

Segmentación de imágenes digitales mediante técnicas de *clustering* complementadas con técnicas de crecimiento de regiones

Digital Image Segmentation Using Clustering Techniques with Region-Growing Algorithms

Gustavo Toranzo Lorca

Universidad de las Ciencias Informáticas, Cuba

✉gtoranzo@uci.cu

Osvaldo Pereira Barzaga

Universidad de las Ciencias Informáticas, Cuba

✉opereira@uci.cu

José Arzola Ruiz

Instituto Superior Politécnico José Antonio Echeverría, Cuba

✉jararzola@ceter.cujae.edu.cu

ABSTRACT

This paper proposes a solution to the problem of digital image segmentation based on clustering techniques. K-means and fuzzy k-means are clustering algorithms detailed within this study. We propose novel modifications to k-means and fuzzy k-means algorithms to vary objective functions and to use color difference as a distance measure. These new algorithms are guaranteed to obtain the same results as the originals while considerably reducing the execution time. Pixel growing is used to obtain connected structures in the results of clustering algorithms.

KEYWORDS: clustering; fuzzy k-means; image segmentation; k-means.

La segmentación de imágenes, según González y Wood (2001), puede definirse como la agrupación de píxeles con intensidades de colores similares en un espacio paramétrico. Si el dominio de la imagen está dado por I el problema de la segmentación se reduce a encontrar N conjuntos S_k que cumplan:

$$(1) \quad \begin{aligned} D &= \bigcup_{k=1}^n S_k \\ S_k \cap S_j &= \emptyset \text{ para } k \neq j \\ S_k &\text{ está conectado.} \end{aligned}$$

La anterior es una etapa fundamental en el análisis y el procesamiento de imágenes, especialmente en el caso de las imágenes médicas digitales (DICOM), obtenidas de las modalidades de resonancia magnética (RM) y tomografía axial computarizada (TAC).

Situación actual

Las metodologías clásicas de segmentación de imágenes incluyen métodos de umbralización, detección de bordes e identificación de regiones (Coto, 2003); sin embargo, estos han mostrado poca eficiencia ante la presencia de ruido en las

imágenes, son computacionalmente costosos y requieren una elevada interacción por parte del usuario con el objetivo de obtener los resultados con la calidad deseada.

En los últimos años se han propuesto numerosos métodos de segmentación basados en diferentes ramas de las matemáticas, con velocidades de procesamientos mayores y más flexibles que las técnicas clásicas de segmentación de imágenes. Entre ellos, los algoritmos basados en el agrupamiento participacional (del inglés *clustering*), que descomponen el conjunto de objetos de tal modo que los objetos de un mismo grupo son más similares unos a otros que con objetos de otros grupos (Campos, 2009).

Clustering: K-means y Fuzzy K-means

Los algoritmos de agrupamiento utilizan métricas (distancia euclídea, distancia Manhattan, distancia de Mahalanobis y distancia Chord) como medidas de similitud. Esto es fundamental, pues indica a qué grupo pertenece un determinado elemento, que debe estar definido en el espacio de características de los objetos que se van a agrupar (Jain, Murty y Flynn, 1999). En el caso particular de la segmentación de imágenes, los objetos son los píxeles, y las características, el color (en escala de grises [0,255]) y la posición (x, y) del píxel dentro

de la imagen. Hasta el momento se han propuestos varios algoritmos de agrupación de píxeles (Jain, Murty y Flynn, 1999), entre los que podemos encontrar el *K-means* y el *fuzzy K-means* (Oliva et al., 2001).

K-means

Busca minimizar una función objetivo (Ecuación 2), donde SSE es la suma del cuadrado de los errores, C_i es el i -ésimo clúster de la partición, k es el número de clústeres y $d(x, C_i)$ es la medida de disimilitud o distancia entre el elemento x y el clúster C_i :

$$(2) \quad SSE = \sum_{i=1}^k \sum_{x \in C_i} d(x, C_i)^2$$

Fuzzy K-means

Por otro lado, *fuzzy K-means* (también llamado *fuzzy C-means*) es una extensión del *K-means*. Mientras este último encuentra particiones para las que un punto pertenece a un solo clúster, *Fuzzy K-means* es un método estadísticamente formalizado que encuentra k clústeres donde un punto puede pertenecer a más de un clúster con cierto valor de pertenencia (Jain, Murty y Flynn, 1999).

Como el *K-means*, *fuzzy K-means* trabaja con aquellos objetos que pueden ser representados en un espacio n -dimensional con una medida de distancia definida (Jain, Murty y Flynn, 1999), a fin de minimizar una función objetivo (Ecuación 3).

$$(3) \quad SSE(M, C) = \sum_{i=1}^n \sum_{j=1}^k m_{ij}^\phi d_{ij}^2$$

Sujeto a:

$$\sum_{j=1}^k m_{ij} = 1 \quad i = 1, 2, \dots, n$$

$$\sum_{i=1}^n m_{ij} \neq 0 \quad j = 1, 2, \dots, k$$

$$m_{ij} \in [0, 1]$$

Donde $SSE(M, C)$ es la suma del cuadrado de los errores dentro de las clases, m es la matriz ($n \times k$) de pertenencia a los grupos y cumple que $m_{ij} = 1$ si el elemento i pertenece totalmente al clúster j y $m_{ij} = 0$, en caso contrario; C es la matriz ($k \times p$) de centro de las clases, donde p es el número de componentes del espacio, ϕ es el grado de imprecisión de la solución (del inglés *fuzziness exponent*) y d_{ij}^2 es el cuadrado de la distancia entre el elemento i y el centro representativo del clúster j .

Aun cuando los algoritmos de agrupamiento necesitan conocer de antemano la cantidad inicial de clústeres, han demostrado ser más veloces que los algoritmos clásicos de segmentación referenciados en la bibliografía consultada. Sin embargo, la demora en el proceso de segmentación puede ser del orden de las horas para grandes volúmenes de datos, como lo suelen ser los cientos de DICOM de resolución 512×512 y con 8 bits de profundidad de color, obtenidas a partir del estudio realizado a un paciente en algunas de las modalidades de TAC o RM. Además, la calidad de los resultados de la seg-

mentación dependerán en gran medida de la selección de la métrica de similitud que se escoja para reconocer cuándo un píxel corresponde a un clúster determinado.

Solución propuesta

En consecuencia, se propone una optimización de la función objetivo de los algoritmos *K-means* y *fuzzy K-means*, planteando como métrica la diferencia de color, con el objetivo que los algoritmos converjan más rápido a la solución.

Optimización del K-means

La mejora consiste en calcular inicialmente el histograma de la imagen (Sonka, Hlavac y Boyle, 1993) y obtener la frecuencia de ocurrencia de cada color f_i . Luego, en la ecuación de actualización de los centroides cada color es multiplicado por su frecuencia de ocurrencia en la imagen original, a fin de garantizar que la contribución de los píxeles con este color ejerza una influencia en el centroide de acuerdo con su frecuencia de aparición en la imagen (Ecuación 4).

$$(4) \quad C = \frac{\sum_{i=1}^n p_i * f_i}{\sum_{i=1}^n f_i}$$

Donde n es la cantidad de elementos que pertenece al clúster, p_i es la intensidad en escala de grises y f_i es la frecuencia de ocurrencia del color del píxel i perteneciente al clúster. Queda como función objetivo por minimizar la Ecuación 5, donde f_p es la frecuencia de aparición del color i y $d(p, C_i)^2$ es la distancia del color del píxel al centroide del clúster.

$$(5) \quad SSE = \sum_{i=1}^k \sum_{p \in C_i} f_p d(p, C_i)^2$$

Optimización de fuzzy K-mean

El algoritmo *fuzzy K-means* también fue modificado con el mismo objetivo que el *K-means*. En esencia, la modificación realizada es la misma, pero en este caso en particular la fórmula del cálculo de los centroides es:

$$(6) \quad C = \frac{\sum_{i=1}^n m_i^\phi p_i f_i}{\sum_{i=1}^n m_i^\phi f_i}$$

Y la función objetivo que se va a minimizar quedaría planteada como:

$$(7) \quad SSE=(M,C)=\sum_{i=1}^n \sum_{j=1}^k m_{ij}^{\varphi} f_i d_{ij}^2$$

Integración con el *pixel growing*

Por otro lado, resulta importante en casos especiales proveer la obtención de clústeres en los cuales todos sus elementos estén conectados. Para ello se propone aplicar un método de crecimiento de regiones (Pereira y Kindelan, 2009) a los resultados del proceso de agrupamiento y así una clasificación final en estructuras conexas (Fig. 1).

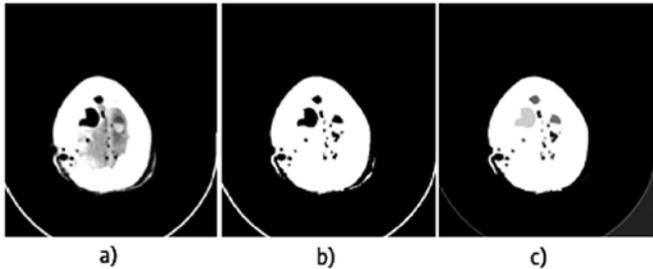


Figura 1. Pixel growing aplicado a los resultados obtenidos del proceso de clustering

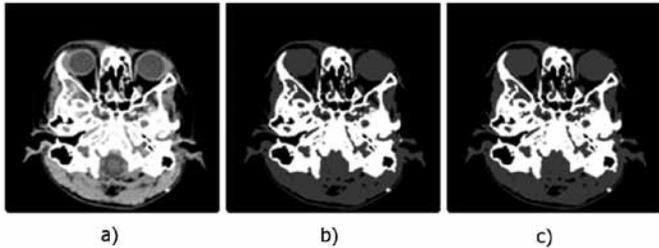


Figura 2. (a) Imágenes médica original, (b) segmentada con K-means, (c) segmentada con K-means optimizado

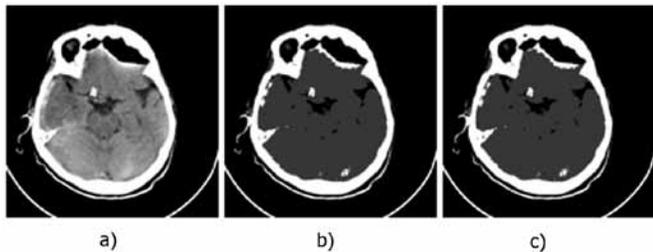


Figura 3. (a) Imágenes médica original, (b) segmentadas con fuzzy K-means (c) segmentada con fuzzy K-means optimizado

Resultados experimentales

En las pruebas realizadas a los algoritmos propuestos se utilizaron imágenes DICOM (de resolución 512×512 y 8 bits de profundidad del color) como juegos de datos fundamentales. En las figs. 2 y 3 se observa que luego de aplicar los algoritmos *K-mean* y *fuzzy K-mean* optimizados se obtiene la misma salida del proceso de clusterización que los algoritmos en su variante clásica. Sin embargo, los tiempos de ejecución en un PC Intel

Pentium 4 a 3,00 GHz con 1 GB de RAM y sistema operativo Ubuntu Desktop 9.10 i386 fueron menores que los obtenidos con los algoritmos en su variante clásica (tablas 1 y 2).

Imagen	Algoritmo	Tiempo (s)	Clústeres	Inicialización de centroide	Métrica
Fig. 2a	<i>K-means</i>	2,986	3	Frecuencia	Color
Fig. 2a	<i>K-means optimizado</i>	0,079	3	Frecuencia	Color

Tabla 1. Resultados de ejecución de los algoritmos *K-means* y *K-means optimizado*

Imagen	Algoritmo	Tiempo (s)	Clústeres	Exponente difuso	Error máximo	Inicialización de centroide	Métrica
Fig. 3a	<i>Fuzzy K-means</i>	6,590	3	1,1	0,001	Frecuencia	Color
Fig. 3a	<i>Fuzzy K-means optimizado</i>	0,091	3	1,1	0,001	Frecuencia	Color

Tabla 2. Resultados de ejecución de los algoritmos *fuzzy K-means* y *fuzzy K-means optimizado*

Discusión

La mejora presentada ofrece la garantía de disminuir el tiempo de ejecución de los algoritmos *K-means* y *fuzzy K-means*. En el peor de los casos el tiempo de procesamiento sería el mismo, pero este caso solo se presenta en imágenes pequeñas donde la cantidad de píxeles sea menor o igual a 256, que es la cantidad de colores diferentes que pueden ser representados en la escala de grises. La disminución temporal del procesamiento de los algoritmos mejorados, en correspondencia con las versiones clásicas, aumenta a medida que la cantidad de datos se hace mayor, debido a la redundancia de los colores.

La clasificación obtenida a través de los algoritmos mejorados es igual a la realizada por los algoritmos originales para cualquier juego de datos, excepto para imágenes de entrada que presenten menor cantidad de colores que la cantidad de clústeres seleccionados inicialmente. En este caso las versiones originales serían forzadas a realizar una partición arbitraria y las versiones mejoradas no podrían lidiar con este juego de datos.

La solución propuesta puede aplicarse a otras modalidades de imágenes en escala de grises adquiridas a partir de otros dispositivos. Actualmente la Universidad de las Ciencias Informáticas cuenta con un *software* de visualización médica tridimensional, que en uno de sus módulos implementa la optimización propuesta para la segmentación de series DICOM.

A pesar de los esfuerzos realizados y que los resultados alcanzados sean en buena medida una solución eficaz para el problema de la segmentación de imágenes, aún quedan aspectos importantes y con una complejidad elevada que requieren la continuidad de la obra. Entiéndase por esto trabajar basándose en métodos que automaticen el cálculo de la cantidad inicial de clústeres, pues este es un parámetro que los algoritmos tratados necesitan conocer a priori; así como perfeccionar la inicialización de los centroides, mientras más de estos valores se aproximen al óptimo, menos iteración en el proceso de convergencia realizará el algoritmo.

Conclusiones

La adaptación propuesta de los algoritmos *K-means* y *fuzzy K-means* al tema de la segmentación de imágenes médicas digitales ofrece una considerable reducción del tiempo de ejecución en comparación con sus variantes clásicas, pues el algoritmo *K-means* es un algoritmo de *clustering* particional muy utilizado en grandes cantidades de datos, por su rapidez de convergencia, del cual hereda estas mismas características el *fuzzy K-means*.

En busca de suplir la desventaja de los algoritmos vistos de no poder producir clústeres conectados se propone usar un método de crecimiento de regiones *pixel growing*, que produce clústeres conexos para ser aplicados al resultado de los algoritmos de *clustering*, método que a su vez elimina la dificultad de elección de las semillas en el inicio del algoritmo de crecimiento de regiones.

Agradecimientos

Por su colaboración en este trabajo, a los revisores de la Sociedad Iberoamericana de Gráfica Digital (Sigradi), al Proyecto VISMEDIC, a la Universidad de las Ciencias Informáticas y al Instituto Superior Politécnico José Antonio Echeverría.

Referencias

- Campos, M. G. (2009). *Aplicación de técnicas de clustering para la mejora del aprendizaje*. Madrid: Universidad Carlos III de Madrid.
- Coto, E. (2003). *Métodos de segmentación de imágenes médicas*. Caracas: Universidad Central de Venezuela.
- González, R. C. y Wood, R. E. (2001). *Digital image processing*. New Jersey: Prentice Hall.
- Jain, A. K., Murty, M. N. y Flynn, P. J. (1999). Data clustering: a review. *ACM Computing Surveys*, 265-317.
- Oliva, F., Cáceres, M., Font, X. y Cuadras, C. M. (2001). *Contribuciones desde una perspectiva basada en proximidades al Fuzzy K-means Clustering*. Documento procedente del XXVI Congreso Nacional de Estadística e Investigación Operativa, 1-10.
- Pereira, O. y Kindelan, R. (2009). Reconstrucción tridimensional de modelos anatómicos a partir de imágenes médicas digitales. *Informática en Salud*, 2-6.
- Sonka, M., Hlavac, V. y Boyle, R. (1993). *Image processing: analysis and machine vision*. s. l.: Capmam and Hall Computing.