

Segmentación automática de tumores cerebrales usando K-means

Kay García-Sánchez, Daniel Cantón-Enríquez,
Hugo Jiménez-Hernández, Luis Antonio Díaz-Jiménez,
Ana Marcela Herrera-Navarro, Jorge Luis Pérez-Ramos,
Selene Ramírez-Rosales, Carlo Giovanni Cetina-Camacho

Universidad Autónoma de Querétaro,
Facultad de Informática,
México

kgarcia@uaq.mx

Resumen. La segmentación automática de tumores cerebrales en imágenes médicas es un desafío debido a la variabilidad en la morfología y el contraste de los tumores. En este trabajo, se propone un marco de referencia basado en detección de contornos mediante el operador de Sobel y segmentación con el algoritmo K-means, refinando los resultados con filtrado morfológico. La metodología implementada permite diferenciar tejido sano de masa tumoral, adaptándose a variaciones de intensidad y morfología. Los resultados muestran que la técnica propuesta es capaz de segmentar tumores en casos complejos, incluso en casos con bordes difusos. Este enfoque proporciona una alternativa reproducible para la segmentación automática de tumores, facilitando la toma de decisiones clínicas y promoviendo el uso de inteligencia artificial en salud.

Palabras clave: Segmentación automática, tumores cerebrales, clustering, aprendizaje automático, inteligencia artificial médica.

Automatic Brain Tumor Segmentation Using K-means

Abstract. Automatic segmentation of brain tumors in medical images is a challenge due to the variability in tumor morphology and contrast. In this work, we propose a reference framework based on contour detection using the Sobel operator and segmentation with the K-means algorithm, refining the results with morphological filtering. The implemented methodology allows differentiating healthy tissue from tumor mass, adapting to variations in intensity and morphology. Results show that the proposed technique is capable of segmenting tumors in complex

cases, even in those with diffuse borders. This approach provides a reproducible alternative for automatic tumor segmentation, facilitating clinical decision-making and promoting the use of artificial intelligence in healthcare.

Keywords: Automatic segmentation, brain tumors, clustering, machine learning, medical artificial intelligence.

1. Introducción

Los tumores cerebrales presentan una amplia heterogeneidad en su gravedad determinada por su grado de malignidad según la OMS [1]. Este espectro clínico abarca desde gliomas de alto grado como el glioblastoma (grado IV), con un pronóstico desfavorable; hasta meningiomas generalmente benignos (grado I), que a pesar de su baja agresividad, pueden resurgir localmente [2]. Asimismo, los adenomas pituitarios, aunque mayoritariamente indolentes, tienen el potencial de afectar funciones endocrinas críticas [3].

La detección de tumores cerebrales enfrenta importantes desafíos técnicos, entre ellos la dificultad para diferenciar radiológicamente la progresión tumoral de los efectos postratamiento en diversas afecciones oncológicas [4], así como la alta variabilidad interobservador en tumores con bordes difusos [5]. En este contexto, la segmentación automática surge como una solución prometedora para reducir la inconsistencia en las anotaciones manuales [6]. Además, de cerrar la brecha entre los datos de investigación y las condiciones clínicas reales [7].

A nivel global, el Objetivo de Desarrollo Sostenible (ODS) 3 de las Naciones Unidas, centrado en "Salud y Bienestar", enfatiza la importancia de fortalecer los sistemas sanitarios mediante la adopción de tecnologías médicas innovadoras y accesibles [8]. Este objetivo está alineado con los esfuerzos por reducir la brecha en el diagnóstico temprano de tumores cerebrales en países de bajos ingresos, donde la falta de equipos de neuroimagen avanzada incrementa la mortalidad por gliomas no detectados [9]. Además, como señala Gupta et al. [10], la implementación de herramientas de inteligencia artificial de código abierto para la segmentación automática de tumores cerebrales podría democratizar el acceso a diagnósticos precisos, contribuyendo al cumplimiento de la meta 3.8 del ODS la cual busca cobertura sanitaria universal mediante al acceso equitativo a servicios de salud.

Por otro lado, la detección temprana de tumores cerebrales no solo mejora el pronóstico, sino que también preserva la calidad de vida de los pacientes. En el caso de los glioblastomas diagnosticados en estadios iniciales, la supervivencia media se duplica y las resecciones completas son más factibles [11]. Por otro lado, en meningiomas asintomáticos de alto riesgo, el seguimiento mediante MRI permite evitar complicaciones neurológicas graves [12]. Estas ventajas contrastan con las marcadas diferencias en tasas de supervivencia entre los distintos tipos tumorales: los pacientes con gliomas de alto grado tienen una supervivencia a 5 años inferior al 20%, mientras que en adenomas pituitarios no invasivos esta cifra alcanza el 95% [13,14].

La calidad de las imágenes de resonancia magnética es un factor clave en la precisión de la segmentación automatizada de tumores cerebrales. Existen protocolos con alta resolución espacial ($\geq 1 \text{ mm}^3$) y secuencias como T2-FLAIR, que suprimen la señal del líquido cefalorraquídeo, mejorando así la delimitación de tumores infiltrativos [15]. No obstante, parámetros de adquisición subóptimos, como tiempos de eco prolongados, pueden reducir la precisión de los algoritmos de inteligencia artificial hasta en un 30% [16]. Además, artefactos comunes, como el movimiento del paciente o una baja relación señal-ruido ($SNR < 20 \text{ dB}$), generan errores críticos en la segmentación de tumores pequeños, lo que hace necesario el uso de técnicas de corrección basadas en Deep Learning para mitigar su impacto [17,18].

En este artículo, se presenta un marco de referencia basado en K-means para segmentar tumores cerebrales. Este algoritmo, combinado con técnicas de preprocesamiento, permite una binarización eficiente de imágenes en escala de grises, facilitando la identificación de regiones tumorales. Su robustez ante variaciones de contraste lo hace una alternativa competitiva frente a otros algoritmos de agrupamiento como DBSCAN, que debido a su sensibilidad a parámetros como ϵ , convirtiéndolo en un método menos robusto en imágenes con variaciones locales de contraste, típicas en imágenes de resonancias magnéticas de tumores cerebrales [16].

El resto del artículo está organizado de la siguiente manera: se presentan los materiales y métodos utilizados para la segmentación automática de los tumores cerebrales; después, se muestran los resultados obtenidos de la experimentación; posteriormente, la discusión de los resultados; por último, las conclusiones y trabajos a futuro.

2. Materiales y métodos

2.1. Descripción del conjunto de datos

El dataset utilizado en este estudio fue obtenido del repositorio público *Brain Tumor MRI Dataset* [19], el cual contiene 7,023 imágenes de resonancia magnética en formato JPG, clasificadas en cuatro tipos; véase Tabla 1. Las imágenes fueron preprocesadas para garantizar uniformidad en dimensiones (512 x 512 px) y contraste. Se incluyeron imágenes donde la región tumoral era claramente distinguible y se excluyeron aquellas con artefactos de movimiento severos ($SNR < 20 \text{ dB}$). Para mejorar la calidad del dataset, se realizaron pruebas de normalización de intensidades y eliminación de ruido utilizando filtros adaptativos.

2.2. Metodología

El proceso realizado para la segmentación automática de tumores cerebrales a partir de imágenes de resonancia magnética (MRI) consta de tres etapas principales: 1) preprocesamiento, donde, se buscan los contornos de las

Table 1. Distribución del dataset Brain Tumor MRI Dataset [19].

Tipo de tumor	Descripción	Cantidad
Meningioma	Crecimiento en meninges, ejerciendo presión sobre el cerebro.	1,621
Glioma	Proliferación de células anormales en una región cerebral.	1,645
Pituitario	Tumores en la glándula pituitaria, con afectaciones endocrinas.	1,757
Sin tumor	Imágenes sin evidencia de tumor.	2,000




Fig. 1. Diagrama de flujo del marco de referencia propuesto.

imágenes MRI; 2) segmentación con K-means, donde, se agrupan los píxeles en dos clústeres (tejido sano y tumoral); y 3) postprocesamiento, donde, se selecciona la región tumoral dominante usando filtros de convexidad y área para eliminar artefactos.

La metodología empleada en este trabajo se muestra de forma general en el diagrama de flujo de la figura 1.

Detección de contornos: Primero, se aplicó el operador de Sobel, un filtro de convolución discreto ampliamente utilizado en visión por computadora para la detección de bordes. Este operador calcula una aproximación del gradiente de la imagen en dos direcciones: horizontal (eje X) y vertical (eje Y), lo que permite resaltar los contornos de los objetos presentes en la imagen [20]. Matemáticamente, se define mediante dos kernels de convolución de tamaño 33, como se muestra en la Ecuación 1:

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \quad G_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}. \quad (1)$$

El núcleo convolucional G_x resalta variaciones abruptas de intensidad a lo largo del eje X , facilitando la detección de bordes verticales. De manera análoga, G_y permite identificar bordes horizontales al calcular los cambios de intensidad

en el eje Y. Por otro lado, la magnitud del gradiente proporciona una medida cuantitativa de la intensidad total de los bordes en la imagen, y se calcula mediante la Ecuación 2:

$$|G| = \sqrt{G_x^2 + G_y^2}. \quad (2)$$

Detección del Umbral Automático con K-means: El algoritmo K-means es un método de aprendizaje no supervisado utilizado para agrupar datos en K clústeres en función de sus similitudes. Su objetivo es minimizar la varianza intra-clúster, asignando cada dato al clúster cuyo centroide se encuentre más cercano. Este proceso se describe matemáticamente en la Ecuación 3 [21]:

$$J = \sum_{i=1}^K \sum_{\mathbf{x} \in C_i} \|\mathbf{x} - \boldsymbol{\mu}_i\|^2, \quad (3)$$

donde K es el número de clusters, C_i es el conjunto de puntos en el agrupamiento i y $\boldsymbol{\mu}_k$ es el centroide del cluster i -ésimo. Para este algoritmo se han de seguir los siguientes pasos:

1. Seleccionar K centroides iniciales (aleatorios o heurísticos).
2. Cada píxel $\mathbf{x}$ se asigna al cluster C_k cuyo centroide $\boldsymbol{\mu}_k$ está más cerca siguiendo la ecuación 4:

$$C_k = \arg \min_k \|\mathbf{x} - \boldsymbol{\mu}_k\|^2. \quad (4)$$

3. Recalcular los centroides $\boldsymbol{\mu}_k$ como la media de los puntos en C_k .
4. Repetir hasta que los centroides no cambien, véase Ecuación 5:

$$\Delta \boldsymbol{\mu}_k < \text{tolerancia}. \quad (5)$$

El algoritmo K-means puede utilizarse para la segmentación de imágenes agrupando píxeles que comparten características similares, como color o intensidad, en dos clústeres: fondo y objeto de interés [23]. Dada una imagen en escala de grises $I \in \mathbb{R}^{m \times n}$, de tamaño $m \times n$, esta se modela como un conjunto de $N = m \times n$ puntos 1D, donde cada punto corresponde a una intensidad de píxel $x_p \in [0, 255]$. La binarización con $K = 2$ se define en la Ecuación 6:

$$\text{Cluster 1 (Fondo)} : \mu_1 \approx 0, \quad \text{Cluster 2 (Tumor)} : \mu_2 \approx 255. \quad (6)$$

Post-procesamiento: La morfología matemática es una técnica de procesamiento de imágenes fundamentada en la teoría de conjuntos y la geometría, que se utiliza para modificar la estructura de objetos en imágenes binarias o en escala de grises. Sus operaciones básicas, como la apertura y la cerradura, permiten eliminar ruido, rellenar huecos y preservar la forma de las regiones de interés [25].

En este contexto, un elemento estructurante es una pequeña matriz de píxeles con forma y tamaño definidos, utilizada para modificar la estructura de los objetos en la imagen durante las operaciones morfológicas. Define cómo se modifican los píxeles en erosión y dilatación, y es fundamental en la morfología matemática, ya que controla el tipo de modificación aplicada y, por ende, los efectos de apertura y cerradura.

En esta propuesta, la morfología se aplicó en dos etapas: apertura (erosión seguida de dilatación) y cerradura (dilatación seguida de erosión), utilizando un elemento estructurante cuadrado de 5×5 píxeles.

Primero, la erosión elimina regiones pequeñas y ruido, conservando únicamente los píxeles z donde el elemento estructurante B cabe completamente dentro de la máscara binaria A . La fórmula correspondiente se presenta en la Ecuación 7.

$$A \ominus B = \{z \in \mathbb{Z}^2 \mid B \subseteq A\}. \quad (7)$$

Por otro lado, la dilatación, por su parte, recupera áreas útiles erosionadas, expandiendo los bordes de las regiones restantes donde B_z intersecta con la máscara binaria (A) . La estructura de la dilatación se describe en la Ecuación 8:

$$A \oplus B = \{z \in \mathbb{Z}^2 \mid B_z \cap A \neq \emptyset\}. \quad (8)$$

La operación de cierre (dilatación seguida de erosión) tiene como objetivo consolidar los agujeros microscópicos que puedan quedar después del proceso de apertura, logrando esto mediante la conexión de regiones cercanas y asegurando la continuidad en la máscara binaria.

El elemento estructurante empleado fue cuadrado de 5×5 , lo que equilibra eficazmente la eliminación de ruido y la preservación de las estructuras. Matrices pequeñas podrían retener artefactos, mientras que elementos estructurantes mayores podrían erosionar zonas tumorales válidas o fusionar regiones no relacionadas.

Finalmente, se aplicó un filtro de área mínima, que es una técnica que elimina regiones conectadas en una imagen binaria cuyo tamaño es inferior a un umbral predefinido. Su objetivo principal es descartar el ruido residual o artefactos morfológicos no relevantes [22]. Este filtro se puede definir de manera que, dado un contorno C , su área se calcula mediante integración discreta, véase Ecuación 9:

$$C = \sum_{(x,y) \in C} 1. \quad (9)$$

El filtro de área mínima se complementa con el filtro de convexidad, que evalúa la “compactidad” de una región al comparar su área con la de su envolvente convexa mínima o casco convexo (*hull*). Los tumores cerebrales suelen mostrar alta convexidad debido a su crecimiento expansivo [26]. La convexidad se puede determinar como una fracción, cuya fórmula se presenta en la Ecuación 10:

$$\tau = \frac{\text{Área}(C)}{\text{Área}(\text{CascoConvexo}(C))}. \quad (10)$$

De este modo, se pueden definir que valores cercanos a 1 indican formas convexas, como los meningiomas, mientras que valores bajos (< 0.7) sugieren bordes irregulares, característicos de los gliomas infiltrativos. Además, se realiza un aislamiento del tumor seleccionando el clúster de mayor área, lo que garantiza que solo se retenga la masa tumoral primaria. Este proceso puede expresarse mediante la ecuación 11:

$$C_{\max} = C_j = \arg \max_{i \in \{1, 2, \dots, k\}} |C_i|. \quad (11)$$

2.3. Complejidad computacional

La complejidad computacional para el proceso de segmentación automática propuesto se determina como una función $O : \mathbb{R}^2 \rightarrow O : \mathbb{R}^2$. Por tanto, se tiene $O(I, k, B)$, donde I es la imagen que se analiza en escala de grises; k es el número de clusters utilizados por K-means; y B es el elemento estructurante utilizado.

La complejidad del proceso paso a paso conlleva el siguiente análisis. Primero, la detección de contornos utiliza una convolución con un kernel 3×3 sobre una imagen de tamaño $m \times n$. Cada píxel se procesa en $O(1)$ y se recorren los $m \times n$ píxeles, por lo que la complejidad es $O(mn)$. Luego, al realizar la segmentación automática con K-means tanto la asignación de clústeres y actualización toma $O(kmn)$ en cada iteración. Además, si el algoritmo tarda t iteraciones en converger, la complejidad de K-means es $O(tkmn)$, donde, t y k son constantes en la práctica, se aproxima a $O(mn)$. Posteriormente, en las operaciones de convoluciones con el elemento estructurante B de tamaño $b \times b$, por lo que la complejidad es $O(b^2mn)$. Aunque tomando en cuenta que b es constante, la complejidad es $O(mn)$. Por ultimo, en el cálculo de área y convexidad, se recorren los contornos que depende del número de regiones segmentadas r . En el peor caso, la complejidad es $O(mn)$ si hay regiones pequeñas.

En resumen, la complejidad del proceso de segmentación automática es:

$$\underbrace{O(mn)}_{\text{Sobel Gradient}} + \underbrace{O(mn)}_{\text{K-means}} + \underbrace{O(mn)}_{\text{Morphology}} + \underbrace{O(mn)}_{\text{Convexity Filter}} = O(mn).$$

La segmentación automática de tumores cerebrales es un desafío debido a la variabilidad en la apariencia del tumor y la similitud de intensidades con el tejido sano. Matemáticamente, se busca particionar la imagen I en una región tumoral T y el fondo B , con $I = T \cup B$. Tradicionalmente, esto se realiza manualmente por especialistas o mediante umbralización global, donde un valor T_{umbral} separa las regiones de interés. También se emplean contornos activos para ajustar curvas a los bordes de tumor. Sin embargo, estos métodos son sensibles a la calidad de la imagen y poco eficaces en tumores con bordes difusos. En contraste, el Algoritmo 1, presenta un pseudocódigo de la segmentación automática usando K-means.

Los parámetros de entrada del algoritmo son los siguientes: I es la imagen en escala de grises, k es el número de clústeres, y B es el elemento estructurante. Como parámetro de salida se tiene M_{tumor} es la mascara de la región tumoral.

Algorithm 1 Segmentación automática de tumores cerebrales con K-means

```

1: procedure SEGMENTATIONPROCESS( $I, k, B$ )
2:    $G_x \leftarrow I * S_x, G_y \leftarrow I * S_y$                                  $\triangleright$  Calcular gradientes en  $x$  y  $y$ 
3:    $G \leftarrow \sqrt{G_x^2 + G_y^2}$                                            $\triangleright$  Magnitud del gradiente
4:    $G_{norm} \leftarrow \frac{G - \min(G)}{\max(G) - \min(G)}$                        $\triangleright$  Normalizar gradiente
5:    $\mu_k \leftarrow \mathcal{U}(a, b)$                                             $\triangleright$  Inicializar  $k$  centroides
6:   for cada píxel  $x \in I$  do
7:      $C_k \leftarrow \arg \min_k \|x - \mu_k\|^2$                              $\triangleright$  Asignar  $x$  al clúster más cercano
8:      $\|\mu_k^{(t)} - \mu_k^{(t-1)}\| < \epsilon$                                  $\triangleright$  Recalcular centroides hasta convergencia
9:   end for
10:   $M_{Kmeans} \leftarrow \{x \in I \mid C(x) = C_{tumor}\}$                    $\triangleright$  Generar máscara inicial
11:   $M_{apertura} \leftarrow (M_{Kmeans} \ominus B) \oplus B$                      $\triangleright$  Mascara de apertura morfológica
12:   $M_{cerradura} \leftarrow (M_{apertura} \oplus B) \ominus B$                  $\triangleright$  Mascara de cerradura morfológica
13:   $C \leftarrow \{C_1, C_2, \dots, C_n\} \in M_{cerradura}$                  $\triangleright$  Obtener contornos
14:  for cada contorno  $C_i$  do
15:     $A(C_i) \leftarrow \sum_{(x,y) \in C_i} 1$                                  $\triangleright$  Calcular áreas
16:     $\tau(C_i) \leftarrow \frac{A(C_i)}{A(CascoConvexo(C_i))}$                      $\triangleright$  Calcular convexidades
17:  end for
18:   $M_{tumor} \leftarrow \{C_i \mid A(C_i) > A_{min} \wedge \tau(C_i) > \tau_{min}\}$   $\triangleright$  Obtener mascara tumoral
19:  return  $M_{tumor}$ 
20: end procedure





















```

3. Resultados y su discusión

El marco de trabajo propuesto mostró una capacidad robusta para segmentar tumores cerebrales en imágenes de resonancia magnética. A diferencia de los métodos de umbralización fija, la binarización adaptativa mediante K-means permitió ajustarse a variaciones de contraste tumoral, logrando una segmentación más precisa incluso en gliomas heterogéneos, tumores con bordes difusos y diferentes perspectivas. La combinación con operadores morfológicos y el filtrado posterior eliminó eficazmente el ruido residual, preservando la morfología tumoral y superando las limitaciones de técnicas basadas únicamente en contornos o umbrales globales, como se muestra en la Tabla 2.

Si bien el modelo ha demostrado ser efectivo, presenta algunas limitaciones. La elección fija de clústeres puede llevar a una subsegmentación en tumores complejos, como los glioblastomas con regiones necróticas, o en imágenes con baja relación señal-ruido ($SNR < 20dB$). Además, el uso de parámetros morfológicos estáticos, como un kernel de (5×5) , restringe la adaptabilidad a diferentes resoluciones espaciales, lo que podría afectar su generalización a

Table 2. Etapas del marco de trabajo propuesto para la segmentación automática.

Categoría	Meningioma	Pituitaria	Glioma	Normal
Original				
Sobel Gradient				
K-means				
Morphology				
Convexity Filter				
Region of Interest				

otros protocolos de adquisición de imágenes. Como líneas de trabajo futuro, se plantean las siguientes mejoras:

1. Evaluar el proceso de segmentación mediante métricas como Dice Score e IoU, contrastándolo con el *Ground Truth*.
2. Comparar con otros algoritmos de segmentación, como U-Net o Gaussian Mixture Models, para analizar su desempeño relativo.
3. Vectorizar características de las imágenes para entrenar un modelo predictivo capaz de clasificar distintos tipos de tumores cerebrales.
4. Extender el marco de referencia a imágenes volumétricas en 3D, permitiendo una segmentación más robusta y una mejor integración con datos clínicos reales.

4. Conclusiones

En este trabajo, se desarrolló un marco de referencia para la segmentación automática de tumores cerebrales en imágenes de resonancia magnética, basado en tres pilares fundamentales: *i*) realce de bordes mediante el gradiente de Sobel, *ii*) segmentación con K-means para identificar las áreas de interés y *iii*) refinamiento de la máscara tumoral mediante filtros de convexidad y área.

Los resultados mostraron que este enfoque es capaz de segmentar con éxito las regiones tumorales, incluso en casos desafiantes (véase Tabla 2). En comparación con los métodos de umbralización fija, la capacidad adaptativa de K-means representa una mejora significativa, permitiendo manejar variaciones en la intensidad y morfología de los tumores.

Desde una perspectiva práctica, el marco de referencia propuesto facilita la automatización de la segmentación de tumores cerebrales, reduciendo la carga de trabajo de los especialistas y mejorando la reproducibilidad del diagnóstico. Su implementación clínica podría agilizar la identificación de tumores, optimizando el seguimiento de la enfermedad y la planificación quirúrgica, aunque su adopción dependerá de su integración con sistemas médicos y validación en datos reales.

En el ámbito teórico, este estudio profundiza en el uso de clustering para la segmentación médica, resaltando sus ventajas y limitaciones frente a otros modelos del estado del arte. Los resultados obtenidos sugieren la necesidad de enfoques de aprendizaje profundo e híbridos que combinen técnicas de agrupamiento con modelos más avanzados, abriendo nuevas líneas de investigación en segmentación multimodal y modelos autorregulados.

Agradecimientos. Los autores agradecen al Centro de Investigación e Innovación en Ciencias de la Computación y Tecnología Educativa (CIICTE) de la Facultad de Informática de la UAQ por brindar el espacio para llevar a cabo este trabajo.

References

1. Louis, D.N., Perry, A., Wesseling, P.: The WHO Classification of Tumours of the Central Nervous System: A Comprehensive Update. *Acta Neuropathologica*, 141(1), pp. 1–36 (2021)

2. Ostrom, Q.T., Gittleman, H., Xu, J.: Epidemiology and Prognosis of Meningiomas: A Population-Based Study. *Neuro-Oncology*, 19(6) (2017)
3. Molitch, M.E.: Pituitary Adenomas: Epidemiology, Diagnosis, and Management. *Pituitary*, 20(1), pp. 1–10 (2017)
4. Kumar, A., Jain, R., Wang, M.: Limitations of Conventional MRI in Distinguishing Brain Tumor Progression from Treatment-Related Effects. *Journal of Neuro-Oncology*, 148(2), pp. 231–245 (2020)
5. Smith, J.A., Patel, R., Lee, C.H.: Challenges in the Radiological Diagnosis of Brain Tumors: A Systematic Review. *Neurosurgery Clinics*, 33(4), pp. 455–467 (2022)
6. Chen, L., Zhang, W., Zhou, H.: Inter-Rater Variability in Manual Segmentation of Pituitary Adenomas: Implications for AI-Driven Tools. *Frontiers in Endocrinology*, 12 (2021)
7. Ronneberger, O., Fischer, P., Brox, T.: Deep Learning for Brain Tumor Segmentation: Pitfalls and Future Directions. *Medical Image Analysis*, 85 (2023)
8. World Health Organization.: World Health Organization Framework on Medical Technologies for Universal Health Coverage. (2022)
9. Patel, A., Mburu, S., Al-Husseini, M.: Global Disparities in Brain Tumor Diagnostics: Challenges and Opportunities for Low-Income Countries. *The Lancet Oncology*, 24(4), pp. 167–175 (2023)
10. Gupta, R., Lee, S.Y., Nkengla, L.: Open-Source AI Tools for Medical Imaging: A Pathway to Equitable Healthcare Innovation. *Nature Medicine*, 27(9), pp. 1512–1515 (2021)
11. Martínez-Luna, C., Rodríguez-Barrera, L., Kim, S.K.: Impact of Early Diagnosis on Survival and Quality of Life in Glioblastoma Patients: A Multicenter Cohort Study. *Neuro-Oncology*, 25(7), pp. 1234–1245 (2023)
12. Tanaka, H., Smith, E.R., Gupta, V.: The Role of Screening MRI in High-Risk Populations for Early Detection of Asymptomatic Meningiomas. *Journal of Neuro-Oncology*, 158(2), pp. 217–225 (2022)
13. Alentorn, A., Dehais, C., Houillier, C.: Survival Disparities in Primary Brain Tumors: A Population-Based Analysis of Gliomas, Meningiomas, and Pituitary Adenomas. *JAMA Oncology*, 7(10), pp. 1501–1509 (2021)
14. Losa, M., Mortini, P., Barzaghi, L.: Long-Term Outcomes in Pituitary Adenomas: A 20-Year Follow-Up Study. *The Journal of Clinical Endocrinology & Metabolism*, 105(12) (2020)
15. Johnson, E.R., Tanaka, K., Müller, H.: Optimizing MRI Protocols for Brain Tumor Detection: Focus on T2-FLAIR and Diffusion Sequences. *Magnetic Resonance in Medicine*, 89(4), pp. 1567–1580 (2023)
16. Wang, Q., Li, C., Smith, J.K.: The Impact of MRI Acquisition Parameters on Automated Brain Tumor Segmentation Accuracy. *NeuroImage*, 237 (2021)
17. Lee, S.H., Park, M., Kim, Y.G. Motion Artifacts in Brain MRI: Effects on Segmentation Algorithms and Correction Strategies. In: *IEEE Transactions on Medical Imaging*, 41(7), pp. 1792–1803 (2022)
18. García, M.A., López, J., Torres, A.: The Role of Signal-to-Noise Ratio in MRI for Robust Tumor Segmentation. *Frontiers in Neuroinformatics*, 17 (2023)
19. Nickparvar, M.: Brain Tumor MRI Dataset. Kaggle, URL: <https://www.kaggle.com/datasets/mnikzad/brain-tumor-mri-dataset>. (2021)
20. Gonzalez, R.C., Woods, R.E.: Digital Image Processing. Pearson (2018)
21. Lloyd, S.P.: Least Squares Quantization in PCM. In: *IEEE Transactions on Information Theory*, 28(2), pp. 129–137 (1982) doi: 10.1109/TIT.1982.1056489.

22. Otsu, N.: A Threshold Selection Method from Gray-Level Histograms. In: IEEE Transactions on Systems, Man, and Cybernetics, 9(1), pp. 62–66 (1979) doi: 10.1109/TSMC.1979.4310076.
23. Molina E., Escobar D.J, Silva H.H: Algoritmos de Binarización Robusta de Imágenes con Iluminación No Uniforme. Revista Iberoamericana de Automática e Informática Industrial, 15(3), pp. 252–261 (2017) doi: 10.4995/riai.2017.8847.
24. Nickparvar M.: Brain Tumor MRI Dataset. Kaggle, URL: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset/data>. (2021)
25. Soille P.: Morphological Image Analysis: Principles and Applications. Springer, pp. 63–103 (2003) doi: 10.1007/978-3-662-05088-0
26. Levine M.D., Arun K.: Shape Analysis in Medical Imaging: Applications to Brain Tumors. Medical Image Analysis, 24(1), pp. 187–202 (2015)