2010]. La ventaja de estos métodos es que permiten la utilización de más de una única banda espectral como información de entrada, lo que facilita su traslado a problemas de segmentación multiespectral, donde las imágenes de entrada corresponden a las de un mismo paciente, pero obtenidas utilizando más de una modalidad de captura [Chen et al., 2010]. Sin embargo, sus resultados dependen en gran medida de la información característica de los clústeres con los que es inicializado, y requieren de etapas de postprocesamiento para su refinamiento y utilización [Li et al., 2011].

Otros de los métodos de segmentación más populares son los basados en modelos deformables, también conocidos como snakes o superficies activas, en su versión 3D [McInemey and Terzopoulos, 1999]. Los mismos se basan en la minimización de una función de energía asociada a una superficie continua, que se deforma elásticamente de acuerdo a la acción de un sistema de fuerzas, hasta alcanzar los límites de las regiones de interés. Además, se aplican sobre un dominio continuo, lo que permite reconstruir superficies suaves, con una precisión mayor a la de la imagen de entrada. Sin embargo, no soportan directamente cambios topológicos, y requieren una inicialización apropiada, complicando su adaptación a la segmentación de objetos de estructura compleja. Por otro lado, existen muy pocos enfoques en la bibliografía que propongan modificaciones a su definición original para incorporar información probabilística obtenida a través de estrategias de segmentación difusa [Shyu et al., 2012].

---

## OBJETIVO

---

El objetivo del trabajo es estudiar y desarrollar un enfoque híbrido de segmentación que permita la combinación de mapas probabilísticos obtenidos por Fuzzy C-Means con modelos deformables. En particular, se buscará diferenciar los tejidos de interés de la imagen a partir de una segmentación inicial, obtenida a través de un umbralado de los mapas probabilísticos obtenidos utilizando Fuzzy C-Means. Sobre esta región se extraerá una malla de superficie, que servirá como inicialización para un enfoque de modelos deformables que combine, para guiar su evolución, la información de intensidades de la imagen junto con la información provista por los mapas probabilísticos. El resultado será una malla refinada que representa a la región de interés, y que puede ser utilizada tanto para la generación de vistas tridimensionales como para posteriores cálculos, simulaciones o análisis.

Como resultado final, el enfoque híbrido desarrollado será volcado en una herramienta interactiva que posibilite el análisis de los resultados. Mediante la misma se realizarán pruebas sobre casos artificiales simulados, de los cuales se conoce la segmentación de referencia, y sobre diferentes estudios reales, lo que permitirá analizar de manera general los resultados y evaluar combinaciones óptimas de parámetros.

---

## PLAN DE TRABAJO

---

1. Relevamiento bibliográfico sobre las características de modalidades de captura y enfoques de segmentación difusos, en especial basados en Fuzzy C-Means y su combinación con Modelos Deformables.
2. Estudio e implementación del enfoque de Fuzzy C-Means.
3. Búsqueda y estudio sobre un banco de imágenes médicas y evaluación de los resultados obtenidos.
4. Análisis de estrategias de umbralado y postprocesamiento para la extracción de mallas de superficie cerradas a partir de los volúmenes difusos obtenidos por Fuzzy C-Means.
5. Estudio e implementación de estrategias de incorporación de información difusa en Modelos Deformables para completar la segmentación.
6. Análisis, validación y generación de resultados en base a imágenes simuladas y casos reales en formato estándar DICOM y MHA.
7. Estudio de sensibilidad de los algoritmos de segmentación implementados y análisis de resultados. Comparación respecto a otros enfoques.
8. Redacción del informe correspondiente al trabajo realizado (a realizar en paralelo durante las etapas anteriores).

---

## BIBLIOGRAFÍA

---

- Isaac Bankman. *Handbook of medical image processing and analysis*. Academic press, 2008.
- Tamalika Chaira. Intuitionistic fuzzy segmentation of medical images. *Biomedical Engineering, IEEE Transactions on*, 57(6):1430–1436, 2010.
- Yen-Sheng Chen, Shao-Hsien Chen, and Chun-Chih Chang. Comparison of multispectral image processing techniques to brain mr image classification between fuzzy c-mean method and geodesic active contours of caselles level set method. In *Computational Collective Intelligence. Technologies and Applications*, pages 491–498. Springer, 2010.
- Keh-Shih Chuang, Hong-Long Tzeng, Sharon Chen, Jay Wu, and Tzong-Jer Chen. Fuzzy c-means clustering with spatial information for image segmentation. *computerized medical imaging and graphics*, 30(1):9–15, 2006.
- Enrique Corona, Jason E Hill, Brian Nutter, and Sunanda Mitra. An information theoretic approach to automated medical image segmentation. In *SPIE Medical Imaging*, pages 86693Q–86693Q. International Society for Optics and Photonics, 2013.
- M Del Fresno, M Vénere, A Clausse, et al. A combined region growing and deformable model method for extraction of closed surfaces in 3d ct and mri scans. *Computerized Medical Imaging and Graphics*, 33(5):369, 2009.
- Wankai Deng, Wei Xiao, He Deng, and Jianguo Liu. Mri brain tumor segmentation with region growing method based on the gradients and variances along and inside of the boundary curve. In *Biomedical Engineering and Informatics (BMEI), 2010 3rd International Conference on*, volume 1, pages 393–396. IEEE, 2010.
- Bing Nan Li, Chee Kong Chui, Stephen Chang, and SH Ong. Integrating spatial fuzzy clustering with level set methods for automated medical image segmentation. *Computers in Biology and Medicine*, 41(1):1–10, 2011.
- William E Lorensen and Harvey E Cline. Marching cubes: A high resolution 3d surface construction algorithm. In *ACM Siggraph Computer Graphics*, volume 21, pages 163–169. ACM, 1987.
- T McNemey and Demetri Terzopoulos. Topology adaptive deformable surfaces for medical image volume segmentation. *Medical Imaging, IEEE Transactions on*, 18(10):840–850, 1999.
- Dzung L Pham, Chenyang Xu, and Jerry L Prince. Current methods in medical image segmentation 1. *Annual review of biomedical engineering*, 2(1):315–337, 2000.
- Xiaohua Qian, Jiahui Wang, Shuxu Guo, and Qiang Li. An active contour model for medical image segmentation with application to brain ct image. *Medical physics*, 40:021911, 2013.

Kuo-Kai Shyu, Van-Truong Pham, Thi-Thao Tran, and Po-Lei Lee. Global and local fuzzy energy-based active contours for image segmentation. *Nonlinear Dynamics*, 67 (2):1559–1578, 2012.

Zhao Yi, Antonio Criminisi, Jamie Shotton, and Andrew Blake. Discriminative, semantic segmentation of brain tissue in mr images. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2009*, pages 558–565. Springer, 2009.