







Caracterización de isquemias cerebrales en imágenes de resonancia magnética usando la transformada de Hermite

Characterization of cerebral ischemia in magnetic resonance images using the Hermite transform

Yaileth Johanna Morales Daza ¹, Leticia María Acosta Oñate ², Lorena Paola Vargas Quintero ³,
Leiner Barba Jiménez ⁴ y Carlos Eduardo Díaz Fernández ⁵


Fecha de Recepción: 22 de agosto de 2025


Fecha de Aceptación: 15 de marzo de 2026


Cómo citar: Y. J. Morales Daza, L. M. Acosta Oñate, L. P. Vargas Quintero, L. Barba Jiménez, y C. E. Díaz Fernández, «Caracterización de isquemias cerebrales en imágenes de resonancia magnética usando la transformada de Hermite», *Tecnura*, vol. 30, n.º 87. mar. 2026. 25–38. <https://doi.org/10.14483/22487638.24046>


Resumen


Contexto: Las Imágenes de Resonancia Magnética (IRM) son altamente útiles para evaluar isquemias cerebrales y resultan de vital importancia para detectar las regiones donde se ubican dichas lesiones, así como para determinar su estado y condición. El análisis de estas imágenes lo realiza normalmente el médico especialista, y el diagnóstico depende fundamentalmente del conocimiento y experiencia del especialista. No obstante, para llevar a cabo un análisis cuantitativo y más objetivo, resulta de mucha utilidad la creación de modelos y herramientas matemáticas que permitan caracterizar las regiones afectadas y las regiones sanas. Antes esta necesidad, las técnicas de procesamiento digital de imágenes y las de inteligencia artificial se han convertido en alternativas para desarrollar herramientas de ayuda diagnóstica para las isquemias y otros tipos de enfermedades.

¹ Ingeniera Electrónica, estudiante de Maestría en Ciencias Física, Docente Investigador, reconocida por el Sistema Nacional de Ciencia y tecnología de Colombia como investigador junior. Universidad Popular del Cesar.  Email: morales.yaileth@unicesar.edu.co

² Ingeniera Electrónica y de Telecomunicaciones, Magíster en Ciencias Físicas y Especialista en Gestión de Proyectos y en Didáctica para la Docencia Virtual. Docente investigadora reconocida como Investigador Asociado por el Sistema Nacional de Ciencia y Tecnología de Colombia. Universidad Popular del Cesar.  Email: leticiaacosta@unicesar.edu.co

³ Ingeniera Electrónica titulada de la Universidad Popular del Cesar en el 2005. Realizó sus estudios de maestría y el doctorado en ingeniería Eléctrica en la Universidad Nacional Autónoma de México en el área de procesamiento de señales. Trabajo como investigador postdoctoral en medicina nuclear en el 2018. Universidad Popular del Cesar.  Email: vargas.lorena@unicesar.edu.co

⁴ Ingeniero Electrónico de la Universidad Popular del Cesar (Colombia) Magíster en Ingeniería Eléctrica de la Universidad Nacional Autónoma de México y el doctorado del mismo programa en 2017. Fue investigador postdoctoral en el centro médico Medicina Nuclear, Colombia en 2018. Universidad Popular del Cesar.  Email: barba.leiner@unicesar.edu.co

⁵ Ingeniero Electrónico de la Universidad Popular del Cesar, Magíster en Educación y Entornos Virtuales y Especialista en Docencia y Pedagogía. Docente Investigador reconocido como Investigador Junior por el Sistema de Ciencia y Tecnología de Colombia. Universidad Popular del Cesar.  Email: carlosdiazfernandez@unicesar.edu.co

Objetivo: Caracterizar y segmentar isquemias cerebrales a partir de IRM utilizando un proceso de análisis de textura basado en la transformada de Hermite.

Metodología: La caracterización permite desarrollar un esquema capaz de diferenciar tejidos sanos e isquémicos de forma automática en las IRM, mediante un algoritmo de aprendizaje de máquinas o clasificador. Además, se utilizan otras técnicas de procesamiento de imágenes que contribuyen al proceso final de segmentación.

Resultados: Las pruebas se realizaron con imágenes de una base de datos pública conformada por IRM que han sido adquiridas de pacientes con isquemias cerebrales. Los resultados fueron evaluados y analizados en la etapa de clasificación de los tejidos y en la etapa de segmentación, con presentación de resultados cualitativos y cuantitativos. En el contexto de la segmentación, el algoritmo desarrollado mostró un alto nivel de eficacia al delimitar las regiones isquémicas con un coeficiente Dice promedio cercano al 80 %. Aunque se observaron algunos falsos positivos, estos fueron mitigados en etapas posteriores mediante técnicas de morfología matemática como la erosión, dilatación y llenado de huecos.

Conclusiones: El enfoque descrito no solo mejoró la calidad de la segmentación, sino que también aseguró la robustez del sistema frente a variaciones y ruidos en las imágenes. Este enfoque matemático demostró ser una herramienta de gran valor, al permitir un análisis profundo y direccional de las texturas presentes en las imágenes, destacándose por su capacidad para identificar y diferenciar tejidos sanos de los afectados por isquemias con una alta precisión.

Keywords: Isquemia cerebral, Imagen RM, transformada de Hermite, segmentación de imágenes

Abstract

Context: Magnetic Resonance Imaging (MRI) is highly useful for evaluating cerebral ischemia and plays a crucial role in detecting the regions where these lesions are located, as well as determining their extent and condition. The analysis of these images is usually performed by a medical specialist, and the diagnosis largely depends on their knowledge and experience. However, in order to carry out a more objective and quantitative analysis, the development of mathematical models and tools that allow the characterization of both affected and healthy regions becomes highly valuable. In this context, digital image processing techniques and artificial intelligence methods have become promising alternatives for developing diagnostic support tools for ischemia and other types of diseases.

Objective: To characterize and segment cerebral ischemia from MRI images using a texture analysis process based on the Hermite Transform.

Methodology: The characterization process enables the development of a scheme capable of automatically differentiating healthy and ischemic tissues in MRI images through a machine learning algorithm (classifier). In addition, other image processing techniques are used to support the final segmentation process.

Results: The tests were carried out using images from a public database composed of MRI scans acquired from patients with cerebral ischemia. The results were evaluated and analyzed during the tissue classification and segmentation stages, presenting both qualitative and quantitative outcomes. In the segmentation stage, the developed algorithm showed a high level of effectiveness in delineating ischemic regions, achieving an average Dice coefficient close to 80%. Although some false positives were observed, these were mitigated in subsequent stages through mathematical morphology techniques such as erosion, dilation, and hole filling.

Conclusions: The approach described not only improved the quality of the segmentation but also ensured the robustness of the system against variations and noise in the images. This mathematical approach proved to be a valuable tool, enabling a deep and directional analysis of the textures present in the images and demonstrating a strong capability to accurately identify and differentiate healthy tissues from those affected by ischemia.

Palabras clave: Cerebral ischemia, MRI, Hermite transform, image segmentation

Introducción

La isquemia cerebral es una de las principales causas de discapacidad y mortalidad en todo el mundo, originada por la reducción o interrupción del flujo sanguíneo en una región del cerebro. Esta condición impide que las células reciban oxígeno y nutrientes, lo que puede derivar en un daño neurológico permanente o incluso en la muerte si no se trata oportunamente [1].

Las imágenes de resonancia magnética (IRM) constituyen una de las principales herramientas diagnósticas en la evaluación de este tipo de lesiones, ya que permiten identificar las regiones afectadas y valorar su extensión y severidad. Tradicionalmente, el análisis de estas imágenes depende en gran medida de la experiencia y criterio del especialista. Sin embargo, la necesidad de métodos más objetivos, reproducibles y cuantitativos ha impulsado el desarrollo de modelos matemáticos y técnicas de procesamiento digital de imágenes, apoyados en herramientas de inteligencia artificial, como mecanismos de apoyo al diagnóstico clínico [2].

En este contexto, la Transformada de Hermite (TH) se presenta como una alternativa eficaz para el análisis de texturas en imágenes médicas, gracias a su capacidad para modelar y caracterizar patrones complejos. La TH es una poderosa herramienta matemática que permite hacer una descomposición ortogonal de funciones. Fue desarrollada por Martens [3] a principios de los años 90 y desde entonces ha sido usada en muchas aplicaciones de análisis de imágenes [4], [5], [6], [7]. En esta herramienta se usan los polinomios de Hermite como las funciones bases de la descomposición. En este artículo se propone la implementación de la TH, combinada con técnicas de procesamiento digital de imágenes, para la caracterización y segmentación de lesiones isquémicas en IRM. El enfoque se centra en la extracción de coeficientes derivados de la transformada, los cuales son empleados para describir diferencias texturales entre tejidos sanos y afectados, permitiendo así su clasificación automática.

Para la validación de la metodología, se utilizaron imágenes de la base de datos ISLES 2022 [8]. Inicialmente, estas se sometieron a un preprocesamiento para optimizar su calidad. Posteriormente, se seleccionaron regiones con y sin isquemia, de las cuales se extrajeron coeficientes de Hermite que fueron organizados en vectores característicos. Dichos vectores se emplearon en el entrenamiento de un algoritmo de inteligencia artificial que lograra diferenciar de manera efectiva tejido sano y lesionado.

Este estudio busca proveer una herramienta de apoyo al diagnóstico clínico, capaz de mejorar la precisión y objetividad en la detección de isquemias cerebrales a partir de imágenes RM, contribuyendo a optimizar la evaluación neurológica de los pacientes isquemia cerebral.

2. Metodología

2.1 Materiales y selección de los datos

Para la caracterización y segmentación de isquemias cerebrales en imágenes de resonancia magnética se siguieron los siguientes pasos:



Figura 1. Diseño del sistema

Fuente: elaboración propia.

Para la evaluación experimental de la metodología propuesta se utilizó el conjunto de datos públicos ISLES 2022, el cual reúne aproximadamente 400 estudios de IRM correspondientes a pacientes diagnosticados con accidente cerebrovascular isquémico, incluyendo tanto las imágenes originales como las máscaras de referencia generadas por expertos clínicos [8]. Con el objetivo de garantizar la consistencia en el análisis y disponibilidad de la información necesaria para la caracterización de las lesiones se realizó un proceso de selección de los casos a partir del conjunto total disponible. Los criterios considerados incluyeron la disponibilidad de las secuencias de IRM requeridas, la presencia de máscaras de referencia para la delimitación de las regiones isquémicas y la calidad adecuada de las imágenes.

A partir de estos criterios se seleccionaron estudios que contenían las secuencias *Diffusion Weighted Imaging* (DWI), FLAIR, T1-weighted MRI y T2-weighted MRI, las cuales proporcionan información complementaria sobre la estructura y el estado fisiopatológico del tejido cerebral. En particular, la secuencia DWI es altamente sensible a cambios en la difusión del agua asociados con eventos isquémicos, mientras que FLAIR y T2 permiten visualizar alteraciones estructurales en el tejido cerebral. El desarrollo de este proyecto se centró en el DWI y FLAIR, evaluadas de manera independiente.

Antes de realizar el análisis de textura y la caracterización de las IRM, se aplicó una etapa de preprocesamiento orientada a mejorar la calidad de las imágenes y resaltar las estructuras relevantes del tejido cerebral. En primer lugar se aplicó un filtro gaussiano con el fin de reducir el ruido presente en las imágenes.

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

donde K y σ son variables que definen la amplitud máxima y ancho de la gaussiana. Este filtrado se implementó mediante la convolución de la imagen con una función gaussiana caracterizada por una desviación estándar de $\sigma = 0.8$, lo que permite suavizar las variaciones de intensidad de alta frecuencia preservando la estructura principal de la imagen.

Luego se aplicó un proceso de realce de bordes mediante la técnica de *Unsharp Masking*, cuyo objetivo es destacar las transiciones de intensidad asociadas a bordes y patrones texturales. En este trabajo se utilizó un parámetro de escala de 1.5, lo cual permitió mejorar la visibilidad de las estructuras más relevantes antes del proceso de extracción de características.

$$I_r = I(x, y) - k G(x, y) \quad (2)$$

donde $I(x, y)$ es la imagen original de entrada, $G(x, y)$ es la imagen resultante después de aplicar un filtro de suavizado o baja frecuencia como el tipo gaussiano, y k es un parámetro de escala. Este filtro realza detalles de las imágenes al restar la información de baja frecuencia de la imagen original.

La caracterización de las imágenes se realizó mediante la Transformada de Hermite (TH). A partir de las imágenes preprocesadas $I_{prep}(x, y)$, se lleva a cabo un proceso de descomposición a través de la TH, es decir,

$$L_{m,n-m}(x, y) = TH\{I_{prep}(x, y)\} \quad (3)$$

donde TH representa el operador de la transformada de Hermite, y $L_{m,n-m}$ son los coeficientes de la descomposición hasta el orden n , con $n = 0, 1, \dots$, y $m = 0, 1, \dots, n$. Estos coeficientes son conocidos como cartesianos dado que se toma como base un sistema cartesiano para calcularlos.

Para el caso particular de este proyecto, se utilizaron los coeficientes hasta el orden cuatro, lo cual permitió obtener 15 coeficientes diferentes. Estos coeficientes luego fueron rotados para considerar la orientación de las texturas. Se eligió hasta el orden cuatro, porque estos permiten capturar diferentes niveles de información textural en la imagen. Los órdenes bajos describen características globales tales como intensidad y bordes, mientras que los órdenes superiores captan patrones texturales más complejos asociados a la estructura del tejido cerebral. El orden cuatro ofrece un equilibrio adecuado entre riqueza de la información y estabilidad numérica, evitando la sensibilidad al ruido, que suelen aparecer en órdenes más altos. [3]

$$L_{n,n-m}(\theta) = RotTH\{L_{n,n-m}\} \quad (4)$$

donde $RotTH$ representa la operación de rotación, $L_{n,n-m}(\theta)$ son los coeficientes rotados. Con estos coeficientes se construyeron vectores característicos que fueron usados como entrada a tres clasificadores supervisados: Redes neuronales artificiales (ANN del inglés *artificial neural network*), Máquina de soporte vectorial (SVM del inglés *support vector machines*) y K-Vecinos Cercanos (KNN del inglés *K-Nearest neighbors*). Estos clasificadores fueron entrenados con vectores etiquetados como tejido sano o con isquemia, para luego ser aplicados en nuevas imágenes.

La arquitectura de las redes neuronales artificiales (ANN) estuvo compuesta por una capa oculta con 10 neuronas, mientras que la función de activación utilizada fue ReLU, la cual permite modelar

relaciones no lineales entre las características y facilita el proceso de entrenamiento de red. También se empleó el clasificador Máquina de soporte vectorial (SVM), utilizando un Kernel polinomial de orden 2, el cual permitió modelar las relaciones no lineales entre las características extraídas. Este clasificador busca encontrar un hiperplano óptimo que maximice la separación entre las clases correspondientes a tejido sano y tejido isquémico. Adicionalmente, se utilizó el algoritmo K-Vecinos Cercanos (KNN), con $K=1$ y la distancia euclidiana como métrica de similitud. En este enfoque, la clasificación de cada muestra se realiza asignando la clase del vecino más cercano en el espacio de características.

Para el entrenamiento y evaluación de los modelos se utilizó un esquema de partición de datos dividido entre subconjuntos: 80% de los datos destinados al proceso de entrenamiento (*training*), 10% de los datos utilizados para la etapa de validación (*validation*) y 10% de los datos reservados para la evaluación final del modelo (*testing*). Este esquema permitió evaluar el desempeño de los clasificadores en datos no utilizados durante el entrenamiento. En este estudio no se aplicó validación cruzada, ya que el objetivo principal fue analizar la capacidad discriminante de las características extraídas mediante la Transformada de Hermite en el proceso de clasificación de tejidos cerebrales.

Finalmente, el proceso de segmentación integró todas las etapas (preprocesamiento, extracción de texturas, construcción de vectores y clasificación) para detectar regiones lesionadas en las imágenes de RM. Como etapa de refinamiento se aplicaron operaciones de morfología matemática (erosión, dilatación y llenado de huecos) que redujeron errores derivados del ruido o inhomogeneidades [9].

Para evaluar el desempeño del proceso de segmentación se utilizó el coeficiente de DICE que mide el grado de superposición entre la segmentación obtenida por el algoritmo y la segmentación de referencia proporcionada por expertos clínicos. Su valor se encuentra en el rango 0 y 1; donde 0 indica ausencia total de coincidencia y 1 representa una coincidencia perfecta entre ambas segmentaciones

Matemáticamente, esta métrica se define como:

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \quad (5)$$

Donde A representa la región segmentada por el algoritmo y B la región de referencia o *ground truth*. En este estudio se obtuvo un coeficiente de DICE promedio cercano al 80 %, lo cual indica un nivel de coincidencia significativo entre las regiones detectadas automáticamente y las realizadas por expertos.

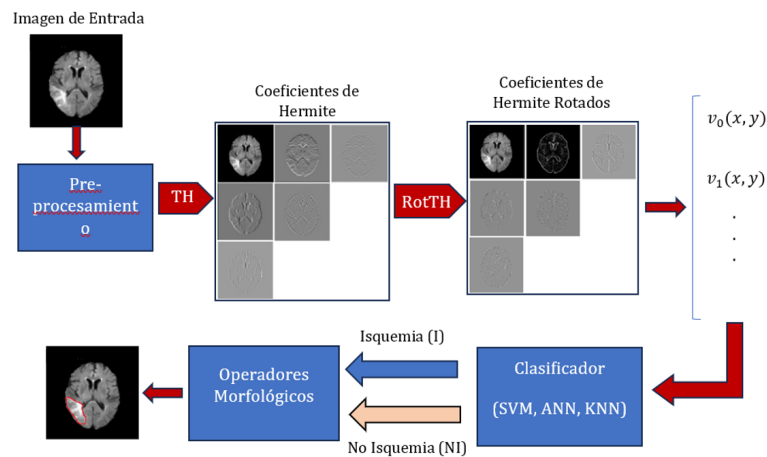


Figura 2. Proceso de segmentación de isquemias en las imágenes de RM.

Fuente: elaboración propia.

3. Resultados

Para evaluar el desempeño de los métodos utilizados se tuvieron en cuenta dos etapas: 1. Caracterización y clasificación; 2. Segmentación. Otras etapas importantes incluyen el preprocesamiento de las imágenes antes de llevar a cabo el análisis de textura con la TH, y el posprocesamiento para optimizar la segmentación y reducir errores. La construcción del vector característico se hizo considerando dos posibles opciones: 1. Los coeficientes de Hermite rotados directamente; 2. Calculando parámetros estadísticos a partir de los coeficientes. No obstante, el proceso de segmentación se lleva a cabo tomando como base la salida del clasificador el cual define cuales regiones de las imágenes corresponden a tejido sano.

Para configurar cada uno de los clasificadores fue necesario construir un conjunto de entrenamiento a partir de puntos muestreados en las regiones de las imágenes con lesión y sin lesión, (ver [Figura 2](#)). Se tomaron imágenes de 21 pacientes para construir los datos de entrenamiento; por cada imagen se muestrearon alrededor de 100 puntos en cada región, con lesión y sin lesión, resultando en un total de 3938 muestras. De ellas, 3349 fueron usadas para entrenamiento, 196 para validación y 393 para evaluación. La [Figura 3](#) muestra el proceso de muestreo llevado a cabo en las IRM para construir los vectores característicos y entrenar los clasificadores.




Figura 3. Muestreo puntos de análisis en las regiones con lesión y sin lesión para entrenar los clasificadores.

Fuente: elaboración propia.

En cuanto a la segmentación, las pruebas se hacen tomando todos los puntos de la imagen que hacen parte de la región cerebral. No obstante, se consideran los dos tipos de imágenes utilizadas en las pruebas, FLAIR y DWI, así como la opción del vector característico con el cual se logró el mejor desempeño en la clasificación. Para evaluar el desempeño de los clasificadores, se utilizó la métrica de exactitud expresada como:

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

y la matriz de confusión. En el caso de la segmentación, se tomó como métrica el coeficiente DICE, Entre más alto sea, mayor es la similitud entre las dos segmentaciones comparadas.

Las Tablas 1 y 2 ilustran los resultados del desempeño de los clasificadores para cada una de las opciones utilizadas para construir los vectores de caracterización. El resultado muestra específicamente la exactitud de cada método para clasificar cada vector como perteneciente a una región con isquemia y sin lesión

Tabla 1. Desempeño de los clasificadores para diferenciar entre vectores característicos de regiones con isquemia y sin lesión construidos a partir de imágenes de RM tipo FLAIR, utilizando diferentes condiciones para su construcción.

COEFICIENTES DE HERMITE			EXACTITUD (%) DEL CLASIFICADOR			
Tipo de Coeficiente	Filtro de preprocesamiento aplicado	Tamaño del Vector de Textura Característico V	Árbol de decisión	SVM	KNN	RNA
Coeficientes de Hermite Cartesianos	Sin filtro	15	86.1%	87.3%	80.6%	87.8%
	Filtro Gaussiano		87.2%	87.0%	90.7%	91.2%
	Filtro de Realce		84.1%	85.5%	79.3%	85.1%
Coeficientes de Hermite Rotados	Sin Filtro	5	87.3%	88.8%	84.6%	89.2%
	Filtro Gaussiano		89.9%	90.1%	87.0%	90.9%
	Filtro de Realce		83.7%	87.1%	81.6%	87.0%
Estadística de los coeficientes de Hermite Rotados	Sin Filtro	25	89.6%	89.8%	91.1%	91.7%
	Filtro Gaussiano		90.2%	90.9%	92.1%	91.4%
	Filtro de Realce		89.5%	90.3%	91.7%	91.8%

Fuente: elaboración propia.

Tabla 2. Desempeño de los clasificadores para diferenciar entre vectores característicos de regiones con isquemia y sin lesión construidos a partir de imágenes de RM tipo DWI, utilizando diferentes condiciones para su construcción.

COEFICIENTES DE HERMITE			EXACTITUD (%) DEL CLASIFICADOR			
Tipo de Coeficiente	Filtro de preprocesamiento aplicado	Tamaño del Vector de Textura Característico V	Árbol de decisión	SVM	KNN	RNA
Coeficientes de Hermite Cartesianos	Sin filtro	15	86.4%	87.2%	81.2%	88.2%
	Filtro Gaussiano		87.7%	87.2%	91.0%	90.2%
	Filtro de Realce		84.6%	86.5%	78.7%	85.7%
Coeficientes de Hermite Rotados	Sin Filtro	5	86.9%	88.7%	83.2%	88.6%
	Filtro Gaussiano		88.5%	89.2%	86.0%	89.3%
	Filtro de Realce		85.1%	87.8%	82.6%	87.5%
Estadística de los coeficientes de Hermite Rotados	Sin Filtro	25	90.3%	90.5%	92.9%	91.7%
	Filtro Gaussiano		90.5%	91.7%	93.7%	92.7%
	Filtro de Realce		88.3%	89.4%	91.0%	90.3%

Fuente: Autores

De acuerdo con las Tablas 1 y 2, el desempeño óptimo se obtiene construyendo el vector característico a partir de parámetros estadísticos calculados sobre los coeficientes de Hermite rotados. No obstante, aplicar un filtro gaussiano y de realce mejora el desempeño en un pequeño porcentaje. En cada caso, el clasificador KNN y las RNA muestran un desempeño superior en la clasificación. La Figura 5 muestra las matrices de confusión que describen el desempeño de estos dos clasificadores para el caso de las imágenes FLAIR y DWI.

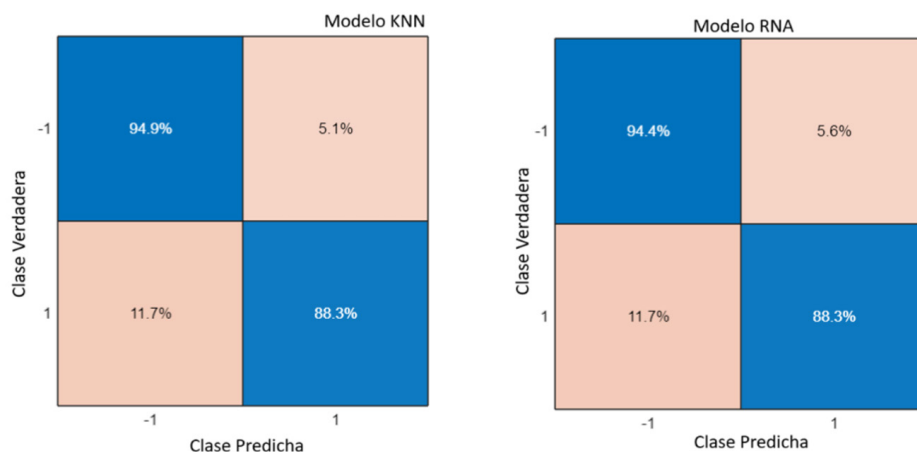


Figura 3. Matriz de confusión que muestra el desempeño obtenido por los modelos KNN y ANN en la clasificación de los vectores característicos construidos a partir de la estadística de los coeficientes de Hermite rotados y filtradas previamente con un kernel de tipo Gaussiano. Clase con etiqueta -1 corresponde a tejido normal, mientras que la etiqueta 1 corresponde a tejido con isquemia.

Fuente: elaboración propia.

Una vez que se ha configurado el modelo, el siguiente paso fue evaluar su comportamiento durante un proceso de segmentación. Para tal efecto, se usaron 15 IRM tipo FLAIR tomadas de pacientes con isquemia cerebral. El proceso de segmentación se llevó a cabo pixel a pixel, considerando únicamente la región cerebral. Sobre cada pixel o punto de la imagen se obtiene un vector característico el cual debe ser clasificado como isquemia o no.

En la [Tabla 3](#) se muestran los resultados cuantitativos de las pruebas de segmentación llevadas a cabo. Se calculó el coeficiente DICE entre la segmentación automática y la manual a través de los modelos desarrollados. Las pruebas se hicieron sobre las imágenes de tipo FLAIR y el vector característico se construyó a partir de parámetros estadísticos calculados sobre los coeficientes de Hermite rotados. Las imágenes fueron preprocesadas inicialmente con un filtro de realce.

Tabla 3. Coeficiente **Dice** obtenido entre la segmentación automática y manual a través de los modelos desarrollados

	Modelo		
	RNA	SVM	KNN
Imagen 1	0.7311	0.7642	0.7707
Imagen 2	0.7208	0.7415	0.7717
Imagen 3	0.7387	0.7542	0.7397
Imagen 4	0.7531	0.7709	0.7962
Imagen 5	0.7789	0.7815	0.8052
Imagen 6	0.8938	0.9024	0.8896
Imagen 7	0.8948	0.8970	0.8735
Imagen 8	0.8895	0.8861	0.8646
Imagen 9	0.8736	0.8772	0.8655
Imagen 10	0.8640	0.8630	0.8552
Imagen 11	0.8990	0.8852	0.8277
Imagen 12	0.8733	0.8938	0.8223
Imagen 13	0.8613	0.9083	0.8397
Imagen 14	0.8941	0.9214	0.8579
Imagen 15	0.8754	0.9305	0.8975

Fuente: elaboración propia.

Las [Figuras 4](#) y [5](#) ilustran resultados cualitativos de la segmentación. Se utilizan dos ejemplos del conjunto de imágenes usadas para evaluación. En ella se muestra la imagen original, la segmentación manual, la segmentación automática obtenida con el método propuesto, el cual incluye las etapas de

extracción de textura a través de la THR, la construcción del vector característico, el proceso de segmentación inicial con los clasificadores y la corrección de la segmentación a través de los operadores morfológicos tales como: erosión, dilatación y llenado de huecos, con la finalidad de mejorar la coherencia espacial de las regiones segmentadas. Esta última etapa ayuda sustancialmente a corregir los errores arrojados por el clasificador. Esta etapa de postprocesamiento contribuyó a reducir falsos positivos y a corregir pequeñas discontinuidades en las regiones detectadas mejorando de manera significativa la calidad y consistencia de la segmentación final.

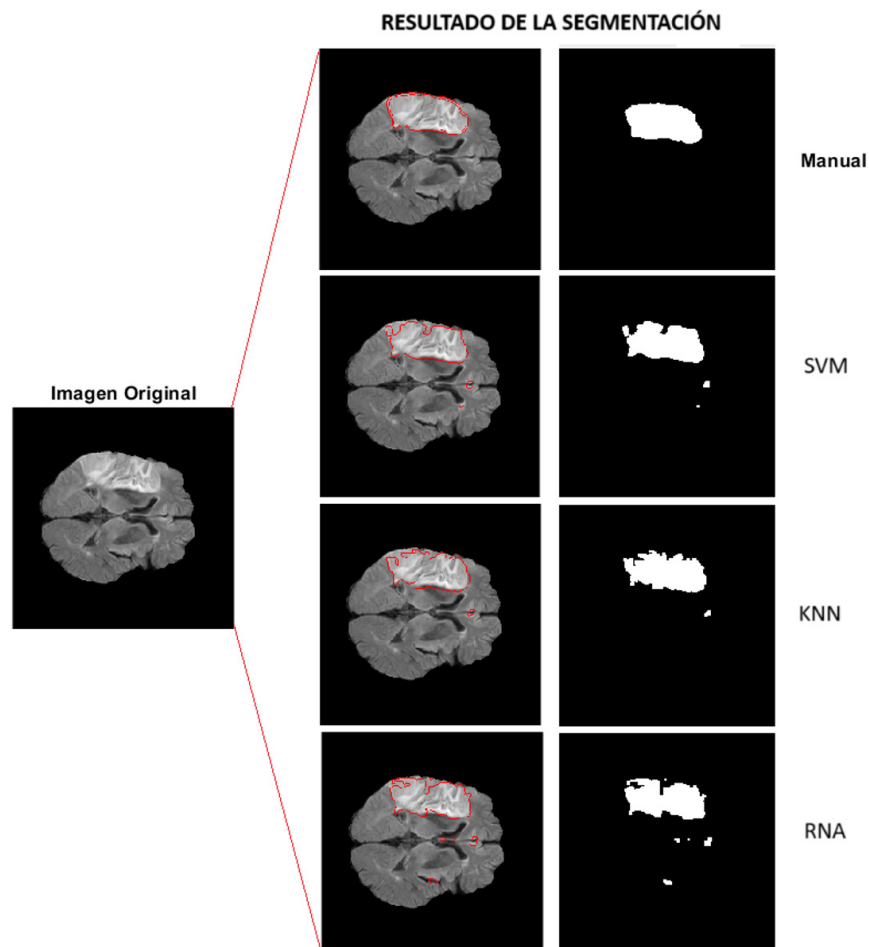


Figura 4. Segmentación resultante utilizando la Imagen 6 de la Tabla 3. Los resultados se ilustran para tres clasificadores. El vector característico fue construido a partir de parámetros estadísticos calculados sobre la TH rotada. El contorno rojo es la segmentación obtenida y dibujada sobre la imagen original. También se ilustra la máscara de segmentación final.

Fuente: Autores




Figura 5. Segmentación resultante utilizando la Imagen 2 de la Tabla 3. Los resultados se ilustran para tres clasificadores. El vector característico fue construido a partir de parámetros estadísticos calculados sobre la TH rotada. El contorno rojo es la segmentación obtenida y dibujada sobre la imagen original. También se ilustra la máscara de segmentación final

Fuente: elaboración propia.

Los resultados confirman que la combinación de la transformada de Hermite junto con vectores estadísticos y clasificadores supervisados, constituyen una estrategia eficaz para la detección y segmentación automática de isquemias cerebrales en IRM. Cabe resaltar que el eje central de este proyecto está en la extracción de características de las IRM mediante la transformada de Hermite y no en el diseño de arquitecturas de aprendizaje profundo.

4. Conclusiones

La investigación desarrolló una metodología robusta para la segmentación y caracterización de isquemias cerebrales en imágenes de RM mediante la Transformada de Hermite. Este enfoque permitió extraer patrones texturales significativos, especialmente al combinar coeficientes rotados con parámetros estadísticos locales, alcanzando precisiones superiores al 90% en la clasificación de tejidos sanos y lesionados.

En la etapa de segmentación, el método logró un coeficiente de **DICE** promedio cercano al 80%, mejorado posteriormente con técnicas de morfología matemática que redujeron falsos positivos ya aumentaron la robustez frente al ruido.

El principal aporte del trabajo radica en integrar el análisis matemático de texturas con modelos de aprendizaje automático (SVM, KNN y RNA), validado en una base de datos pública, lo que asegura reproducibilidad y aplicación clínica.

Por último, se puede decir, que la Transformada de Hermite se consolida como una herramienta poderosa y versátil en el procesamiento biomédico de imágenes, abriendo nuevas posibilidades para el diagnóstico y tratamiento de patologías neurológicas y otras enfermedades.

Referencias

- [1] C. Feng, D. Zhao, y M. Huang, "Segmentation of Ischemic Stroke Lesions in Multi-spectral MR Images Using Weighting Suppressed FCM and Three Phase Level Set," en *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, A. Crimi, B. Menze, O. Maier, M. Reyes, y H. Handels, Eds., *Lecture Notes in Computer Science*, vol. 9556. Cham: Springer, 2016, pp. 233–245. doi: https://doi.org/10.1007/978-3-319-30858-6_20
- [2] E. Díez Tejedor, O. H. Del Brutto Perrone, J. Álvarez Sabín, M. Muñoz Collazos, y G. R. P. Abiusi, "Clasificación de las enfermedades cerebrovasculares. Sociedad Iberoamericana de ECV," *Rev Neurol*, vol. 33, núm. 5, p. 455, 2001. doi: <https://doi.org/10.33588/rn.3305.2001246>
- [3] J. B. Martens, "The Hermite transform-applications," *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 38, núm. 9, pp. 1607–1618, sep. 1990. doi: <https://doi.org/10.1109/29.60076>
- [4] A. L. Barba-J, E. Moya-Albor, B. Escalante-Ramírez, J. Brieva, y E. Vallejo Venegas, "Segmentation and optical flow estimation in cardiac CT sequences based on a spatiotemporal PDM with a correction scheme and the Hermite transform," *Comput. Biol. Med.*, vol. 69, pp. 189–202, feb. 2016. doi: <https://doi.org/10.1016/j.compbiomed.2015.12.021>
- [5] E. Moya-Albor, B. Escalante-Ramírez, y E. Vallejo, "Optical flow estimation in cardiac CT images using the steered Hermite transform," *Signal Process. Image Commun.*, vol. 28, núm. 3, pp. 267–291, mar. 2013. doi: <https://doi.org/10.1016/j.image.2012.11.005>

- [6] A. Estudillo-Romero y B. Escalante-Ramirez, "Rotation-invariant texture features from the steered Hermite transform," *Pattern Recognit. Lett.*, vol. 32, núm. 16, pp. 2150–2162, dic. 2011. doi: <https://doi.org/10.1016/j.patrec.2011.06.014>
- [7] B. Escalante-Ramírez, "The Hermite transform as an efficient model for local image analysis: An application to medical image fusion," *Comput. Electr. Eng.*, vol. 34, núm. 2, pp. 99–110, mar. 2008. doi: <https://doi.org/10.1016/j.compeleceng.2007.10.002>
- [8] M. R. Hernandez Petzsche et al., "ISLES 2022: A multi-center magnetic resonance imaging stroke lesion segmentation dataset," *Sci. Data*, vol. 9, núm. 1, art. 762, dic. 2022. doi: <https://doi.org/10.1038/s41597-022-01875-5>
- [9] B. M. Ellingson *et al.*, "Comparison between intensity normalization techniques for dynamic susceptibility contrast (DSC)-MRI estimates of cerebral blood volume (CBV) in human gliomas," *J. Magn. Reson. Imaging*, vol. 35, núm. 6, pp. 1472–1477, jun. 2012. doi: <https://doi.org/10.1002/jmri.23600>

