

Artículo Original

Comparación de métodos de segmentación automática en Neurociencia.

Horacio Sosa



¹Universidad Politécnica Taiwán Paraguay/Facultad de Ingeniería. San Lorenzo, Paraguay

<https://orcid.org/0009-0000-6757-9705>

Autor corresponsal: biososa20@gmail.com

Joshua Harper



²Universidad Comunera/ Facultad de Informática. Asunción, Paraguay

³Universidad Paraguaya Alemana/ Facultad de Ingeniería. Asunción, Paraguay

<https://orcid.org/0000-0002-8246-556X>

Para citar este artículo:

Sosa, H. y Harper, J. (2023). Comparación de métodos de segmentación automática en Neurociencia. *UCOM Scientia*, 1(1), 15-26.

Fecha de recepción: 13/05/2023

Fecha de aceptación: 20/07/2023

Resumen

La segmentación cerebral es fundamental en el análisis de imágenes médicas para identificar y diferenciar estructuras anatómicas dentro del cerebro. La segmentación precisa del líquido cefalorraquídeo, la materia gris y la materia blanca es crucial para el diagnóstico, la planificación del tratamiento y el monitoreo de trastornos neurológicos. Este estudio presenta una comparación de dos técnicas de procesamiento de imágenes del cerebro, FSL y DIPY, las cuales son utilizadas para la segmentación de tejidos cerebrales. Estas técnicas utilizan umbrales basados en la intensidad para clasificar píxeles de imágenes en líquido cefalorraquídeo, materia gris y materia blanca. Este trabajo tiene como objetivo proporcionar mayor comprensión sobre enfoques automatizados, para así mejorar la toma de decisiones clínicas y la comprensión de la estructura y función del cerebro.

Palabras clave: neurociencia, procesamiento digital de imágenes, segmentación.

Original Article

Comparison of automatic segmentation methods in Neuroscience

Abstract

Cerebral segmentation is essential in the analysis of medical images to identify and differentiate anatomical structures within the brain. Accurate segmentation of cerebrospinal fluid, gray matter, and white matter is crucial for diagnosis, treatment planning, and monitoring neurological disorders. This study presents a comparison of two brain image processing techniques, FSL and DIPY, which are used for segmenting brain tissues. These techniques use intensity-based thresholds to classify image pixels into cerebrospinal fluid, gray matter, and white matter. The aim of this work is to provide a better understanding of automated approaches, thereby enhancing clinical decision-making and the understanding of brain structure and function.

Keywords: neuroscience, digital image processing, segmentation

1. Introducción

La identificación temprana de enfermedades relacionadas con el cerebro, tales como Parkinson, Alzheimer y tumores cerebrales, es crucial y depende en gran medida del uso de técnicas de imagenología cerebral. El cáncer cerebral y otros tipos de tumores del sistema nervioso están entre las diez principales causas de muerte tanto en hombres como en mujeres. En el año 2020, se estima que aproximadamente 251,329 personas en todo el mundo perdieron la vida a causa de tumores cerebrales y del sistema nervioso central primarios (American Society of Clinical Oncology, 2023).

Es esencial contar con una segmentación precisa y coherente de las regiones cerebrales objetivo o los tumores a partir de imágenes de resonancia magnética. Esto desempeña un papel fundamental en la evaluación clínica del avance de la enfermedad, la planificación de cirugías, el seguimiento postoperatorio y los resultados de la terapia de radiación. Debido a que la segmentación manual de los tumores cerebrales y las estructuras cerebrales más pequeñas implica un proceso laborioso y que requiere mucho tiempo, se han explorado y presentado numerosas soluciones automatizadas hasta la fecha. En líneas generales, los métodos automatizados de segmentación cerebral empleando imágenes de resonancia magnética se pueden clasificar en tres categorías teóricas principales (i) basadas en la intensidad, (ii) basadas en el aprendizaje automático e (iii) híbridos (Fawzi, Achuthan & Belaton, 2021).

Los métodos de segmentación cerebral que se basan en la intensidad operan en el dominio espacial y utilizan el valor de los píxeles. Estos métodos se pueden clasificar en enfoques de umbralización y enfoques basados en regiones. La umbralización (*thresholding*) es uno de los métodos convencionales y más sencillos de segmentación de imágenes en los cuales se categorizan las regiones de la imagen midiendo sus intensidades y comparándolas con uno o más umbrales de intensidad (Mbuyamba et al., 2017). Este trabajo busca explorar dos técnicas basadas en intensidad (*thresholding*) y evaluar su desempeño mediante métricas definidas.

2. Materiales y métodos

2.1 Datos

La competencia BraTS (*Brain Tumor Segmentation Challenge*) según Ilhan (2017) es un evento anual que se enfoca en la evaluación y comparación de métodos de segmentación de tumores cerebrales en imágenes de resonancia magnética (IRM). En particular, la edición BraTS2020 utilizó una amplia colección de datos de escaneos de IRM preoperatorios de múltiples instituciones. Estos datos incluyen imágenes (IMR) T2 en formato nifti, los cuales fueron usados para este trabajo.

Las imágenes de resonancia magnética (IRM) T2 son un tipo de secuencia de imágenes utilizadas en el campo de la radiología para visualizar y analizar tejidos y estructuras dentro del cuerpo humano. En particular, las imágenes MR T2 son conocidas por resaltar el líquido y los tejidos blandos, lo que las hace especialmente útiles en la evaluación de afecciones cerebrales, como tumores, lesiones o enfermedades degenerativas. Estas imágenes proporcionan una visión detallada de los tejidos cerebrales, permitiendo identificar cambios patológicos, edema, inflamación u otras anomalías en la sustancia blanca y gris del cerebro. Además, las imágenes MR T2 pueden ayudar a diferenciar entre diferentes tipos de tejido cerebral, como el líquido cefalorraquídeo, el tejido tumoral y las estructuras normales del cerebro.

Estas imágenes T2 nifti permiten una visualización precisa de la estructura y la heterogeneidad de los tumores cerebrales, lo que es fundamental para el desarrollo de algoritmos de segmentación avanzados y precisos. La imagen T2 con formato nifti fue extraída del conjunto de datos de BraTS (2020).

2.2 Extracción de cerebro *Skullstripping*

La eliminación del cráneo, también conocida como extracción cerebral, es un paso crucial en el procesamiento y análisis de imágenes, especialmente en el campo de la neuro imagen. Se refiere al proceso de eliminar tejidos y estructuras no cerebrales de imágenes médicas, principalmente escáneres de resonancia magnética (MRI), para aislar y enfocarse en la región cerebral de interés.

En general, la eliminación del cráneo desempeña un papel crítico en el pre procesamiento de datos de neuro imagen al aislar la región cerebral de interés y mejorar la precisión del análisis subsiguiente, la calidad de los datos, la eficiencia computacional y la visualización. Es un paso esencial para diversas aplicaciones, como la segmentación cerebral, el registro, la reconstrucción de la superficie cortical y el análisis de conectividad funcional.

La eliminación del cráneo fue realizada mediante la herramienta BET (Brain Extraction Tool) perteneciente a FSL. Esta herramienta es ampliamente utilizada en el campo de la neuro imagen para llevar a cabo esta importante tarea (Zhang, Brady & Smith, 2001). BET utiliza algoritmos de umbralización y técnicas de superficie para separar el cerebro del cráneo y otros tejidos no cerebrales en las imágenes de resonancia magnética. Proporciona resultados rápidos y eficientes, permitiendo una segmentación precisa del cerebro. El cerebro de la imagen BRAINX_NIFTI_T2.nii.gz fue extraído usando BET y un umbral de intensidad fraccional igual a 0.2.

2.3 Segmentación

2.3.1 FSL

La Biblioteca de Software FMRIB (FSL) es un paquete de software ampliamente reconocido en el campo de la neuro imagen. Ofrece una variedad de herramientas para el procesamiento y análisis de datos de resonancia magnética funcional y estructural (MRI). Aunque FSL es conocido por sus capacidades en el pre procesamiento de datos, el análisis estadístico y la visualización en neuro imagen, también incluye herramientas específicas para la segmentación de imágenes.

Una de las herramientas más utilizadas en FSL para la segmentación de imágenes es FAST (*FMRIB's Automated Segmentation Tool*) (Zhang, Brady & Smith, 2001). FAST es un algoritmo de segmentación que se basa en la estimación y clasificación de diferentes tejidos en una imagen de resonancia magnética. Utiliza técnicas de modelado estadístico y procesamiento de señales para identificar y separar diferentes regiones de interés, como el tejido cerebral compuesto por materia gris, materia blanca y el líquido cefalorraquídeo.

La segmentación en FSL mediante su herramienta FAST usó como archivo de entrada, la imagen resultante de la extracción del cerebro. De acuerdo con la información proporcionada por la documentación de FSL, en el caso de imágenes ponderadas T2, es necesario elegir 4 clases para asegurar un procesamiento adecuado de la materia oscura que no está relacionada con el cerebro. Cada una de estas clases representará un tejido específico del cerebro: líquido cefalorraquídeo, materia gris, materia blanca y materia oscura.

2.3.2 DIPY

DIPY es un módulo en Python que utiliza una formulación bayesiana para segmentar imágenes estructurales ponderadas en T1 y T2. El modelo de observación se basa en una distribución gaussiana y se utiliza un Campo Aleatorio de Markov (MRF) para capturar la probabilidad a priori de patrones dependientes del contexto exhibidos por diferentes tipos de tejido cerebral.

Para utilizar el algoritmo de segmentación es necesario definir dos parámetros importantes, el número de clases y el factor de suavidad. Como nuestro objetivo es segmentar imágenes T2 en cuatro clases: líquido cefalorraquídeo (CSF), materia blanca (WM), materia gris (GM) y materia oscura no cerebral (NB), entonces definimos `nclass` (número de clases) como 4. Para el factor de suavidad de la segmentación, se utilizó el valor de 0.5, ya que según la documentación de DIPY, se suelen obtener buenos resultados con valores entre 0 y 0.5. Luego se procedió a usar una instancia de la clase *TissueClassifierHMRF* y su método *classify*, proporcionando los parámetros establecidos anteriormente para llevar a cabo la tarea de segmentación. Como resultado se generaron 4 mapas de probabilidad para cada una de las 4

clases especificadas arriba.

2.4 Visualización de datos

La visualización de datos fue realizada mediante la herramienta FSLeys. Esta es una herramienta de visualización avanzada utilizada en neuroimágenes y desarrollada por el FMRIB *Software Library* (FSL). Proporciona una interfaz gráfica intuitiva y poderosa para explorar y analizar datos de imágenes médicas, como imágenes de resonancia magnética (MRI) y tomografía computarizada (CT).

Además, para la gestión y visualización de imágenes en Python 3.10.9 (*Jupyter Notebook*) se utilizaron los módulos: *nibabel* para la importación de datos, *numpy* para la operación y manejo de matrices y, por último, *matplotlib* para la visualización de resultados e histogramas.

2.5 Similitud estructural

La similitud estructural (del inglés *Structural similarity* o SSIM) se utiliza para medir la similitud entre dos imágenes. Es una métrica de referencia completa, lo que significa que la evaluación o estimación de la calidad de la imagen se basa en una imagen inicial sin comprimir o sin distorsiones que se toma como referencia. SSIM se basa en un modelo perceptual que considera la degradación de la imagen como un cambio percibido en la información estructural. También incorpora importantes fenómenos perceptuales, como el enmascaramiento de luminancia y el enmascaramiento de contraste. A diferencia de otras técnicas como el MSE o el PSNR, que estiman errores absolutos, SSIM se enfoca en la información estructural, que resalta las fuertes interdependencias entre píxeles vecinos. Estas interdependencias transmiten información relevante sobre la estructura de los objetos en la escena visual.


La similitud entre las clases obtenidas mediante FSL y DIPY fue medida con la métrica SSIM, mediante la función *structural_similarity* perteneciente al módulo de *skimage.metrics*, tomando las clases obtenidas con DIPY, como clases de referencia. Las clases obtenidas por cada uno de los métodos fueron convertidas a vectores booleanos, obteniendo Verdadero si la probabilidad de ese píxel de pertenecer a su clase es mayor a 0.7 o Falso si es menor.

3. Resultados

3.1 Extracción cerebral

Como fue mencionado anteriormente, para una correcta segmentación de tejidos cerebrales, la remoción del cráneo es necesaria. En la Figura 1 se puede observar la imagen antes y después de la extracción del cerebro. Sin embargo, en la Figura 1 B, todavía se observan vestigios de lo que podría ser tejido no-cerebral en la parte frontal del cerebro.

Figura 1. Visualización de la imagen BRAINX_NIFTI_T2.nii. Se observa la imagen antes (A) y después (B) de la extracción cerebral.




Fuente: BraTS (2020)

3.2 Segmentación de tejidos del cerebro

Como fue descrito anteriormente, la segmentación fue realizada mediante dos herramientas que utilizan modelos probabilísticos para clasificar los píxeles en cuatro grupos o clases: líquido cefalorraquídeo (CSF), materia gris (GM), materia blanca (WM) y materia oscura no cerebral (NN).

En la Figura 2 se observa los resultados para las clases obtenidas mediante FSL. Se puede observar que el algoritmo de FSL es capaz de clasificar el tejido cerebral en 4 clases correctamente, sin observarse anomalías en alguna de las clases. Además, se puede observar en la Figura 2 (A), la presencia de un tumor, el cual es clasificado en la clase de líquido cefalorraquídeo.

Figura 2. Mapas de probabilidad de cada una de las clases segmentadas por FSL




Fuente: Segmentación propia de imágenes, (2023)

En la Figura 2, (A) corresponde a píxeles clasificados como líquido cefalorraquídeo (B) corresponde a píxeles clasificados como líquido materia gris. (C) Corresponde a los píxeles clasificados como materia blanca. Por último, (D) corresponde a píxeles que fueron imposible de clasificar y corresponden a materia oscura no cerebral.

En la Figura 3, se pueden observar los resultados obtenidos mediante DIPY. Se puede visualizar la clasificación de las 4 clases que corresponden a CSF, GM, WM y NN. Nuevamente se puede observar que el tumor es clasificado dentro de la clase de CSF.

Figura 3. Mapas de probabilidad de cada una de las clases segmentadas por el módulo DIPY



Fuente: Segmentación propia de figuras, (2023)

(A) Corresponde a píxeles clasificados como líquido cefalorraquídeo. (B) Corresponde a píxeles clasificados como líquido materia gris. (C) Corresponde a los píxeles clasificados como materia blanca. Por último, (D) corresponde a píxeles que fueron imposible de clasificar y corresponden a materia oscura no cerebral.

3.3 Comparación de los resultados obtenidos

La similitud entre cada una de las clases obtenidas mediante los métodos de FSL y DIPY fue medida mediante la métrica de similitud estructural. SSIM tiene como objetivo encontrar similitudes entre píxeles, específicamente examinando si los píxeles en las dos imágenes se alinean o tienen valores de densidad de píxeles comparables.

En la tabla se observa un alto grado de similitud entre las clases pertenecientes a CSF y GM, mientras que las clases pertenecientes a WM y NN presentan una menor similitud al ser comparadas con el par anterior. Esta última observación es visible a simple vista en la figura 2 C- figura 3 C y figura 2 D- figura 3 D, en donde una diferencia en formas y píxeles es notoria.

Tabla 1. Valores de similitud estructural (SSMI)

Tejido	SSMI
CSF	0.8999953
GM	0.9087935
WM	0.8579387
NN	0.8762699

Fuente: Elaboración propia (2023)

Tabla 1. Valores de similitud estructural (SSMI) entre clases obtenidas mediante diferentes métodos. La métrica SSIM utiliza un rango de -1 a 1 (aunque no puede obtener un puntaje inferior a 0). Un puntaje de 1 indica una gran similitud entre las imágenes, mientras que un puntaje de -1 indica una diferencia significativa.

4. Discusión

Tanto los métodos FSL como DIPY muestran una alta precisión y realizan de manera efectiva la segmentación de imágenes. Son herramientas confiables que identifican y aíslan con precisión diferentes estructuras dentro de las imágenes.

Es importante resaltar que ambos métodos clasificaron el tumor presente dentro de la clase de líquido cefalorraquídeo (CSF). Si bien existen métodos más avanzados basados en inteligencia artificial capaces de discernir entre tumores y tejido cerebral (Elshaikh et al. 2021), estos métodos están fuera del alcance del tema de este artículo y merecen ser explorados con detenimiento.

Al comparar los resultados de ambos métodos, se pueden observar pequeñas diferencias, especialmente en la segmentación de la materia blanca y la materia oscura. Estas diferencias son capturadas por medidas como el SSMI (Índice de Similitud Estructural), que resalta las variaciones entre los resultados de segmentación. Estas disparidades pueden deberse a las diferencias inherentes en las metodologías utilizadas por FSL y DIPY.

A pesar de las pequeñas discrepancias, tanto FSL como DIPY ofrecen imágenes de segmentación confiables. Para asegurar una evaluación completa, es importante comparar los resultados obtenidos con imágenes de referencia (del inglés *ground truth*), las cuales sirven como estándar de referencia. Estas imágenes de referencia proporcionan un punto de referencia con el cual se puede evaluar la precisión y el rendimiento de los métodos de segmentación. Al incorporar comparaciones con las imágenes de referencia, se podrían obtener una comprensión más profunda de las fortalezas y limitaciones de cada método y tomar decisiones informadas basadas en los resultados de segmentación respectivos.

5. Conclusión

Tanto FSL (*FMRIB Software Library*) y DIPY (*Diffusion Imaging in Python*) han demostrado ser métodos altamente efectivos para la segmentación de tejido cerebral. Estas herramientas poderosas se destacan por categorizar con precisión los píxeles en 4 clases que corresponden al líquido cefalorraquídeo + Tumor (CSF), materia gris (GM), materia blanca (WM) y materia oscura.

Mediante sus fiables métodos, FSL y DIPY proporcionan resultados de segmentación robustos, lo que permite a los investigadores y médicos analizar estructuras cerebrales con precisión. Una fortaleza notable tanto de FSL como de DIPY es la consistencia de sus resultados. Al comparar los resultados de segmentación de estos dos métodos, se observa un alto nivel de acuerdo, lo que demuestra la confiabilidad y reproducibilidad de las técnicas.

La prevalencia de enfermedades cerebrales como el cáncer y la enfermedad de Parkinson está en aumento, lo que plantea desafíos significativos para la comunidad médica. En vista de esta preocupante tendencia, es crucial mejorar continuamente los métodos de segmentación existentes y evaluar su rendimiento. Al comprender más a fondo las fortalezas y limitaciones de FSL y DIPY, los investigadores pueden perfeccionar estos métodos y desarrollar nuevas técnicas que ofrezcan una mayor precisión y confiabilidad.

En conclusión, la efectividad de FSL y DIPY en la segmentación del tejido cerebral los convierte en herramientas valiosas tanto para investigadores como para médicos. Con el aumento de las enfermedades que afectan al cerebro, es crucial invertir en la mejora de los métodos existentes y empujar los límites de su precisión. Al hacerlo, podemos mejorar la atención médica de los pacientes, facilitar descubrimientos innovadores y, en última instancia, mejorar la vida de las personas afectadas por trastornos cerebrales.

6. Declaración de financiamiento

La presente investigación se llevó a cabo con financiación propia.

7. Declaración de conflictos de intereses

Los autores declaran no tener conflictos de intereses

8. Declaración de autores

Los autores aprueban la versión final del artículo

9. Contribución de los autores



Autor

Contribución

Horacio Sosa	Participación importante en la conceptualización, metodología, segmentación y comparación de resultados además de la redacción del borrador del manuscrito.
Joshua Harper	Participación importante en la conceptualización, metodología, segmentación y comparación de resultados además de la redacción del borrador del manuscrito.

10. Referencias

- American Society of Clinical Oncology. (2023). *Brain tumor statistics*. Cancer.Net. <https://www.cancer.net/cancer-types/brain-tumor/statistics>
- BraTS2020 Competition. (2020). *Brain Tumor Segmentation (BraTS2020)*. Kaggle. <https://www.kaggle.com/datasets/awsaf49/brats2020-training-data>
- Elshaikh, B. G., Garelnabi, M., Omer, H., Sulieman, A., Habeebballa, B., & Tabeidi, R. A. (2021). Recognition of brain tumors in MRI images using texture analysis. *Saudi Journal of Biological Sciences*, 28(4), 2381-2387. <https://doi.org/10.1016/j.sjbs.2021.01.035>
- Fawzi, A., Achuthan, A., & Belaton, B. (2021). *Brain Image Segmentation in Recent Years: A Narrative Review*. *Brain sciences*, 11(8), 1055. <https://doi.org/10.3390/brainsci11081055>
- Ilhan, A. (2017). Brain tumor segmentation based on a new threshold approach. *Procedia Comput. Sci.*, 120, 580–587. <https://doi.org/10.1016/j.procs.2017.11.282>.
- Mbuyamba, E. I., Avina-Cervantes, J. G., García-Pérez A., Romero-Troncoso, R. D. J., Aguirre-Ramos, H., Cruz-Aceves, I., Chalopin C. (2017). Localized active contour model with background intensity compensation applied on automatic MR brain tumor segmentation. *Neurocomputing*; 220,84–97. <https://doi.org/10.1016/j.neucom.2016.07.057>
- Zhang, Y., Brady, M., & Smith, S. (2001). Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm. *IEEE Transactions on Medical Imaging*, 20(1), 45-57. <https://doi.org/10.1109/42.906424>