

Segmentación Automática de Imágenes de Resonancia Magnética Cerebrales en T1

M. P. Zamudio^{1,*}, F. A. Alba,¹ M. O. Méndez¹, O. R. Marrufo²

¹ Facultad de Ciencias, Universidad Autónoma de San Luis Potosí, San Luis Potosí, S.L.P., México

² Departamento de Neuroimagen, Instituto Nacional de Neurología y Neurocirugía MVS, Cd.Mx., México

* mel.zaart@alumnos.uaslp.edu.mx

Resumen— Una de las técnicas más utilizadas en el procesamiento digital de imágenes es la segmentación, la cual consiste en la extracción de áreas de interés. Esta técnica tiene aplicaciones importantes en la medicina, particularmente, el estudio del cerebro mediante imágenes de resonancia magnética se ha convertido en un aspecto indispensable para el diagnóstico y planificación de tratamiento de enfermedades. Existen diversos algoritmos de segmentación del cerebro, sin embargo, la mayoría de ellos dependen de la interacción del usuario, son sensibles al ruido o utilizan cálculos muy complejos. En este trabajo se plantea un algoritmo automático que inicialmente aísla el cerebro de materias extra-cerebrales mediante operaciones morfológicas sencillas, facilitando su posterior segmentación de materia gris y blanca mediante un método probabilístico. El algoritmo presentó una eficacia del 98.668 % en el aislamiento del cerebro e índices SD 7% mejores que los obtenidos con K-medias, un método basado en intensidades.

Palabras clave— **cerebro, campos de Markov, GMMF, MRI, operaciones morfológicas, segmentación.**

I. INTRODUCCIÓN

La segmentación es una técnica que permite extraer regiones (grupos de píxeles) u objetos dentro de una imagen, donde cada región es homogénea en relación a una característica determinada como: el color, el nivel de intensidad o la textura [1]. Una de las principales aplicaciones de la segmentación de imágenes se encuentra en el campo de la medicina, ya que éste cuenta con muchos sistemas de imagenología como la resonancia magnética, la tomografía o los rayos X.

La resonancia magnética es una técnica no invasiva que produce imágenes anatómicas tridimensionales en escala de grises. Se basa en una tecnología sofisticada y de gran precisión que no utiliza radiación ionizante, la cual estimula y detecta el cambio en la dirección del eje de rotación de protones de hidrógeno presentes en las moléculas de agua y grasa de los tejidos vivos [2].

Los recientes avances en el diseño de sistemas de resonancia magnética han resultado en mejoras significativas en las áreas anatómica, funcional y dinámica, proveyendo una creciente gama de conjuntos de datos multispectrales que contienen características importantes para la segmentación y clasificación de tejidos [3]. Por esta razón, la segmentación

de MRI se está convirtiendo en una técnica de procesamiento de imágenes cada vez más importante.

En estudios clínicos del cerebro, localizar ciertos tejidos se ha convertido en un aspecto primordial para el diagnóstico y tratamiento de enfermedades como convulsiones, demencia, esclerosis múltiple, aneurismas, cáncer o accidentes cerebrovasculares. Estas enfermedades manifiestan edemas, necrosis, tejido cicatricial o tumores [4], por lo que definir el tamaño del tejido debe llevarse a cabo con la mayor precisión posible. En algunos estudios, como en los de amígdala e hipocampo [5] las imágenes de cerebro siguen siendo investigadas y segmentadas por médicos expertos rebanada por rebanada debido a su apariencia amorfa, de modo que se convierte en una tarea de intensa labor y que consume horas. Por esta razón, el objetivo del trabajo es el desarrollo de un método automático para la segmentación de imágenes volumétricas de resonancia magnética de la cabeza en materia: gris, blanca y extra-cerebral, todo en cuestión de minutos.

II. METODOLOGÍA

Para las pruebas se utilizaron 2 tipos de imágenes: sintéticas y reales.

Las imágenes sintéticas fueron obtenidas de BrainWeb: Simulated Brain Database [6]. Esta base de datos contiene un conjunto de imágenes producidas por un simulador de MRI, que permite a los usuarios controlar varios parámetros. Específicamente las imágenes fueron ponderadas en T1, con dimensiones de 121×187×181 y grosor de corte de 1 mm.

Las imágenes reales fueron adquiridas en un equipo de 3T (Excite 3T HDX, General Electric Medical Systems, Milwaukee, USA), con una antena de 8 canales de cabeza. Ponderadas en T1, se adquirieron con los siguientes parámetros: 3D-SPGR, TR=5.6 ms, TE= 13 ms, dimensiones de 512×512×120 y grosor de corte de 1.2 mm.

Para lograr la segmentación es necesario aislar primero la región correspondiente únicamente a materia cerebral de las materias extra-cerebrales para posteriormente clasificar sus componentes en materia gris y materia blanca.

A. Aislado del Cerebro

Consiste básicamente en la conversión de la imagen en escala de grises a su equivalente binaria, la cual será

manipulará mediante operaciones morfológicas para eliminar las estructuras que no son de interés.

1) *Binarización de la imagen*: Para la selección correcta del umbral de binarización, se ajustó un modelo de mezcla de 3-Gaussianas al histograma de la imagen correspondiente. La selección de tres Gaussianas se debe a que los histogramas de la mayoría de las imágenes se ajustaban a éste modelo. El valor mínimo entre las dos primeras Gaussianas indica el punto de diferenciación entre lo que podría tratarse de fondo e información en primer plano, por este motivo se seleccionó ese valor como umbral.

2) *Homogenización de la imagen y eliminación de estructuras pequeñas*: Para cada voxel de la imagen volumétrica se toma un vecindario-26 de $3 \times 3 \times 3$ para asegurar una buena correspondencia. Se coteja cuántos de sus 26 vecinos poseen un valor de 1, si el total resulta mayor al umbral preestablecido el voxel toma el valor de 1, 0 en caso contrario. De esta forma se logra reducir el ruido eliminando tanto agujeros como estructuras que no sean significantes.

3) *Asignación de etiquetas por conectividad y clasificación*: El aislado del cerebro implica detectar los objetos o regiones existentes en la imagen para eliminar las consideradas como materias extra-cerebrales. Esto se logra buscando un voxel (semilla) dentro de la imagen 3-D y se le asigna una etiqueta. Posteriormente, mediante un vecindario-26 se realiza el barrido y etiquetado de sus adyacentes distintos del fondo, de forma que se etiqueten todos los voxeles conectados en la región que contiene a la semilla. Estos dos pasos se repiten hasta que todos los voxeles de la imagen hayan sido etiquetados. Al final se conserva únicamente el objeto de mayor volumen el cual corresponde a materia cerebral.

4) *Recomposición del cerebro mediante dilatación*: Durante el proceso de binarización y homogenización existe una erosión de la máscara binaria y por lo tanto una pérdida de información. Para recuperar esta información, se aplica una operación de dilatación la cual permitirá recomponer la morfología original de la imagen.

Ya que la estructura del cerebro en su mayoría es curva, la dilatación se basa en la utilización de un elemento estructural en forma de disco de radio r . Se identifica cada pixel de la imagen distinto de cero el cual es llamado pixel central u origen y alrededor de este se considera un vecindario con valores binarios verdaderos del tamaño del elemento estructural. Una vez que se cuenta con la máscara binaria dilatada, ésta se multiplica por la imagen volumétrica original para obtener la imagen en escala de grises del cerebro aislado.

B. Clasificación de materias cerebrales

Ya obtenida la imagen volumétrica del cerebro aislado, se procede a calcular los parámetros de inicialización del algoritmo mediante K-medias [8] y se procede segmentar el cerebro en materia gris y materia blanca.

5) *Segmentación mediante Campos Markovianos de Medidas Gaussianas (GMMF)*: Considerando al conjunto de etiquetas de los pixeles como un Campo Aleatorio de Markov, es decir, como un conjunto de variables aleatorias independientes e idénticamente distribuidas [7], la probabilidad de etiquetar cada dato dependerá de las etiquetas de sus vecinos. Para un sistema de vecindad de primer orden (4 vecinos), la similitud entre el pixel central y sus vecinos tendrá un costo asociado λ . Sabiendo esto, la probabilidad de pertenencia a una clase para cada pixel se puede calcular como:

$$p_k(\vec{x}) = \frac{v_k(\vec{x}) + \lambda \sum_{\vec{y} \in N_{\vec{x}}} p_k(\vec{y})}{1 + \lambda |N_{\vec{x}}|} \quad (1)$$

Donde \vec{x} representa el vector de coordenadas espaciales de cada pixel, $v_k(\vec{x})$ la verosimilitud, es decir, qué tan bien se ajustan los datos a una clase en observación, $p_k(\vec{y})$ la probabilidad de pertenencia a una clase k de cada vecino \vec{y} y $|N_{\vec{x}}|$ el número de vecinos de \vec{x} , en este caso 4.

Tomando en cuenta que las imágenes de resonancia magnética presentan ciertas inhomogeneidades, el nivel de intensidad de cada pixel de la imagen y el ruido presente en él se puede aproximar como una distribución normal [7]. Partiendo de este modelo de observación Gaussiano, la verosimilitud se define como:

$$\hat{v}_k(\vec{x}) = \frac{1}{\sqrt{2\pi}\sigma_k} \exp\left\{-\frac{(f(\vec{x}) - \mu_k)^2}{2\sigma_k^2}\right\} \quad (2)$$

Donde $f(\vec{x})$ representa el nivel de intensidad de cada pixel y μ_k y σ_k^2 la media y varianza respectivamente, de cada clase k presente en la imagen.

Normalizando la verosimilitud se obtiene:

$$v_k(\vec{x}) = \frac{\hat{v}_k(\vec{x})}{\sum_i \hat{v}_i(\vec{x})} \quad (3)$$

Una vez que se ha calculado $p_k(\vec{x})$, a cada dato \vec{x} se le asigna la etiqueta que obtuvo la mayor probabilidad; es decir:

$$t(\vec{x}) = \arg \max_k \{p_k(\vec{x})\} \quad (4)$$

III. RESULTADOS

Para demostrar la conveniencia del algoritmo se evaluó su desempeño, por lo que fue necesario contar con imágenes sintéticas de etiquetas conocidas. Además, estas imágenes se modelaron a un caso cercano al real agregando distintos niveles de ruido Gaussiano. Finalmente se aplicó el algoritmo a imágenes reales.

A. Imágenes Sintéticas

Como primer paso se evaluó el aislado del cerebro. Para esto, se compararon los pixeles clasificados como cerebro

(materia gris + materia blanca) mediante el algoritmo, con los píxeles clasificados como cerebro de la imagen patrón y se calculó el porcentaje de eficacia mediante (6).

$$\% \text{ Eficacia} = \frac{\# \text{ píxeles bien clasificados}}{\# \text{ total de píxeles}} \times 100. \quad (6)$$

La Fig. 1 muestra la comparación de una rebanada de la imagen 3-D con el patrón en cuanto al aislado del cerebro, donde se utilizó un elemento estructural de $r=1$ y se obtuvo una eficacia del 98.668%.

Después se llevó a cabo la segmentación de materia gris y materia blanca y se evaluó la clasificación de materias cerebrales mediante el coeficiente de Sorensen-Dice, el cual está definido como:

$$SD = \frac{2|A \cap B|}{|A| + |B|} \quad (7)$$

Donde: $|A \cap B|$ se interpreta como el número de píxeles bien clasificados como materia-x, $|A|$ como el número de píxeles pertenecientes a materia-x estimados por el algoritmo y $|B|$ como el número de píxeles pertenecientes a materia-x reales (imagen patrón). Estos coeficientes fueron de 0.986 para materia blanca y 0.932 para materia gris. Los resultados de la segmentación se pueden observar en la Fig. 2.



Fig. 1. Rebanadas de la máscara binaria del cerebro de la imagen patrón (izquierda) y la máscara binaria del cerebro estimada con el algoritmo para un caso sin ruido (derecha).

Los porcentajes de eficacia se calcularon para cada nivel de ruido y se registraron en la siguiente tabla.

TABLA 1. EFICACIA DEL AISADO DEL CEREBRO

Ruido (%)	Eficacia (%)
0	98.668
1	98.667
3	98.650
5	98.554
7	98.333
9	98.038

Se puede observar que la variación es casi nula a pesar de presencia de distintos niveles de ruido, por lo que el aislado del cerebro es la etapa del algoritmo con mejor desempeño.

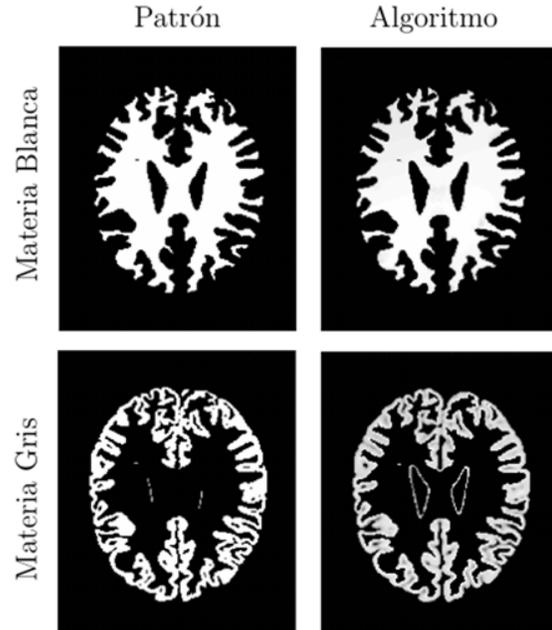


Fig. 2. Segmentación de materia blanca y materia gris de la imagen patrón mediante Campos Markovianos de Medidas Gaussianas con un parámetro de regularización $\lambda = 0$.

Para la segmentación por GMMF se utilizaron parámetros de regularización $\lambda = 0$ para ruidos del 1% y 3%, $\lambda = 0.2$ para ruido del 5%, $\lambda = 0.4$ para ruido del 7% y $\lambda = 0.5$ para ruido del 9%. Al igual que el aislado del cerebro, para cada nivel de ruido se calcularon los índices Sorensen-Dice de materia gris y blanca y se compararon con los índices obtenidos de imágenes segmentadas por K-medias. Los resultados se graficaron en la Fig. 3.

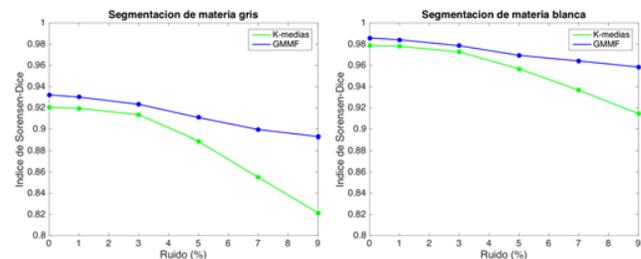


Fig. 3. Índices Sorensen-Dice de materia gris (izquierda) y materia blanca (derecha) de imágenes segmentadas mediante GMMF y K-medias.

Se puede notar como el método de K-medias se vuelve ineficiente conforme aumenta el nivel de ruido, a diferencia de GMMF el cual tiene una mejor consideración espacial lo que lo vuelve menos susceptible al ruido.

B. Imágenes Reales

Puesto que en este tipo de imágenes las regiones que componen el cerebro se encuentran menos definidas, habrá

un mayor adelgazamiento de la máscara binaria; por esta razón fue necesario aumentar el radio del elemento estructural en la dilatación. Además, en la segmentación se utilizó un parámetro de regularización $\lambda = 2.5$.

La Fig. 4 muestra el resultado del aislado del cerebro y la Fig. 5 el resultado de la segmentación de materias.

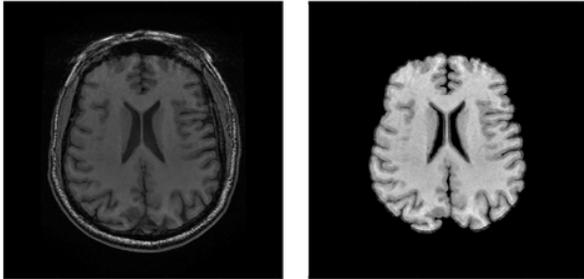


Fig. 4. Rebanada de una imagen 3-D de resonancia magnética real (izquierda) y cerebro aislado de la misma rebanada (derecha).



Fig. 5. Rebanada de una imagen 3-D de resonancia magnética real segmentada en materia blanca (izquierda) y materia gris (derecha), mediante Campos Markovianos de Medidas Gaussianas.

IV. DISCUSIÓN

Durante la etapa del aislado del cerebro, la selección del umbral de binarización mediante un modelo de Gaussiana resultó determinante para una correcta diferenciación entre materia cerebral y materias extra-cerebrales. Las imágenes reales tienen una menor definición y hay una mayor pérdida de información durante la binarización en comparación con las imágenes sintéticas, por lo que es necesario utilizar un elemento estructural de mayor diámetro. Los resultados de esta etapa muestran que el aislado del cerebro se realizó de forma simple y con alta eficacia.

En la etapa de clasificación de materias, fue necesario aumentar el valor del parámetro de regularización conforme la cantidad de ruido también lo hacía. Por otra parte, existe una mejor segmentación de materia blanca que de materia gris, ya que parte de esta última se encuentra en la periferia de la imagen y resulta afectada en la etapa del aislado de cerebro. A pesar de esto, la morfología de ambas después de la segmentación es muy buena.

V. CONCLUSIÓN

El principal reto de los algoritmos de segmentación en imágenes médicas es la susceptibilidad al ruido. La combinación del aislado del cerebro mediante operaciones morfológicas en máscaras binarias y la segmentación de materias cerebrales mediante Campos Markovianos de Medidas Gaussianas utilizando la información espacial, resultó en un algoritmo automático con un desempeño promedio del 97% y baja susceptibilidad a ruido e inhomogeneidades presentes naturalmente en MRI. Con estas ventajas, el algoritmo puede ser ajustado para utilizarse en otras modalidades con sus respectivas modificaciones, como T2, PD o secuencias FLAIR para la detección de lesiones manifestadas como hiperintensidades en este tipo de imágenes.

RECONOCIMIENTOS

A la Facultad de Ciencias de la UASLP por la excelente formación académica y al Instituto Nacional de Neurología y Neurocirugía por la proporción de los datos.

BIBLIOGRAFÍA

- [1] García, I. (2010). Aportaciones a la Segmentación y Caracterización de Imágenes Médicas. Tesis de licenciatura, Universidad de Sevilla, Departamento de Telecomunicaciones, Sevilla.
- [2] Reimer, P., Parizel, P. M., & Stichnoth, F.-A. (2006). *Clinical MR Imaging. A practical approach* (2a ed.). Berlín: Springer.
- [3] Clarke, L. P., Velthuizen, R. P., Camacho, M. A., Heine, J. J., Vaidyanathan, M., Hall, L. O., ... Silbiger, M. L. (1995). MRI Segmentation: Methods and Applications. *Magnetic Resonance Imaging*, XIII(3), 342-368.
- [4] Yazdani, S., Yusof, R., Karimian, A., Pashna, M., & Hematian, A. (2015). Image Segmentation Methods and Applications in MRI Brain Images. *IETE Technical Review*, XXXII(6), 413-427.
- [5] Morey, R. A., Petty, C. M., Xu, Y., Hayes, J. P., Wagner, H. R., Lewis, D. V., ... McCarthy, G. (15 de Abril de 2009). A comparison of automated segmentation and manual tracing for quantifying hippocampal and amygdala volumes. *Neuroimage*, XLV(3), 855-866.
- [6] Cocosco, C., Kollokian, V., Kwan, R.-S., Evans, A., Pike, G., Collins, D., y otros. (1999). *Brain Web*. Recuperado en noviembre de 2017, de Simulated Brain Database: <http://brainweb.bic.mni.mcgill.ca/brainweb/>
- [7] Rubio, M. E. (2017). Segmentación de Imágenes Utilizando Superpíxeles y Algoritmos de Clasificación. Tesis de maestría, Universidad Autónoma de San Luis Potosí, Departamento de Ingeniería Electrónica, San Luis Potosí.
- [8] K-means, t. b. (2013). Stanford CS221. (A. Ng, Ed.) Recuperado el 2018 de Abril de 9, de <http://stanford.edu/epiech/cs221/handouts/kmeans.html>