

Transformada de Gabor aplicada al análisis y caracterización de tumores cerebrales en imágenes de resonancia magnética*

Leticia Maria Acosta-Oñate^a ■ Leiner Barba-Jiménez^b ■ Lorena Paola Vargas-Quintero^c ■ Yaileth Johanna Morales-Daza^d ■ José Luis Consuegra-González^e

Resumen: Se desarrolló un método para caracterizar tumores cerebrales en imágenes de resonancia magnética (IRM) mediante el uso de filtros de Gabor. Esta técnica permite obtener un conjunto exhaustivo de características que describen con precisión la textura de la imagen en función de la dirección, frecuencia y amplitud de los patrones presentes en las zonas de interés. La identificación se basa en los coeficientes de Gabor y consiste en calcular un vector propio de textura o histograma para cada punto de la imagen, clasificándolo como perteneciente o no a una región tumoral. Para mejorar el desempeño en la caracterización, se aplican filtros de preprocesamiento a las imágenes de entrada y filtros de posprocesamiento a los coeficientes de Gabor. Los resultados muestran que las imágenes de la secuencia de FLAIR son más adecuadas para obtener el vector característico de textura que se utiliza posteriormente para registrar zonas tumorales.

Palabras clave: transformada de Gabor; análisis de tumores cerebrales; imágenes de resonancia magnética; procesamiento de imágenes

* Artículo de investigación.

a Magíster en Ciencias Físicas. Docente de la Universidad Popular del Cesar y de la Fundación Universitaria del Área Andina, Valledupar, Colombia.
Correos electrónicos: leticiaacosta@unicesar.edu.co, lacosta2@areandina.edu.co;
ORCID: <https://orcid.org/0000-0001-8713-7891>

b Doctor en Ingeniería. Docente de la Universidad Popular del Cesar, Valledupar, Colombia.
Correo electrónico: barba.leiner@unicesar.edu.co; ORCID: <https://orcid.org/0000-0002-6203-8974>

c Doctora en Ingeniería. Docente de la Universidad Popular del Cesar, Valledupar, Colombia.
Correo electrónico: vargas.llorena@unicesar.edu.co; ORCID: <https://orcid.org/0000-0001-7912-533X>

d Magíster en Ciencias Físicas. Docente de la Universidad Popular del Cesar, Valledupar, Colombia.
Correo electrónico: morales.yaileth@unicesar.edu.co; ORCID: <https://orcid.org/0000-0002-6699-4576>

e Magíster en Ingeniería - Automatización industrial. Docente de la Universidad Popular del Cesar y de la Fundación Universitaria del Área Andina, Valledupar, Colombia.
Correos electrónicos: joconsuegra@areandina.edu.co, joseconsuegra@unicesar.edu.co;
ORCID: <https://orcid.org/0000-0002-3295-3098>

Recibido: 06/10/2024 **Aceptado:** 04/09/2025 **Disponible en línea:** 22/10/2025

Cómo citar: L. M. Acosta-Oñate, L. Barba-Jiménez, L. P. Vargas- Quintero, Y. J. Morales Daza, y J. L. Consuegra González, «Transformada de Gabor aplicada al análisis y caracterización de tumores cerebrales en imágenes de resonancia magnética», Cien.Ing.Neogranadina, vol. 35, n.º 2, pp. 65–86, oct. 2025.

Gabor Transform Applied to the Analysis and Characterization of Brain Tumors in Magnetic Resonance Imaging

Abstract: A method was developed to characterize brain tumors in magnetic resonance images (MRI) using Gabor filters. This technique allows for obtaining a comprehensive set of features that accurately describe the image's texture based on the direction, frequency, and amplitude of patterns present in the regions of interest. The characterization is based on Gabor coefficients and involves calculating a texture feature vector or histogram for each point in the image, classifying it as belonging to a tumoral region or not. To improve performance in characterization, preprocessing filters are applied to the input images, and postprocessing filters are applied to the Gabor coefficients. The results show that FLAIR (*Fluid-Attenuated Inversion Recovery*) sequence images are more suitable for obtaining the texture feature vector, which is subsequently used to identify tumor regions.

Keywords: Gabor Transform, Brain Tumor Analysis, Magnetic Resonance Imaging, Image Processing.

Transformada de Gabor aplicada à análise e caracterização de tumores cerebrais em imagens de ressonância magnética

Resumo: Foi desenvolvido um método para caracterizar tumores cerebrais em imagens de ressonância magnética (IRM) mediante o uso de filtros de Gabor. Essa técnica permite obter um conjunto abrangente de características que descrevem com precisão a textura da imagem em função da direção, frequência e amplitude dos padrões presentes nas áreas de interesse. A identificação baseia-se nos coeficientes de Gabor e consiste em calcular um vetor próprio de textura ou histograma para cada ponto da imagem, classificando-o como pertencente ou não a uma região tumoral. Para melhorar o desempenho na caracterização, são aplicados filtros de pré-processamento às imagens de entrada e filtros de pós-processamento aos coeficientes de Gabor. Os resultados mostram que as imagens da sequência FLAIR são mais adequadas para obter o vetor característico de textura utilizado posteriormente para identificar as zonas tumorais.

Palavras-chave: transformada de Gabor; análise de tumores cerebrais; imagens de ressonância magnética; processamento de imagens

Introducción

El diagnóstico y evaluación de las enfermedades cerebrales, incluyendo las cancerígenas, ha sido uno de los principales retos de médicos, especialistas e investigadores. Dentro de las que atacan al cerebro se encuentran los gliomas, considerados los tumores más agresivos y sobre los que se da un impreciso diagnóstico [1]-[3]. Para hacer el análisis de este tipo de enfermedades se utilizan comúnmente las imágenes de resonancia magnética (IRM), una técnica no invasiva que no emplea radiación ionizante (rayos x) y que además sirve para determinar otros tipos de anomalías cerebrales [4]-[7]. El proceso de evaluación lo realiza el neurólogo de forma cualitativa y manual, lo que implica que este sea un proceso subjetivo que puede involucrar mucho tiempo. Teniendo en cuenta lo anterior, las técnicas de procesamiento digital de imágenes y las de inteligencia artificial, se han convertido en alternativas para desarrollar herramientas de ayuda diagnóstica para los tumores y otras afecciones [8]-[11].

El análisis de tumores cerebrales en imágenes de resonancia magnética, el procesamiento digital de imágenes y las técnicas de inteligencia artificial para las cuales se emplean algoritmos matemáticos complejos [12], se hacen con varios propósitos. Los más importantes son: 1) partir las imágenes en múltiples regiones; 2) cambiar la imagen a un espacio de representación diferente y óptimo para el estudio; 3) identificar, localizar, clasificar tumores y sus subregiones, y 4) ver el tejido sano del cerebro. De este modo, la anomalía será más fácil de observar y se proporcionará al médico especialista una ayuda diagnóstica más detallada y un conjunto de herramientas poderosas para abordar el problema [7]-[8],[13]-[14].

Adicionalmente, se busca analizar y descomponer la imagen con el fin de segmentar o distinguir las variaciones de intensidad por medio de la aplicación de técnicas basadas en el análisis de texturas que contribuyen a distinguir una región de otra, debido a que contienen información espacial local del color o niveles de intensidad en una [15]. Un importante número de referencias científicas evidencia el uso de diferentes métodos y

estrategias para una mayor precisión y optimización de los tiempos de análisis, buscando entregar un diagnóstico sobre la presencia de un tumor cerebral, utilizando como estrategia la segmentación y caracterización del glioma. [16]-[19].

En este contexto, la transformada de Gabor, un caso especial de la transformada corta de Fourier (STFT, por sus siglas en inglés), ha sido de mucho interés por su capacidad para discriminar las diferentes texturas de una imagen. Su uso permite determinar los valores de frecuencias de una señal en un determinado tiempo [20]. Con esta se obtienen características y propiedades similares al sistema de visión humano que involucra el direccionamiento local y la modulación de una función gaussiana con una señal senoidal. Este tipo de modelamiento es propio de las células corticales de la visión temprana [21]-[22]. De igual forma, a partir de esta transformada se pueden codificar detalles relevantes en los registros por lo cual resulta útil para examinar imágenes médicas [23]-[25].

La transformada de Gabor y las herramientas de entrenamiento como las redes neuronales artificiales se han usado con éxito para observar las propiedades de la textura de las imágenes e identificar y clasificar tramas tumorales con precisión, siendo esta una etapa requerida durante un proceso de segmentación [26]. Otros autores también han utilizado los filtros de Gabor para identificar el crecimiento tumoral anormal en el cerebro [27].

Una de las principales dificultades en el procesamiento imagenológico de tumores cerebrales es que no se puede tener acceso a bases de datos públicas con facilidad y aquellas que están disponibles no evidencian si las imágenes contienen tumores primarios, secundarios de crecimiento sólido o infiltrativo, tampoco denotan aspectos clínicos como el estado de la enfermedad del paciente ni los tratamientos realizados como radioterapia o cavidades por cirugía. Eso dificulta la comparación de los modelos matemáticos empleados para procesos de segmentación y clasificación. Sin embargo, con la base de datos BraTS se accede a un conjunto de imágenes que nos permiten probar los modelos propuestos y conocer la ubicación del tumor [28], [29].

El diagnóstico de las enfermedades es una tarea que realiza un médico especialista a partir de una inspección y evaluación visual de las imágenes adquiridas. Convencionalmente, la marcación de los tumores se hace de forma manual lo que se convierte en una tarea tediosa, que demanda mucho tiempo y que además depende de la experiencia del especialista. Por ello, en este trabajo se desarrolló un mecanismo de análisis que involucra la caracterización de tejidos de tumores cerebrales mediante modelos matemáticos, estadísticos y de inteligencia artificial, con el objetivo de proporcionar una herramienta de ayuda al experto en su tarea.

Para desarrollar el trabajo, empleamos imágenes de resonancia magnética extraídas de la base de datos BraTS 2017. En una etapa inicial, estas se someten a un proceso para mejorar su calidad. A continuación, se definen las zonas tumoral y no tumoral, seleccionando un número idéntico de puntos o píxeles, que se utilizan para entrenar un algoritmo de inteligencia artificial. Utilizamos la transformada (o filtros) de Gabor para extraer atributos de textura de ambas regiones, con lesión y sin lesión.

Los filtros de Gabor generan coeficientes para cada punto en la imagen, que capturan diversos rasgos al modificar la escala de Gauss, ajustar el ángulo de rotación del filtro y variar las frecuencias de la senoidal [27]. Los filtros se representan


en forma matricial y posteriormente se someten a un análisis de histograma, en el que se construye un vector de coeficientes de Gabor para especificar las zonas tumorales y las de tejido sano, y para diferenciar y entrenar de manera efectiva un algoritmo de inteligencia artificial que conduce a identificar y validar la presencia de tumores en función de las cualidades extraídas.

Metodología

Esta sección describe el proceso de caracterización de tumores cerebrales propuesto a partir de imágenes de resonancia magnética, que busca desarrollar un mecanismo automático para reconocer o diferenciar tejidos tumorales y tejidos sanos. El método empleado son las técnicas de procesamiento de imágenes, los filtros de Gabor y los métodos de aprendizaje de máquinas. En la figura 1 se muestra el esquema general del proceso desarrollado, que consta de las siguientes etapas:

- Etapa 1. Captura de la imagen y preprocesamiento
- Etapa 2. Descomposición en texturas con filtros de Gabor
- Etapa 3. Caracterización a partir de los coeficientes de textura
- Etapa 4. Clasificación

Figura 1. Segmentación y caracterización de tumores cerebrales aplicando la transformada de Gabor



Fuente: elaboración propia (2024).

Captura de la imagen y preprocesamiento

Las imágenes usadas se tomaron de una base de datos pública, conocida como BraTS 2017, que contiene imágenes médicas —obtenidas de los protocolos o secuencias T1, T2 y recuperación de la inversión atenuada de fluido (FLAIR, por sus siglas inglés), y de agentes de contraste— de 65 pacientes con tumores cerebrales [29]. Cada uno de estos protocolos proporciona información valiosa para la detección y definición de estos tumores desde perspectivas distintas.


El protocolo FLAIR permite identificar gliomas y áreas de edema circundantes a los tumores. Con este tipo de imágenes es común utilizar características de textura basadas en la homogeneidad, la entropía y la energía [30].

Las que se obtuvieron con la secuencia T1 son muy útiles para visualizar la anatomía estructural

del cerebro, lo que facilita la detección de tumores con alta densidad de proteínas y líquidos. Por medio de este protocolo es frecuente el uso de características de textura que codifican la variabilidad de intensidad, la homogeneidad y la distribución de intensidad en las regiones con y sin lesión [31].

Al ser sensibles a cambios en la cantidad de agua en los tejidos, las imágenes T2 resultan especialmente útiles para advertir edema peritumoral y tumores que retienen agua. En estas imágenes, parámetros de textura que miden la rugosidad, la correlación y el contraste son de gran valor para catalogar la lesión y su relación con el tejido circundante [32]. Con base en la descripción anterior, nuestro análisis se ha centrado en las secuencias T1 y FLAIR para describir la zona tumoral con respecto a los tejidos sanos. La figura 2 detalla el procedimiento seguido en esta primera etapa.

Figura 2. Preprocesamiento y normalización de las imágenes de RM de análisis



Fuente: elaboración propia (2024).

De la base de datos se seleccionaron imágenes de veinte pacientes como soporte para el diseño del método de caracterización. Para el preprocesamiento se efectúa un proceso de normalización y de eliminación de ruido, usando un filtro gaussiano cuya respuesta impulso viene dada por la ecuación (1)

$$h(s, t) = K e^{-\frac{s^2+t^2}{2\sigma^2}} \quad (1)$$

donde K es una constante y σ es la desviación estándar o ancho de la función gaussiana. Definiendo la variable $r^2 = \sqrt{s^2 + t^2}$, solo se codificaría la distancia espacial de cada punto del *kernel* a su centro. Para la normalización se selecciona la técnica conocida como “z-score” de uso frecuente en resonancia magnética (RM) y que busca rectificar las desigualdades en la luminosidad de la imagen y mejorar de forma significativa la inhomogeneidad intrínseca en las imágenes de IRM [12]. La normalización se obtiene tal como lo muestra la ecuación (2)

$$In = \frac{I - \mu \text{ (toda la región cerebral)}}{\sigma \text{ (toda la región cerebral)}} \quad (2)$$

donde In es la imagen normalizada; I es la imagen de entrada; σ es la desviación estándar de los niveles de intensidad de la región cerebral; μ es el promedio de intensidad de la región cerebral.

Descomposición en texturas con filtros de Gabor

Una vez preprocesada, la imagen se descompone en coeficientes de textura usando los filtros de Gabor (ecuación 3), para diferentes valores de σ_x , σ_y , f_0 y θ .

$$H_{\sigma_x, \sigma_y, f_0, \theta}(u', v') = e^{-2\pi^2((u' - f_0)^2 \sigma_x^2 + v'^2 \sigma_y^2)} \quad (3)$$

donde

σ_y : eje menor de la función gaussiana

σ_x : eje mayor de la función gaussiana

f_0 : frecuencia central del filtro

θ : direccionamiento o rotación

De acuerdo con la ecuación (3), se configuró σ_x , σ_y , f_0 , θ , teniendo en cuenta que:

$\gamma = \frac{\sigma_y}{\sigma_x}$; $\gamma = 1$ indica que

$$\sigma_x = \sigma_y; \gamma < 1; \lambda = \frac{1}{f_0}$$

Para la descomposición se utilizaron estos parámetros en los filtros de Gabor: $\gamma = 0.5$, $\sigma_x = \gamma = 2.2$, $\lambda = \{2, 8, 14\}$ y $\theta = \{0^\circ, 30^\circ, 60^\circ, 90^\circ, 120^\circ, 150^\circ\}$. A partir de ellos se generaron 18 filtros de Gabor que resultaron en la misma cantidad de coeficientes de textura en los que se desagrega la imagen de resonancia magnética. Los filtros se aplican por convolución en el dominio espacial (ecuación 4).

$$\hat{i}(x, y) = \{f * h\}(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b f(s, t) h(x-s, y-t) \quad (4)$$

donde $*$ denota la operación de convolución, $a = \frac{p-1}{2}$ y $b = \frac{q-1}{2}$. Durante el proceso de filtrado resulta difícil eliminar todas las componentes del ruido por lo que $\hat{i}(x, y)$ es una estimación de la imagen sin ruido. En el dominio de la frecuencia, la convolución se expresa como una simple multiplicación o en el dominio de la frecuencia (ecuación 5).

$$\hat{I}(u, v) = F(u, v) H(u, v) \quad (5)$$

donde $H(u, v)$ es la transformada de Fourier del *kernel* $h(x, y)$. El resultado es un conjunto de imágenes que aquí se llaman coeficientes o textura o de Gabor y se denotan como $c_{\sigma_x, \gamma, \lambda, \theta}^g$ (ecuación 6).

$$c_{\sigma_x, \gamma, \lambda, \theta}^g(x, y) = f(x, y) * h_{\sigma_x, \gamma, \lambda, \theta}(x, y) \quad (6)$$


donde $f(x, y)$ es la imagen de entrada y $h_{\gamma, \lambda, \theta}(x, y)$ son los filtros configurados usando los parámetros anteriores. Por simplicidad, se configuraron filtros de Gabor para diferentes valores de λ y θ , y se han fijado los valores de σ_x y γ . Los coeficientes de textura obtenidos a partir de la aplicación de los filtros de Gabor se agrupan tal como se muestra en la tabla 1.

Por simplicidad, los coeficientes de textura se denotan como $c_1^g, \dots, c_{18}^g$. Es de resaltar que el objetivo fundamental de la disgregación es detectar los parámetros de bordes, esquinas, intensidad y textura en general que permiten diferenciar o clasificar mejor los tejidos tumorales y los sanos, a partir de las imágenes de resonancia magnética. La figura 3 ilustra un esquema del procedimiento seguido en la etapa de descomposición en textura con filtros de Gabor.

Tabla 1. Distribución de los coeficientes de textura obtenidos luego de aplicar los filtros de Gabor

	$\theta = 0^\circ$	$\theta = 30^\circ$	$\theta = 60^\circ$	$\theta = 90^\circ$	$\theta = 120^\circ$	$\theta = 150^\circ$
$\lambda = 2$	$c_{2,2,0,5,2,0}^g = c_1$	$c_{2,2,0,5,2,30}^g =$	$c_{2,2,0,5,2,60}^g =$	$c_{2,2,0,5,2,90}^g =$	$c_{2,2,0,5,2,120}^g =$	$c_{2,2,0,5,2,150}^g =$
$\lambda = 8$	$c_{2,2,0,5,8,0}^g = c_7$	$c_{2,2,0,5,8,30}^g =$	$c_{2,2,0,5,8,60}^g =$	$c_{2,2,0,5,8,90}^g =$	$c_{2,2,0,5,8,120}^g =$	$c_{2,2,0,5,8,150}^g =$
$\lambda = 14$	$c_{2,2,0,5,14,0}^g = c$	$c_{2,2,0,5,14,30}^g =$	$c_{2,2,0,5,14,60}^g =$	$c_{2,2,0,5,14,90}^g =$	$c_{2,2,0,5,14,120}^g =$	$c_{2,2,0,5,14,150}^g =$

Fuente: elaboración propia (2024).

Figura 3. Extracción de características de textura aplicando filtros de Gabor

Fuente: elaboración propia (2024).

Los filtros de Gabor son de naturaleza compleja conjugada, es decir, que contienen una parte real y otra imaginaria, permitiendo extraer propiedades de la región de estudio de manera fasorial. Los coeficientes de Gabor resultantes son también complejos conjugados por lo que se puede analizar la región de interés en términos de la magnitud $|c_{\sigma_x, \gamma, \lambda, \theta}^g(x, y)|$ que brinda información sobre el detalle presente en la región, y varía en función del ancho de banda de la gaussiana definida para el filtro, y de la fase $(c_{\sigma_x, \gamma, \lambda, \theta}^g(x, y))$, útil para extraer características relacionadas con el contorno y con el delineado de los bordes de los objetos. De la misma forma, se puede analizar el proceso de caracterización usando solo la parte real o imaginaria de los coeficientes de Gabor.

Por otro lado, para homogeneizar los coeficientes de Gabor en regiones cercanas, se aplica un filtro de suavizado a cada uno de los coeficientes resultantes. Eso ayuda también a eliminar el ruido que se genera en el proceso de descomposición.

Caracterización a partir de los coeficientes de textura

Después de completar la extracción de la textura de la imagen usando los filtros de Gabor, se construye un mecanismo para delimitar las regiones o tejidos tumorales. Esto se logra mediante la definición de una función discreta que llamaremos vector característico o histograma elaborado a partir de esos coeficientes de textura. Partimos de

la hipótesis de que los de la región tumoral y de los tejidos sanos es diferente. Por tanto, la caracterización se hace definiendo un conjunto vectorial con los coeficientes de Gabor. En la literatura no existe un criterio único para construir un vector con información de textura. En este proyecto se han definido dos formas: 1) empleando los coeficientes de textura originales obtenidos, y 2) aprovechando la información estadística calculada a partir de los coeficientes de textura. Para el primer caso, el vector característico queda tal como se ve en la ecuación 7),

$$V^g(x, y) = \{c_1^g, c_2^g, \dots, c_{18}^g\}(x, y) \quad (7)$$

Es de anotar que la caracterización se hace para cada píxel de la imagen. Eso implica que para cada posición (x, y) hay un vector que se debe calcular. Para el segundo caso es necesario definir unos parámetros estadísticos a partir de los coeficientes de textura. En este proyecto se optó por usar la media μ y la desviación estándar σ como medidas estadísticas que se obtienen en una vecindad o ventana w alrededor de la posición (x, y) de cada coeficiente c_k^g , con $k = 1, 2, \dots, 18$. Luego, el vector característico queda determinado como la ecuación 8.

$$V^g(x, y)_w = \{\mu(c_1^g), \sigma(c_1^g), \mu(c_2^g), \sigma(c_2^g), \dots, \mu(c_{18}^g), \sigma(c_{18}^g)\}(x, y) \quad (8)$$

En este segundo caso es el doble de tamaño en comparación con el de la ecuación 9, debido a que por cada coeficiente de textura se han obtenido dos parámetros de caracterización. Finalmente, se aplicará $V^g(x, y)$ para definir si el píxel (x, y) de la imagen $f(x, y)$ corresponde a tejido sano o tumoral.

$$c_{\sigma_x, \gamma, \lambda, \theta}^g(x, y) = f(x, y) * h_{\sigma_x, \gamma, \lambda, \theta}(x, y) \quad (9)$$

donde $f(x, y)$ es la imagen de entrada y $h_{\gamma, \lambda, \theta}(x, y)$ son los filtros configurados empleando los parámetros anteriores. Por simplicidad, se configuraron filtros de Gabor para diferentes valores de λ y θ , y se han fijado los valores de σ_x y γ .

Clasificación

Con el proceso de clasificación se busca saber si un determinado píxel de la imagen corresponde

a un tejido tumoral o sano. Por tanto, el vector característico de textura construido debe contener la información necesaria para establecer si el elemento analizado de la imagen forma parte de una región donde hay un tumor. En razón a que el vector característico está en un espacio de muy alta dimensión, su análisis por inspección visual para ordenar tejidos tumorales y sanos es poco práctico. Eso supone que el análisis debe hacerse con un modelo de clasificación robusto. En la literatura existen muchos métodos de aprendizaje de máquinas que han demostrado ser bastante útiles en este punto.

La tarea de determinar si un píxel específico de la imagen pertenece o no a un tumor a partir de su vector característico de textura se enmarca en un problema de clasificación binaria, es decir, con dos posibles resultados. Para abordar este desafío, en este proyecto se han adoptado dos métodos de categorización: 1) máquinas de vectores de soporte (svm, por sus siglas en inglés), y 2) redes neuronales artificiales (RNA, en español; ANN, en inglés) clásicas. No obstante, el objetivo fundamental es desarrollar un mecanismo de caracterización adecuado que minimice la complejidad del modelo de clasificación.

Resultados y análisis

En esta sección se presentan los resultados obtenidos y se describen además los experimentos realizados. Para el efecto, se utilizó la base de datos BraTS 2017 [29], que contiene imágenes de neuronales artificiales (RNA) de pacientes con tumores, es de libre acceso, y ha sido diseñada para evaluar resultados de investigación sobre el tema de detección y segmentación de tumores.

Materiales

El conjunto de datos BraTS empleado consta de 65 volúmenes de neuronales artificiales (RNA) multicontraste de pacientes con glioma, 14 de los cuales tienen gliomas de bajo grado (diagnóstico histológico: astrocitomas u oligoastrocitomas) y 51 de alto grado (astrocitomas anaplásicos y tumores glioblastoma multiforme). Las imágenes cerebrales se adquirieron en etapas previas y posteriores

al tratamiento (o terapia) de los pacientes en centros diferentes, como las universidades de Berna, Debrecen y Heidelberg, y el Hospital General de Massachusetts a lo largo de varios años, utilizando escáneres de resonadores magnéticos de diferentes proveedores, con diversos campos magnéticos (1.5T y 3T). Todos los volúmenes de imágenes del conjunto de datos tienen cuatro secuencias de imágenes de resonancia magnética.

- 1) T1: adquisiciones 2D sagitales o axiales, de imagen nativa, ponderadas en T1, con un espesor de corte de 1 a 6 mm.
- 2) T1c: imagen ponderada en T1, realzada con contraste (gadolinio), con adquisición 3D y tamaño de vóxel isotrópico de 1 mm para la mayoría de los pacientes. Un vóxel isotrópico de 1 mm es un cubo en una imagen tridimensional donde cada lado mide 1 mm, asegurando una resolución espacial uniforme en todas las direcciones, esencial para una segmentación y análisis precisos del tejido cerebral en estudios de resonancia magnética.
- 3) T2: imagen potenciada en T2, adquisición axial 2D, con espesor de corte de 2 a 6 mm.
- 4) Imagen FLAIR ponderada en T2, adquisiciones 2D axiales, coronales o sagitales, espesor de corte de 2 a 6 mm.

Para homogeneizar las imágenes de cada sujeto se registraron conjuntamente a la secuencia de resonancia magnética T1c, que presenta la más alta resolución en la mayoría de los casos. Después de eso, se volvieron a muestrear a una resolución isotrópica de 1 mm en una orientación axial estandarizada con un interpolador lineal. Los resultados tienen además una dimensión o tamaño discreto de 256 x 256, con una resolución de 12 bits por vóxel. Para cada una se suministra una máscara de segmentación, realizada por médicos especialistas en esta área de la salud, que muestra la región ocupada por el tumor. En [29] se presentan de forma más detallada los volúmenes de las imágenes de resonancia magnética (IRM) de BraTS. La figura 4 ilustra dos ejemplos del conjunto de datos

de imágenes BraTS usadas para desarrollar el proyecto. En ella se demarca la región tumoral.

Pruebas y experimentos

El proceso de evaluación incluyó una serie de pruebas con las imágenes de análisis. Es de recordar que la caracterización consiste en varias etapas: preprocesamiento, descomposición con filtros de Gabor, posprocesamiento de los coeficientes y construcción del vector característico. Las dos primeras son de alguna forma opcionales. El objetivo de caracterizar los tumores en las imágenes de resonancia magnética por medio de un vector de textura (V^g) es que se puedan detectar regiones tumorales y tejidos sanos con un método de clasificación. Esto a su vez permite fraccionar la región de la lesión para hacer cuantificaciones posteriores. No obstante, en este proceso no se discriminó por tipo de glioma. Se hicieron varios experimentos de construcción de V^g teniendo en cuenta la combinación de las siguientes condiciones:


- 1) Sin preprocesar las imágenes originales con el filtro de suavizado
- 2) Usando un suavizado previo de las imágenes de entrada
- 3) A partir de los coeficientes de Gabor sin procesamiento posterior
- 4) Con base en la estadística local de los coeficientes de Gabor
- 5) Desde los coeficientes de Gabor usando un filtro de suavizado posterior
- 6) Con fundamento en las partes real e imaginaria de los coeficientes de Gabor
- 7) Desde la magnitud y la fase de los coeficientes de Gabor

Una práctica muy común en tareas de procesamiento de imágenes es hacer una inspección visual o gráfica de las resultantes de cada proceso. En esta sección mostramos los diferentes métodos de procesamiento asociados a las etapas del método de caracterización desarrollado. Como base se usarán las imágenes de entrada mostradas en la figura 4.

En la figura 5 se observa el resultado de aplicar el filtro de preprocesamiento gaussiano o de baja frecuencia a las dos imágenes de resonancia magnética de la figura 4. Las regiones se hacen más homogéneas,

pero surge el agravante de que los bordes se vuelven borrosos y pierden su fineza. Esta desventaja es más notoria en la medida en que se aumenta la escala de la función gaussiana usada para el filtrado.


Figura 4. Imágenes de la base de datos BraTS



Nota: a) Secuencia FLAIR. b) Secuencia T1w. Se trata de diferentes pacientes.

Fuente: [29].

Figura 5. Imágenes de entrada filtrada en baja frecuencia con *kernel* gaussiano



Nota: a) $\sigma = 0.8$, b) $\sigma = 1.5$, y c) $\sigma = 2.5$.

Fuente: elaboración propia (2024).

En la figura 6 se evidencian los coeficientes resultantes luego de aplicar los filtros de Gabor a una imagen de resonancia magnética de entrada de la base de datos de análisis. En este caso se ilustra la parte real de los coeficientes.

Las figuras 7 y 8 ilustran la magnitud y la fase de los coeficientes de Gabor obtenidos de la misma imagen. En general, los coeficientes exhiben la textura en diferentes direcciones y longitudes de onda.

En la figura 6 se resaltan los detalles estructurales y los bordes finos, mientras que en la figura 7, la magnitud revela la energía en los bordes de manera moderada. Respecto a los patrones texturales predominantes, la parte real tiene baja capacidad para identificar patrones amplios, lo que significa que la imagen no es efectiva para capturar estructuras texturales grandes o repetitivas, sino para centrarse más en detalles finos y locales. Por otro lado, la magnitud identifica patrones texturales dominantes, destacando texturas y patrones repetitivos predominantes.


En términos de localización precisa, la parte real ofrece alta precisión en la ubicación de características finas y buena sensibilidad a variaciones de alta frecuencia, lo que implica que la imagen puede detectar cambios rápidos y detalles

minuciosos, capturando variaciones finas en la textura. Mientras, la magnitud mezcla detalles finos y gruesos de forma moderada, detecta energía en una amplia gama de frecuencias y proporciona una visión completa de la textura que refleja detalles finos y gruesos.


Para las estructuras globales la parte real se concentra en elementos locales y es altamente sensible al ruido, debido a los datos finos. A su turno, y de manera moderada, la magnitud combina detalles locales y globales, y captura ruido y señal útil, lo que expresa un balance entre ambos y muestra la información útil, así como el ruido presente en la imagen.

Adicionalmente, en la figura 9 se muestran los resultados de aplicar un filtro de baja frecuencia a la magnitud de los coeficientes de Gabor.


Figura 6. Parte real de los coeficientes de Gabor resultantes luego de procesar la imagen de la figura 4a



Fuente: elaboración propia (2024).

Figura 7. Magnitud de los coeficientes de Gabor resultantes luego de procesar la imagen de la figura 4a

Fuente: elaboración propia (2024).

Figura 8. Fase de los coeficientes de Gabor resultantes de procesar la imagen de la figura 4a

Fuente: elaboración propia (2024).

Figura 9. Magnitud suavizada de los coeficientes de Gabor resultantes luego de procesar la imagen de la figura 4a

Fuente: elaboración propia (2024).

Clasificación

No resulta práctico hacer una inspección visual al vector característico de textura obtenido, sobre todo a la hora de determinar si un píxel específico de la imagen de resonancia magnética forma parte de una zona tumoral o sana. Esto obedece a la alta dimensionalidad del vector de textura usado para la clasificación. Por tal motivo, en este proyecto se optó por usar algoritmos de aprendizaje de máquinas para clasificar el vector característico. Se emplearon y evaluaron dos métodos: SVM y RNA. Los modelos resultantes son necesarios y complementarios a la caracterización hecha con los filtros de Gabor. A continuación, se describe el procedimiento general del mecanismo clásico de entrenamiento que

adoptamos para configurar el método aprendizaje de máquinas.

- 1) Se seleccionaron 62 imágenes de entrenamiento de la base de datos BraTS.
- 2) En cada una de ellas se identificaron las regiones tumoral y no tumoral, teniendo como referencia la máscara de segmentación incluida en cada volumen de la base de datos.
- 3) De forma aleatoria se escogió un máximo de 50 puntos de entrenamiento en las regiones tumoral y sana, respectivamente. La figura 10 muestra este procedimiento para una de las 62 imágenes de entrenamiento. Los puntos rojos corresponden a la región tumoral mientras que los verdes a la sana. Es de anotar que en este paso solo se hace una localización espacial de tales puntos.

Figura 10. Selección de puntos de entrenamiento en las imágenes de resonancia magnética.

Fuente: elaboración propia (2024).

- 1) Cada una de las imágenes de entrenamiento se preprocesa y luego se proyecta sobre los filtros de Gabor para obtener los coeficientes de textura. En este punto, se hicieron pruebas con las imágenes de las secuencias FLAIR y T1w de forma separada.
 - 2) A partir de los coeficientes de Gabor, se construye el vector característico de textura de los puntos localizados en el paso 3), usando como base la magnitud, fase o parte real de los coeficientes, calculados bien sea sobre los coeficientes de Gabor originales o posprocesados.
 - 3) Aplicando los vectores característicos de cada uno de los puntos de entrenamiento, tumorales y no tumorales, se elabora una matriz que sirve para configurar el método de aprendizaje de máquinas seleccionado.
- 2) En total, se utilizaron 6210 vectores de textura para evaluar el desempeño. De ellos, una mitad (3105) es de tejido sano y la otra tumoral. El 85 % de los datos se dedicó al entrenamiento de los algoritmos de aprendizaje de máquinas y el 15 % restante para la validación. Se trata de un problema de clasificación binario en el que el vector característico de textura puede ser de dos clases: al tejido tumoral se le asignó un valor de salida de +1, y al sano se le asignó la etiqueta de -1.
 - 3) La tabla 2 muestra los resultados de la exactitud obtenida en la clasificación usando imágenes de la secuencia FLAIR para diferentes casos en cuanto a la construcción del vector de textura característico, y evaluando con los tres algoritmos de aprendizaje de máquinas seleccionados: máquinas de vectores de soporte SVM, *kernel SVM* y RNA. El caso del vector de textura se construyó a partir de la parte real, magnitud y fase de los coeficientes de Gabor. Se evaluó también usando un filtro gaussiano de posprocesamiento aplicado a los coeficientes de Gabor antes de crear el vector característico de textura. Solo se empleó una normalización inicial sobre las imágenes de entrada sin filtro de preprocesamiento. Además, se consideró un vector característico utilizando directamente los coeficientes de textura de Gabor, lo que dio como resultado un vector de tamaño,

Desempeño

- 1) Para evaluar el desempeño de la caracterización y clasificación se escogieron las herramientas de configuración y aprendizaje de máquinas del *software* MATLAB 2023b®. Se tuvieron en cuenta métricas de desempeño como la exactitud, la matriz de confusión y la curva característica operativa del receptor ROC. Para ampliar la información véase: <https://la.mathworks.com/help/stats/assess-classifier-performance.html>

y utilizando la estadística (media y desviación estándar) local alrededor de cada punto, se obtuvo un vector de tamaño .

La tabla 2 demuestra la superioridad de la parte real de los coeficientes de Gabor en la clasificación de los tejidos sano y tumoral en imágenes FLAIR de resonancia magnética, destacando su efectividad

en la captura de detalles estructurales finos y en los bordes, esenciales para distinguir entre tejidos. Esto se refleja en la alta precisión de la parte real para localizar características relevantes. Al ser altamente sensible a variaciones de alta frecuencia, esta parte permite detectar pequeños cambios en la textura, cruciales para la caracterización precisa de los tumores cerebrales.

Tabla 2. Resultados de exactitud en la clasificación empleando las imágenes de la secuencia FLAIR

Coeficientes de Gabor			Exactitud (%) del clasificador		
Tipo de coeficiente	Filtro de posprocesamiento aplicado a los coeficientes de Gabor	Tamaño del vector de textura Vg	SVM	Kernel SVM	RNA
Parte real	Filtro gaussiano	K = 18	91,6	92,1	92,1
		K = 36	93,1	93,2	92,9
	Sin filtro	K = 18	91,2	90,7	90,8
		K = 36	92,5	92,0	91,8
Magnitud	Filtro gaussiano	K = 18	79,9	83,2	85,7
		K = 36	82,0	87,7	86,9
	Sin filtro	K = 18	79,1	82,2	83,9
		K = 36	82,1	85,3	84,1
Fase	Filtro gaussiano	K = 18	61,3	81,9	85,4
		K = 36	83,6	84,4	84,7
	Sin filtro	K = 18	59,4	85,8	88,0
		K = 36	87,0	86,2	86,8

Nota: Se normalizó con z-score, sin filtrado de preprocesamiento en la imagen de entrada (antes de aplicar la descomposición de Gabor).

Fuente: elaboración propia.

La robustez de la parte real se comprueba en su rendimiento consistente y sin el uso de un filtro gaussiano, con mejoras observadas al aplicar el filtro, que ayudan a suavizar el ruido sin sacrificar detalles importantes. Al comparar los resultados, se observa que el uso del filtro mejora ligeramente la exactitud en todos los clasificadores y para ambos tamaños de vector de textura (K = 18 y K = 36), indicando que el filtro proporciona un beneficio tangible en la clasificación al reducir el ruido y mantener la claridad de la textura.

La mayor exactitud de la parte real en comparación con la magnitud y la fase, en todos los casos y al aplicar un filtro gaussiano, subraya su menor susceptibilidad al ruido y su capacidad para proporcionar una representación textural más limpia y confiable. Esto la convierte en la mejor opción para

los algoritmos de clasificación de SVM, *kernel SVM* y RNA, que encuentran más fácil trabajar con las características estructurales claras y definidas de la parte real y que resultan en un desempeño superior en la caracterización de tumores cerebrales.

La tabla 3 muestra los resultados obtenidos, pero con las imágenes de la secuencia T1w. No obstante, en la tabla 4 se tomó la configuración que arrojó el mejor resultado general, resaltado en la tabla 2, y se comparó con el mismo algoritmo, pero ahora utilizando un filtro pasa bajo tipo gaussiano de preprocesamiento aplicado a las imágenes de entrada.

Las imágenes FLAIR (tabla 2) están diseñadas para resaltar lesiones y estructuras patológicas —al suprimir el líquido cerebroespinal—, también para facilitar la identificación de características de textura

más distintivas. Esto se advierte en las altas tasas de exactitud en la clasificación, alcanzando hasta un 93,2 % para SVM en la parte real con filtro gaussiano y un tamaño de $K = 36$. En contraste, las imágenes T1w (tabla 3) proporcionan una visualización más

clara de la anatomía normal, pero no destacan las características patológicas con la misma claridad. Esto implica una menor exactitud en la clasificación, con un máximo de 63,7 % para la RNA en la parte real con filtro promedio y un tamaño de $K = 36$.

Tabla 3. Resultados de exactitud en la clasificación mediante las imágenes tipo T1w

Coeficientes de Gabor			Exactitud (%) del clasificador		
	Filtro de posprocesamiento aplicado a los coeficientes de Gabor	Tamaño K del vector de textura V^g	SVM	Kernel SVM	RNA
Parte real	Filtro promedio	K = 18	60,0	60,1	61,4
		K = 36	62,7	62,6	63,7
	Sin filtro	K = 18	55,5	58,6	58,7
		K = 36	60,3	62,7	63,7
Magnitud	Filtro promedio	K = 18	59,6	60,0	62,7
		K = 36	63,2	64,7	66,5
	Sin filtro	K = 18	57,0	57,6	59,0
		K = 36	59,6	59,0	61,3
Fase	Filtro promedio	K = 18	54,2	53,8	59,8
		K = 36	56,3	61,2	61,7
	Sin filtro	K = 18	50,9	51,8	52,1
		K = 36	53,0	56,6	56,4

Nota: Normalizada con z-score, sin filtrado de preprocesamiento en la imagen de entrada (antes de aplicar la descomposición de Gabor).

Fuente: elaboración propia.

La aplicación del filtro gaussiano en las imágenes FLAIR mejora o mantiene la exactitud de la clasificación. Por ejemplo, en la parte real con un tamaño de $K = 36$, la exactitud alcanza hasta 93,2 % con SVM, 93,2 % con *kernel SVM* y 92,9 % con RNA (tabla 2). Esto indica que el filtro gaussiano es eficaz para reducir el ruido y mejorar la calidad de las características extraídas, facilitando una clasificación más precisa.

En contraste, el filtro promedio aplicado a las imágenes T1w también muestra una mejora en comparación con el caso sin filtro, pero menos pronunciada. Por ejemplo, en la parte real con $K = 36$, la exactitud alcanza 62,7 % con SVM, 62,6 % con *kernel SVM* y 63,7 % RNA (tabla 3). Esto sugiere que el filtro promedio produce un impacto menor en la mejora de la calidad de las características en las imágenes T1w en cotejo con el filtro gaussiano en las imágenes FLAIR.

Los resultados de la parte real muestran una exactitud notablemente superior en las imágenes FLAIR si se contrasta con las T1w. Asimismo, la exactitud con la parte real sin filtro es inferior, ya que alcanza un máximo de 55,5 % para máquinas de vectores de soporte SVM, con $K = 18$. Aunque el filtro promedio brinda una mejora moderada, la exactitud sigue siendo menor en comparación con las imágenes FLAIR.

En cuanto a la magnitud y la fase, el filtro aumenta la exactitud en ambas imágenes, pero las mejoras son más evidentes en las imágenes FLAIR. Para la fase, se observa un rendimiento significativamente mejorado con el filtro en las imágenes FLAIR, mientras que el filtro promedio tiene un impacto menor en la mejora de la exactitud en las imágenes T1w.

Tabla 4. Resultados de exactitud en la clasificación usando las imágenes tipo FLAIR

Tipo de filtro de preprocesamiento	Exactitud (%) del clasificador		
	svm	Kernel svm (kernel gaussiano)	RNA (10 neuronas en la capa oculta)
Sin filtro	93,1	93,2	92,9
Filtro gaussiano	93,7	93,9	93,2

Nota: Normalizada con z-score, 36 elementos en el vector de textura y en la parte real de los coeficientes de textura filtrados con *kernel* gaussiano.

* Se comparan los resultados aplicando y sin aplicar un filtro pasa bajo de preprocesamiento en las imágenes de entrada.

Fuente: elaboración propia.

La aplicación del filtro gaussiano como preprocesamiento en imágenes tipo FLAIR mejora de modo significativo la exactitud para todos los clasificadores evaluados.

Sin aplicar el filtro, la exactitud es de 93,1 % con svm, 93,2 % con *kernel svm* y 92,9 % con RNA. De lo contrario, la exactitud aumenta a 93,7 % para svm, 93,9 % para *kernel svm* y 93,2 % para RNA. Esto indica que el filtro gaussiano ayuda a aumentar la precisión general de la clasificación.


El filtro gaussiano actúa como un filtro pasa bajo que suaviza la imagen y reduce el ruido. Este preprocesamiento es crucial porque ayuda a eliminar variaciones no deseadas y ruido en las imágenes, optimando la calidad de las características de textura extraídas; además, se vuelven más limpias y representativas, lo que conduce a una alta discriminación entre las clases durante el proceso de categorización.

Los clasificadores basados en svm y *kernel svm* se benefician en gran medida del filtro

gaussiano, especialmente este último, que muestra una mejora significativa en la exactitud, ya que este ayuda a los clasificadores a identificar patrones más claros y consistentes en los datos. Aunque la RNA también se perfecciona, el incremento es menor en comparación con los métodos basados en svm. Esto podría deberse a la naturaleza de la red neuronal, que puede ser menos sensible a las mejoras en la calidad de las características si la estructura de la red no se optimiza adecuadamente.


Las figuras 11, 12 y 13 presentan los resultados de desempeño de la matriz de confusión y de la curva característica operativa del receptor (ROC, por sus siglas en inglés), obtenidos gracias al modelo de aprendizaje de máquinas que alcanzó la mejor exactitud *kernel svm* para el vector característico construido a partir de la parte real de los coeficientes de Gabor posprocesados y usando imágenes de la secuencia FLAIR normalizadas y preprocesadas.

Figura 11. Matriz de confusión que muestra el desempeño obtenido por el modelo *kernel svm*. Evaluación con respecto al número de observaciones




Fuente: elaboración propia (2024).

Figura 12. Matriz de confusión. Evaluación con respecto al número de verdaderos positivos y falsos negativos obtenidos. Modelo evaluado: *kernel svm*



Fuente: elaboración propia (2024).

Figura 13. Curva característica operativa del receptor roc para el modelo kernel svm

Fuente: elaboración propia (2024).

La extracción de texturas para la identificación de tejidos tumorales en imágenes de resonancia magnética se realiza mediante la transformada de Gabor, una técnica que convierte la imagen del dominio del tiempo al dominio de la frecuencia. Para el efecto, emplea una función seno combinada con una función gaussiana, conocida como “ventana”, que se aplica cuidadosamente a cada punto de la imagen preprocesada, en áreas tumorales y no tumorales, para descomponer la imagen en diversas unidades de textura.

En el proceso de evaluación se seleccionaron 50 puntos de tejido tumoral y 50 puntos de tejido sano en todas las imágenes. Cada punto genera 18 o 36 coeficientes, que sirven para calcular la media y la desviación estándar con modelos estadísticos. Se construyeron vectores característicos o histogramas para representar las texturas de las lesiones y de las áreas sanas.

Para evaluar el rendimiento se priorizaron métricas clave como la exactitud, la matriz de confusión y la curva ROC. Se manejaron tres métodos de aprendizaje automático: la svm, el *kernel svm* y

la RNA. Los algoritmos se configuraron de manera básica, con el objetivo de lograr una caracterización robusta de las zonas tumorales y sanas, sin necesidad de utilizar modelos de aprendizaje automático complejos.

En la figura 11 se observa que la mejor exactitud en la clasificación se alcanza cuando se utiliza la parte real de los coeficientes de Gabor con un filtro gaussiano para construir un vector de 36 elementos. En este contexto, el desempeño es muy similar entre los clasificadores empleados, con una ligera ventaja para el clasificador svm, que alcanza una exactitud de 93,7 %, mientras que el *kernel svm* obtiene 93,9 % y la RNA con diez neuronas en la capa oculta logra una exactitud de 93,2 %. Estos resultados corresponden a imágenes de la secuencia FLAIR.

El mejor desempeño con la parte real de los coeficientes de Gabor puede atribuirse a su capacidad para capturar características texturales más distintivas y estables, fundamentales para una

clasificación precisa. En comparación, los coeficientes basados en magnitud y fase no aportan un rendimiento tan significativo, lo que destaca la superioridad de la parte real en la extracción de características para esta tarea específica.

Además, la construcción del vector de características con 36 elementos muestra una ligera mejora en la exactitud en comparación con el vector de 18 elementos, aunque la diferencia no es considerable. La tendencia general es que un mayor número de elementos en el vector contribuye a una representación más detallada y precisa de las texturas.

El uso de un filtro pasa bajo de preprocesamiento en las imágenes de entrada y un filtro gaussiano en los coeficientes de Gabor también impacta positivamente en la exactitud. Estos filtros ayudan a reducir el ruido y mejorar la calidad de las características extraídas, y contribuye a que el desempeño sea superior al que se obtiene sin aplicarlos. La combinación de un preprocesamiento adecuado y el uso de la parte real de los coeficientes de Gabor permite una caracterización más robusta y precisa de los tejidos, que refleja los mejores resultados en la tabla.

La tabla 3 revela que lo obtenido con las imágenes de la secuencia T1w es significativamente inferior, porque la exactitud máxima es de solo 66,5 %. Esto indica que para la tarea de caracterizar tejidos tumorales es más eficaz utilizar imágenes de la secuencia FLAIR en combinación con la transformada de Gabor y sus filtros.

La matriz de confusión y la curva característica operativa del receptor ROC presentadas en las figuras 11, 12 y 13 ofrecen una visión detallada de los resultados obtenidos con el mejor modelo de clasificación y vector de caracterización, y destacan el desempeño del modelo al mostrar la relación entre los verdaderos positivos y los falsos negativos en las muestras utilizadas para el entrenamiento y la validación.

Conclusiones

Los resultados muestran que las imágenes de la secuencia FLAIR son más adecuadas para obtener el vector característico de textura que se utiliza después para identificar zonas tumorales, en comparación con las imágenes de la secuencia T1w.

Los coeficientes de Gabor que incluyen componentes reales e imaginarios pueden ser representados en forma polar por medio de su magnitud y fase. Los experimentos señalan que la parte real de los coeficientes de Gabor ofrece un mejor desempeño en el proceso de caracterización.

En general, los resultados sugieren que aplicar filtros pasa bajo durante el preprocesamiento de las imágenes de entrada y en los coeficientes de textura de Gabor en el posprocesamiento mejora de modo significativo la precisión de la caracterización. Además, utilizar la estadística de los coeficientes para construir el vector de caracterización contribuye a un desempeño superior en la clasificación.

Referencias

- [1] A. Kumar-Sahoo *et al.*, “Efficient simultaneous segmentation and classification of brain tumors from MRI scans using deep learning”, *Biocybern. Biomed. Eng.*, vol. 43, no. 3, pp. 616-633, jul.-sept. 2023, doi: 10.1016/j.bbe.2023.08.003
- [2] L. C. Hygino da Cruz, I. G. Vieira, and R. C. Domingues, “Diffusion MR imaging: An important tool in the assessment of brain tumors”, *Neuroimaging Clin. N. Am.*, vol. 21, no. 1, pp. 27-49, feb. 2011, doi: 10.1016/j.nic.2011.01.010
- [3] S. Nauyan-Rashid *et al.*, “Early-stage segmentation and characterization of brain tumor”, *Comput. Mater. Contin.*, vol. 73, no. 1, pp. 1001-1017, may. 2022, doi:10.32604/cmc.2022.023135
- [4] M. Juneja *et al.*, “Denoising of magnetic resonance images of brain tumor using BT-Autonet”, *Biomed Signal Process Control*, no. 87, pp. 105477, ene. 2024, doi:10.1016/j.bspc.2023.105477
- [5] N. Dey and V. Rajinikanth, “Image processing methods to enhance disease information in MRI slices”, en *Magnetic Resonance Imaging*, Amsterdam: Elsevier, 2022, pp. 49-82.
- [6] N. Domínguez-Pinilla *et al.*, “Evaluación de la utilidad del coeficiente de difusión aparente en resonancia magnética para la diferenciación del grado tumoral de los tumores cerebrales pediátricos”, *Neurología*, vol. 31, no. 7, pp. 459-465, sept. 2016, doi:10.1016/j.nrl.2014.12.003

- [7] D. Selvaraj and R. Dhanasekaran, "A review on tissue segmentation and feature extraction of MRI brain images", *Int. J. Comput. Sci. Eng. Technol.*, vol. 4, no. 10, pp. 3-4, 2013.
- [8] O. Turk *et al.*, "Automatic detection of brain tumors with the aid of ensemble deep learning architectures and class activation map indicators by employing magnetic resonance images", *Z. Med. Phys.*, vol. 34, no. 2, pp. 278-290, may. 2024, doi: 10.1016/j.zemedi.2022.11.010
- [9] V. Perumal V. Narayanan, and S. J. S. Rajasekar, "Detection of brain tumor with magnetic resonance imaging using deep learning techniques", en *Brain tumor MRI image segmentation using deep learning techniques*, J. Chaki, ed., *Ámsterdam: Elsevier*, 2022, pp. 183-196.
- [10] Y. Zou *et al.*, "MR-Trans: MultiResolution Transformer for medical image segmentation", *Comput. Biol. Med.*, vol. 165, pp. 107456, oct. 2023, doi:10.1016/j.combiomed.2023.107456
- [11] G. Gavidia *et al.*, "Generación de modelos discretos de tejidos del ser humano a través del preprocesamiento y segmentación de imágenes médicas", *Rev. Int. Métodos Numér. Cál. Diseñ. Ing.*, vol. 27, no. 3, pp. 200-226, mzo. 2011, doi: 10.1016/j.rimni.2011.07.002
- [12] A. Noriega-Puente, Segmentación de gliomas en imagen de resonancia magnética multimodal, 2019. <http://hdl.handle.net/10902/17859>
- [13] W. Ren *et al.*, "Brain tumor diagnosis using a step-by-step methodology based on courtship learning-based water strider algorithm", *Biomed. Signal Process Control*, vol. 83, pp. 104-614, may. 2023. doi:10.1016/j.bspc.2023.104614
- [14] P. Chithra and G. Dheepa, "An analysis of segmenting and classifying tumor regions in MRI images using CNN", *Int. J. Pure Appl. Math.*, vol. 118, no. 24, pp. 1-12, ene. 2018. https://www.researchgate.net/publication/332671062_An_Analysis_of_Segmenting_and_Classifying_Tumor_Regions_in_MRI_Images_using_CNN
- [15] A. Dixit and N. P. Hegde, "Image texture analysis – survey", *2013 Third International Conference on Advanced Computing and Communication Technologies (ACCT)*, Rohtak, India, 2013, pp. 69-76, doi:10.1109/ACCT.2013.49
- [16] P. Wang *et al.*, "Vision transformers in multi-modal brain tumor MRI segmentation: A review", *Meta-Radiol.*, vol. 1, no. 1, pp. 100004, jun. 2023, doi:10.1016/j.metrad.2023.100004
- [17] V. Harati-Kabir, R. MahdaviFar-Khayati, and A. Fallahi, "Non-invasive grading of brain tumors using online support vector machine with dynamic fuzzy rule-based parameters optimization", *Proc. Inst. Mech. Eng. H*, vol. 237, no. 6, pp. 727-740, may. 2023, doi:10.1177/09544119231176124
- [18] D. Sulekha, G. Partha, and Ch. Avijit-Kumar, "Segmentation and classification of specific pattern of brain tumor using CNN", *Int. J. Eng. Technol. Manag. Sci.*, vol. 7, no. 2, pp. 21-29, 2023. doi:10.46647/ijetms.2023.v07i02.004
- [19] B. N. Subudhi *et al.*, "Tumor or abnormality identification from magnetic resonance images using statistical region fusion based segmentation", *Magn. Reson. Imaging*, vol. 34, no. 9, pp. 1292-1304, nov. 2016, doi:10.1016/j.mri.2016.07.002
- [20] R. Li, an H. K. Kwan, "Weighted multiwindow discrete Gabor transform", *Digit. Signal Process.*, vol. 117, pp. 103155, oct. 2021, doi:10.1016/j.dsp.2021.103155
- [21] J. G. Daugman, "Two-dimensional spectral analysis of cortical receptive field profile", *Vis. Res.*, vol. 20, no. 10, pp. 847-856, 1980, doi:10.1016/0042-6989(80)90065-6
- [22] J. G. Daugman, "Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters", *J. Optical Soc. Amer.*, vol. 2, no. 7, pp. 1160-9, jul. 1985, doi:10.1364/josaa.2.001160
- [23] M. A. Zhen-Qian *et al.*, "Segmenting cardiac MRI tagging lines using Gabor filter banks", en *Proc. 25th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (IEEE Cat. no. 03CH37439)*, Cancún, México, 2003, pp. 630-633, doi:10.1109/IEMBS.2003.1279834
- [24] M. M. Mohamed *et al.*, Prostate cancer diagnosis based on Gabor filter texture segmentation of ultrasound image. *Proc. CCECE 2003 - Canadian Conf. Electr. Comput. Eng., Toward a Caring and Humane Technol.*, Montreal, QC, Canada, 2003, vol. 3, pp. 1485-1488, doi:10.1109/CCECE.2003.1226185
- [25] R. M. Rangayyan *et al.*, "Detection of the optic nerve head in fundus images of the retina with Gabor filters and phase portrait analysis", *J. Digit. Imaging*, vol. 23, no. 4, pp. 438-453, ene. 2010, doi: 10.1007/s10278-009-9261-1

- [26] S. K. Rajeev *et al.*, “A biologically-inspired hybrid deep learning approach for brain tumor classification from magnetic resonance imaging using improved Gabor wavelet transform and Elmann-BiLSTM network”, *Biomed. Signal Process. Control*, vol. 78, pp. 103949, sept. 2022, doi:10.1016/j.bspc.2022.103949
- [27] D. Maruthi-Kumar, D. Satyanarayana and M. N. Giri-Prasad, “An improved Gabor wavelet transform and rough K-means clustering algorithm for MRI brain tumor image segmentation”, *Multimed. Tools Appl.*, vol. 80, no. 5, pp. 6939-6957, oct. 2020, doi:10.1007/s11042-020-09635-6
- [28] F. Kofler *et al.*, “BraTS toolkit: Translating BraTS brain tumor segmentation algorithms into clinical and scientific practice”, *Front. Neurosci.*, vol. 14, 2020, doi:10.3389/fnins.2020.00125
- [29] B. H. Menze *et al.*, “The multimodal brain tumor image segmentation benchmark (BraTS)”, *IEEE Trans. Med. Imaging*, vol. 34, no. 10, pp. 1993-2024, oct. 2015, doi:10.1109/TMI.2014.2377694
- [30] M. Soltaninejad *et al.*, “Automated brain tumour detection and segmentation using superpixel-based extremely randomized trees in FLAIR MRI”, *Int. J. Comput. Assist. Radiol. Surg.*, vol. 12, no. 2, pp. 183-203, 2017, doi:10.1007/s11548-016-1483-3
- [31] L. Shen, D. Auer, and L. Bai, “3D Gabor wavelets for evaluating medical image registration algorithms”, en *Proc. 3rd Int. Workshop Med. Imaging Augmented Reality (MIAR 2006)*, Shanghai, China, pp. 261-268, 2006, doi:10.1007/11812715_33
- [32] W. -L. Chao, “Gabor wavelet transform and its application”, *Term Project Report*, 2010. <https://api.semanticscholar.org/CorpusID:9372762>