



Identificación de lesiones cerebrales de esclerosis múltiple en imágenes de resonancia magnética mediante análisis de textura

Identification of multiple sclerosis brain lesions in magnetic resonance imaging using texture analysis

César Augusto Aldana Ramírez*, Nelson Fabián Orozco Higuera**, Samuel Barreto Melo***

Citation / Para citar este artículo: Aldana Ramírez, C. A., Orozco Higuera, N. F., & Barreto Melo, S. (2014). Identificación de lesiones cerebrales de esclerosis múltiple en imágenes de resonancia magnética mediante análisis de textura. Revista Tecnura, Edición especial, 89-101.

Fecha de recepción: 27 de julio de 2013, **Fecha de aceptación:** 16 de mayo de 2014

Resumen

La esclerosis múltiple (EM) es una enfermedad neurodegenerativa que ataca al sistema nervioso central (SNC), produce lesiones desmielinizantes y causa secuelas funcionales en adultos jóvenes, especialmente mujeres. Su diagnóstico y seguimiento se realizan a través de la resonancia magnética. En la actualidad, el análisis de texturas se ha convertido en una herramienta útil para la detección de este tipo lesiones. Por tal razón, en este artículo se busca identificar lesiones de EM utilizando los métodos de matrices de co-ocurrencia de nivel de gris y transformada wavelet (TW), y como métodos de clasificación redes neuronales (ANN) y máquinas de soporte vectorial (SVM) en imágenes de resonancia magnética (RMI) en secuencia FLAIR de 5 pacientes con diagnóstico de la enfermedad. La combinación apropiada de medidas de matrices de co-ocurrencia y wavelets permitieron obtener precisiones superiores a 96% para las máquinas de soporte vectorial y 90% para las redes neuronales, lo que demuestra

que el uso combinado de dichas medidas es superior en la detección de estas lesiones.

Palabras clave: análisis de textura, esclerosis múltiple, máquinas de soporte vectorial, redes neuronales, transformada wavelet.

Abstract

Multiple sclerosis (MS) is a neurodegenerative disease that attacks central nervous system, produces demyelinating lesions and causes functional consequences in young adults, especially women. MS diagnosis and monitoring are carried out using magnetic resonance imaging. Currently, texture analysis has become a useful tool for detecting this kind of lesions. That's why this paper aims to identify MS lesions using gray level co-occurrence matrix and wavelet transform, and artificial neural networks and support vector machine are used as classification methods in FLAIR sequence magnetic resonance images from 5 patients with MS diagnosis. Appropriate combination of co-occurrence matrix and

* Ingeniero biomédico. Especialista en bioingeniería. Bogotá, Colombia. Contacto: cealdana@uan.edu.co

** Médico cirujano. Especialista en bioingeniería. Bogotá, Colombia. Contacto: nelfanor@yahoo.com

*** Matemático; magíster en docencia de la matemática, magíster en teleinformática. Docente, Universidad Distrital Francisco José de Caldas. Bogotá, Colombia. Contacto: sbarreto@udistrital.edu.co

wavelets allowed obtaining high precisions above 96% for support vector machine and 90% for artificial neural network, showing the superiority of joining that measurements to detect MS lesions.

Key words: texture analysis, multiple sclerosis, neural networks, support vector machines, wavelet transforms.

INTRODUCCIÓN

La esclerosis múltiple (EM) es una enfermedad crónica, neurodegenerativa, que lleva a desmielinización del SNC en múltiples áreas (Zhang *et al.*, 2008). Su manifestación clínica es variable; usualmente inicia con un curso remitente recurrente en el que los pacientes presentan “ataques” caracterizados por disfunciones locales y transitorias del SNC, tales como entumecimiento o debilidad de una extremidad, incoordinación, vértigo o disfunción visual (García-Lorenzo, 2013) y puede ocasionar discapacidad física y cognitiva desde un grado leve hasta un grado severo de total incapacidad (según la evolución de la enfermedad).

Esta enfermedad es más común en mujeres, su incidencia es baja en la niñez y se incrementa rápidamente después de los 18 años de edad, tiene un pico entre los 25 y 35 años y decae lentamente, convirtiéndose en una enfermedad rara después de los 50 años. Se estima que en el mundo existen entre 1.3 y 2.5 millones de casos, de los cuales aproximadamente 350.000 se presentan en Europa Occidental. De acuerdo con investigaciones publicadas en el año 2007, la incidencia y prevalencia de la enfermedad se ha incrementado a nivel mundial en los últimos años. Colombia es considerada una zona de baja incidencia (1.48 a 4.98 casos por cada 100.000 habitantes); sin embargo, la potencial discapacidad de pacientes en edad productiva hace que los estudios relacionados con la EM tengan gran relevancia (Pradilla, 2007).

En la actualidad el diagnóstico de la EM se fundamenta en el hallazgo de lesiones de la sustancia blanca que se diseminan a través del espacio y del tiempo, basado en criterios clínicos, radiológicos y de laboratorio. En 85% de los casos la enfermedad se inicia en forma remitente-recurrente,

con síntomas localizados en el cerebro, nervio óptico o médula espinal. La técnica más utilizada para el diagnóstico y seguimiento de la enfermedad es la RM, dadas sus características de resolución espacial, específicamente en secuencias T2 y la secuencia en inversión-recuperación de fluido atenuado (FLAIR, por sus siglas en inglés), en las que las lesiones de EM se observan como áreas discretas con incremento de la intensidad, lo que permite hacer una identificación más eficaz en comparación con otras técnicas empleadas (Boudraa, 2000).

Considerando el creciente número de casos reportados a nivel mundial, la escasez de profesionales entrenados con las habilidades de determinar los casos de EM y la variabilidad de la aparición de las lesiones, se implementan como estrategias de apoyo para el diagnóstico, herramientas informáticas que permitan la identificación de lesiones de EM a través de métodos cuantitativos y con alta precisión, buscando minimizar la subjetividad de conceptos diagnósticos. Esto ha generado que la búsqueda de métodos computacionales haya llegado a ser un campo de investigación activo en los últimos años (Lladó *et al.*, 2012).

Entre los métodos más prometedores, por su poder de discriminación en lesiones tempranas y su costo computacional, se encuentra el análisis de texturas, el cual ha sido ampliamente aplicado en imágenes médicas (Zhang, 2008, Boudraa *et al.*, 2000, Lladó *et al.*, 2012, Filipuzzi *et al.*, 2012, Yamamoto *et al.*, 2010); ejemplo de ello es la segmentación de estructuras anatómicas, diagnóstico de distrofia en músculo esquelético, diferenciación de tejido sano y patológico en el cerebro humano, clasificación de lesiones de cervix (Castellano *et al.*, 2004), mediciones de textura en imágenes de ecocardiografía para diagnóstico asistido de

cardiomiopatías, clasificación de tejidos normales en imágenes tomográficas (Dettori *et al.*, 2012). En EM, los trabajos están enfocados en segmentación semiautomática (Ghazel *et al.*, 2006), la detección temprana de la enfermedad (Zhang *et al.*, 2008), detección y caracterización de lesiones utilizando algoritmos automáticos (Goldberg-Zimring *et al.*, 1998) y análisis de texturas para tumores intracraniales (Herlidou-Meme *et al.*, 2003).

La textura es una propiedad inherente a todas las superficies y provee un vocabulario para describir las variaciones en la intensidad de la superficie, incluyendo algunas que no son perceptibles por el sistema visual humano (de ahí la importancia en la detección de lesiones de EM, especialmente en lesiones tempranas) (Zhang *et al.*, 2008). Aunque no existe una definición formal de textura, intuitivamente se puede asociar a algunas propiedades de la imagen como suavidad, rugosidad, regularidad y profundidad de campo. La textura de una imagen puede definirse como un descriptor de la variación local de brillo de píxel a píxel, en una vecindad o si se quiere, un atributo que representa la distribución de los niveles de gris de los píxeles en una determinada región (Bharati, 2004). Los métodos usados en el procesamiento de imágenes para describir la textura de una región son: estructurales, estadísticos y espectrales. Las técnicas estructurales tratan de la composición de primitivas de imágenes (descripción de texturas basadas en líneas paralelas regularmente espaciadas). Las técnicas estadísticas proporcionan características de texturas como suavidad, rugosidad, granulosidad y otras similares, y las técnicas espectrales se utilizan principalmente para detectar la periodicidad global de la imagen mediante la identificación de picos de alta energía del espectro (González, Woods, 2002).

Este trabajo se realiza con el propósito de identificar cambios patológicos que indiquen lesiones de esclerosis múltiple en imágenes cerebrales de resonancia magnética, utilizando los métodos de matriz de co-ocurrencia y transformada wavelet para el análisis de textura. El artículo está

organizado como sigue: la sección 2 aborda la metodología empleada, la 3 los resultados obtenidos y su análisis, 4 las conclusiones y los trabajos futuros, 5 los agradecimientos y finalmente 6, las referencias bibliográficas.

METODOLOGÍA

Base de datos

Para el desarrollo del trabajo fueron suministradas 100 imágenes de RM provenientes de 5 pacientes (20 imágenes por cada uno) con diagnóstico previo de EM, en formato DICOM, de 600 x 600 píxeles. Las imágenes se adquirieron con un resonador Phillips de 1.5 T, con TR 8000 ms y TE 125 ms en secuencia FLAIR. Finalmente, se utilizaron 55 imágenes (11 por paciente), debido a que en estas se presentaron el mayor número de lesiones. Todas las imágenes fueron suministradas por la Facultad de Ingeniería de la Universidad Nacional de San Juan, Argentina, y la Fundación Escuela de Medicina Nuclear (FUESMEN) (Filipuzzi *et al.*, 2012).

En la figura 1 se muestra el diagrama que resume el proceso aplicado a cada imagen, para identificar el tejido cerebral lesionado. Inicialmente se realizó el preprocesamiento que se describe en el numeral 2.2, posteriormente se procedió a la extracción de medidas provenientes de las matrices de coocurrencia de nivel de gris y transformada wavelet. El análisis se llevó a cabo mediante dos recorridos, denominados *horizontal* y *diagonal*. Finalmente, para la clasificación se utilizaron 2 métodos: redes neuronales (NNA) y máquinas de soporte vectorial (SVM).

Preprocesamiento

Para eliminar componentes de hueso del cráneo, se marcaron los bordes de las imágenes con color rojo utilizando un editor de gráficos y se rellenaron las regiones internas para obtener máscaras binarias que se aplicaron a las imágenes, como lo describe Gómez (2000).




Figura 1. Resumen de la metodología aplicada.

Fuente: Elaboración de los autores.

Procesamiento

Para la identificación de las lesiones de EM en tejido cerebral se utilizaron matrices de coocurrencia y transformada wavelet para la obtención de medidas con clasificadores basados en NNA y SVM, los cuales se mencionan a continuación.

Matrices de coocurrencia de nivel de gris

Se aplicó el método de matrices de coocurrencia de niveles de gris, las cuales se construyen considerando la relación entre pares de píxeles y tabulando la frecuencia de varias combinaciones de niveles de gris dentro de una imagen o una región de interés (Kassner et al., 2010).

Dada una imagen $f(x,y)$, con un grupo de niveles de gris $-Ng$, la matriz $h_{d,\theta}(i,j)$ se define como la entrada tal que (i,j) es igual al número de veces que $f(x_1,y_1)=i$ y $f(x_2,y_2)=j$ donde (x_2,y_2) es la suma de (x_1,y_1) y $(d \cos \theta, d \sin \theta)$. De esta manera, una matriz de coocurrencia de nivel de gris se computa para una distancia $d = 1, \dots, n$ píxeles en cada dirección $\theta = 0, \frac{\pi}{4}, \frac{\pi}{2}, \frac{3\pi}{4}$. Catorce características de textura pueden obtenerse para matrices

de coocurrencia de nivel de gris en 2D para cada combinación de d y θ (Haralick et al., 1973).

Posteriormente se seleccionó un subconjunto de características debido a que hasta un pequeño grupo de $3d$ y 4θ puede producir muchas más características de textura que las convenientes para el número de casos positivos que serán sometidas a clasificación. Por ello, si el número de características no se reduce antes de la clasificación, el modelo estadístico reflejará más ruido o error aleatorio que los datos (Kassner et al., 2010). Para este caso, se construyeron 4 matrices de coocurrencia de nivel de gris para regiones establecidas en 25×25 píxeles de cada imagen en las 4 direcciones principales y $d = 1$. Dichas características se describen formalmente en las ecuaciones (1-4):

$$f_1 = \sum_i \sum_j \{p(i,j)\}^2 \quad (1)$$

$$f_2 = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j) \right\}, |i-j|=n \quad (2)$$

$$f_3 = \frac{\sum_i \sum_j (i,j)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3)$$

$$f_4 = -\sum_i \sum_j p(i,j) \log(p(i,j)) \quad (4)$$

Wavelet

La transformada wavelet se basa en pequeñas ondas de frecuencia variable y duración limitada, con lo que se revela la información frecuencial de una imagen y la información temporal, en contraste con la transformada de Fourier que provee solo información frecuencial y pierde la información temporal en el proceso de transformación (González et al., 2002; Barreto, 2004; Barreto et al., 2012).

En 2 dimensiones, se requiere una función de escalado $\varphi(x,y)$ y las tres funciones wavelets de la ecuación (5).

$$\psi^H(x,y), \psi^V(x,y), \psi^D(x,y) \quad (5)$$

Cada una es el producto de una función de escalado unidimensional y la correspondiente wavelet ψ (González et al., 2002). Excluyendo los productos que proporcionan resultados unidimensionales como $\varphi(x)\psi(x)$ los productos dan como resultado la función de escalado separable de la ecuación (6).

$$\varphi(x,y) = \varphi(x)\varphi(y) \quad (6)$$

Y las wavelet “direccionales sensibles” de las ecuaciones (7-9).

$$\psi^H(x,y) = \psi(x)\varphi(y) \quad (7)$$

$$\psi^V(x,y) = \varphi(x)\psi(y) \quad (8)$$

$$\psi^D(x,y) = \psi(x)\psi(y) \quad (9)$$

Estas wavelets miden variaciones de las intensidades de los niveles de gris a lo largo de diferentes direcciones (González et al., 2002). El valor

de energía de estos coeficientes son los utilizados para la clasificación de las lesiones de EM. Para el trabajo actual, se realizaron pruebas sobre las familias de wavelets: Haar, Daubechies 6, Daubechies 9 y Coiflet 3. Finalmente, se eligió la wavelet de Haar, por su longitud y los resultados obtenidos en pruebas iniciales.

Clasificación

Luego de obtener las medidas anteriormente mencionadas, se procedió a realizar la clasificación a partir de dos sistemas: NNA y SVM.

Redes neuronales

Una NNA es un sistema de procesadores paralelos conectados entre sí en forma dirigida. Cada elemento de procesamiento (neuronas) se representa como un nodo, que establece una estructura jerárquica y tratando de emular la fisiología del cerebro busca nuevos modelos de procesamiento para solucionar problemas concretos. Existen variaciones de topologías, que se clasifican según criterios de número de niveles o capas, número de neuronas por nivel y formas de conexión. (Serrano et al., 2009).

En este trabajo se utilizaron redes neuronales *feed forward* de 3 capas, conformadas por: 16, 48 y 1 neuronas, respectivamente, para el caso de medidas de matrices de coocurrencia; 4, 48 y 1 para medidas obtenidas a partir de wavelets y 20, 48 y 1 para medidas combinadas. Se efectuó el entrenamiento con grupos de 10 segmentos reconocidos como lesión y otros 10 reconocidos como tejido sano pertenecientes a los cortes de los 3 primeros pacientes, mediante el método *Conjugate Gradient with Polak-Ribiere Restarts*. Los cortes de los dos pacientes restantes se utilizaron para la validación.

Máquinas de soporte vectorial

Una SVM se fundamenta en la minimización del riesgo estructural (SRM) (Labrador, 2009), planteando el uso de hiperplanos como elementos discriminadores lineales, para separar las clases dadas

con el mayor margen posible m , fijado un parámetro γ , al cual se le asocia un error de clasificación σ , como se muestra en la figura 2.

Maximizar el margen m es un problema de programación cuadrática y puede resolverse introduciendo multiplicadores de Lagrange. Sin ningún conocimiento del mapeo, la SVM encuentra el hiperplano óptimo utilizando el producto punto con funciones en el espacio de características llamadas kernels, los cuales pueden ser lineales, polinomial de grado d , cuadrático, con base radial gaussiano o de perceptrón multicapa y se encuentran disponibles en Matlab. La solución del hiperplano óptimo puede escribirse como la combinación de unos pocos puntos de entrada denominados vectores de soporte (Betancourt, 2005).

Se utiliza una SVM para clasificación considerando el caso como linealmente separable, es decir, se puede utilizar como frontera de decisión el hiperplano $h(x_i)$ de la ecuación (10).

$$h(x) = w^T x + b = 0 \quad (10)$$

Donde w y $x \in \mathbb{R}^d$, siendo d la dimensión del espacio de entrada.

En un conjunto de puntos rotulados para entrenamiento (figura 2) con coordenadas $(y_1, x_1), \dots, (y_l, x_l)$, cada punto de entrenamiento $x_i \in \mathbb{R}^n$ pertenece a una de las dos clases (lesión o no lesión), a la que se le ha dado una etiqueta $y_i \in \{-1, 1\}$ para $i = 1, 2, \dots, l$.




Figura 2. Principio máquina soporte vectorial. G. Betancourt, Las máquinas de soporte vectorial, *Scientia et Technica*, año XI, No. 27, abril 2005.

Se cumplirá, según el lado en el que se encuentre el hiperplano definido en las ecuaciones (11-12).

$$w^T x + b > 0, \text{ para } y_i = 1, i = 1, \dots, n \quad (11)$$

$$w^T x + b < 0, \text{ para } y_i = -1, i = 1, \dots, n \quad (12)$$

Para resolver el problema, se considera que los vectores de soporte cumplen con las condiciones de las ecuaciones (13-14).

$$h(x_i) = 1, \text{ para } y_i = 1, \quad (13)$$

$$h(x_i) = -1, \text{ para } y_i = -1, \quad (14)$$

Para este caso linealmente separable se puede encontrar un único hiperplano óptimo, para el cual el margen de proyecciones de los puntos de entrenamiento x de las dos clases (lesión y no lesión) es maximizado (Betancourt, 2005). En este trabajo se utilizó una máquina de soporte vectorial con kernel lineal y 3 vectores de soporte.

Finalmente, para evaluar el desempeño del sistema con análisis de texturas, transformada wavelet y clasificación con NNA y SVM, se calculó la precisión (P) comparando los segmentos de salida del clasificador identificados como lesión y no lesión de la imagen con base en las lesiones marcadas originalmente de los registros de las imágenes adquiridas, a partir de la ecuación (15).

$$P = \frac{VP + VN}{VP + FP + VN + FN} \cdot 100\% \quad (15)$$

Donde VP, verdaderos positivos, VN verdaderos negativos, FP falsos positivos y FN falsos negativos.

RESULTADOS Y ANÁLISIS

La figura 3 muestra el resultado del preprocesamiento. Mediante la utilización de la máscara observada en c) se elimina el hueso de la cavidad craneana y el espacio meníngeo, conservando el tejido cerebral para aplicar el análisis de textura y la clasificación.




Figura 3. Proceso de eliminación de hueso.

Fuente: Elaboración de los autores.




Figura 4. Resultado recorrido horizontal al aplicar ANN a) imagen original, b) tejido lesionado identificado con matrices de coocurrencia, c) tejido lesionado identificado con wavelets, d) tejido lesionado identificado con medidas combinadas.

Fuente: Elaboración de los autores.




Figura 5. Promedios con redes neuronales en recorrido directo para Caso a) matrices de coocurrencia, b) wavelets, c) medidas combinadas.

Fuente: Elaboración de los autores.

En la figura 4 se presentan los resultados comparativos para la utilización de ANN en recorrido horizontal en una imagen con contenido de lesión en el hemisferio izquierdo del paciente. Se observa que la lesión fue bien definida para las 3 modalidades empleadas; sin embargo, las medidas de matrices de coocurrencia muestran falsos positivos en zonas correspondientes a los bordes del tejido. La figura 5 muestra los promedios de las precisiones obtenidas para las imágenes analizadas en recorrido horizontal utilizando NNA. Se puede observar que la precisión de las medidas combinadas es superior tanto a la aplicación de medidas wavelets como las medidas obtenidas de las matrices de coocurrencia. Estas últimas presentan la menor precisión en el grupo de pacientes.

La figura 6 muestra los resultados utilizando ANN, esta vez en recorrido diagonal. Se aprecia




Figura 6. Resultado recorrido diagonal al aplicar ANN, a) imagen original; b) tejido lesionado identificado con matrices de coocurrencia; c) tejido lesionado identificado con wavelets; d) tejido lesionado identificado con medidas combinadas.

Fuente: Elaboración de los autores.




Figura 7. Promedios con ANN en recorrido diagonal para: a) matrices de coocurrencia; b) wavelets; c) medidas combinadas.

Fuente: Elaboración de los autores.




Figura 8. Resultado recorrido horizontal al aplicar SVM, a) imagen original; b) tejido lesionado identificado con matrices de coocurrencia; c) tejido lesionado identificado con wavelets; d) tejido lesionado identificado con medidas combinadas.

Fuente: Elaboración de los autores.

para esta imagen en particular, que los falsos positivos bajaron, aumentando de esta manera la precisión en comparación con el recorrido aplicado para la figura 5. Sin embargo, algunos sectores de la lesión no fueron identificados, especialmente en la aplicación de wavelets.

En la figura 7 se puede observar que la tendencia vista en la figura 5 se mantiene, siendo de nuevo las medidas combinadas superiores en precisión a las medidas individuales. Con relación a los resultados obtenidos mediante el recorrido horizontal, este recorrido aumenta la precisión superando 98% en promedio para cada método empleado.

La figura 8 muestra la localización de las lesiones utilizando SVM en recorrido horizontal. Para este caso, no se observan falsos positivos en los bordes del tejido y la lesión fue identificada por las 3 modalidades.

Los resultados mostrados en la figura 9 indican que el recorrido directo aplicando clasificación con SVM supera los resultados obtenidos con el mismo recorrido aplicando ANN. Es destacable que los porcentajes de precisión de las matrices de coocurrencia y wavelets se encuentran en un rango cercano, lo cual es contrario a lo encontrado en el caso de las ANN, siendo incluso el porcentaje promedio de las matrices de coocurrencia.




Figura 9. Valores promedio de utilización de SVM en recorrido directo para: a) matrices de coocurrencia; b) wavelets; c) medidas combinadas.

Fuente: Elaboración de los autores.

La figura 10 muestra el uso de SVM en recorrido diagonal y como en el caso anterior, no se observan falsos positivos en los bordes de la imagen, además de una buena localización espacial para las lesiones del tejido.

Por su parte, en la figura 11, al igual que en el recorrido horizontal se observa una mayor precisión comparándolo con la aplicación de NNA. La tendencia muestra que las SVM se acoplan mejor a las matrices de coocurrencia que a las medidas de la transformada wavelet, ya que la primera llega a porcentajes superiores a 99% y logra identificación perfecta en múltiples imágenes.




Figura 10. Resultado recorrido diagonal al aplicar SVM; a) imagen original; b) tejido lesionado identificado con matrices de coocurrencia; c) tejido lesionado identificado con wavelets; d) tejido lesionado identificado con medidas combinadas.

Fuente: Elaboración de los autores.




Figura 11. Valores promedio de utilización de SVM en recorrido diagonal para: a) matrices de coocurrencia; b) wavelets; c) medidas combinadas.

Fuente: Elaboración de los autores

Al comparar los métodos y procedimientos utilizados en este trabajo para la identificación de lesiones de EM en tejido cerebral, se observó que los recorridos de análisis de las imágenes completas pueden sustituir a los utilizados en estudios previos, en los cuales el procesamiento se realizó sobre regiones de interés (ROI) como el planteado en Zhang *et al.* (2008) y Loizou (2009), teniendo en cuenta los resultados de precisión superiores a 90% y el desempeño de los algoritmos utilizados al reconocer lesiones de forma, intensidad y tamaño diferentes.

La utilización de un tamaño de ventana de 25 x 25 píxeles resultó conveniente para el análisis de las imágenes, ya que detectó satisfactoriamente la mayoría de las lesiones cerebrales de EM, con excepción de aquellas de tamaños inferiores a 10 x 9 píxeles. Este tamaño de ventana también fue reportado por Louzou (2009) y Louzou (2010) para las ROI, mientras que en Wang *et al.* (2007) se presentó un análisis de ROI con tamaño de ventanas de 32 x 32; sin embargo, ninguno reveló información sobre el tamaño mínimo detectable de una lesión.

Se corrobora mediante los resultados obtenidos con la transformada wavelet de Haar, que debido a su longitud resultó adecuada en el análisis de este tipo de imágenes que presentan cambios o transiciones repentinas, por las mismas características del tejido cerebral y las lesiones encontradas en

la EM. Tales hallazgos habían sido reportados en Dettori *et al.* (2007), en donde evaluaron 3 familias (Haar, Daubechies 4 (D4) y Coiflet 6). Es destacable que este trabajo se realizó sobre imágenes tomográficas, con lo que la transformada de Haar aparece como un algoritmo apropiado para la evaluación de lesiones diferentes en varios tipos de imágenes médicas.

La combinación de medidas obtenidas de las matrices de coocurrencia con wavelets fue suficiente para obtener altos porcentajes de diferenciación entre las lesiones de EM y tejido sano (superior a 98% para SVM y 95% para NNA) sin la utilización de medidas de primer orden ni medidas correspondientes a las matrices de *run-length* planteados en Zhang *et al.* (2008). Asimismo, es indudable que al utilizar SVM como clasificador se obtienen porcentajes de identificación de lesiones superiores a las NNA planteadas con menores tiempos de ejecución. El menor rendimiento de las NNA se presenta en zonas correspondientes a los bordes del tejido, en donde ocurre el mayor número de falsos positivos; sin embargo, su capacidad de detección de segmentos con lesiones no activas o en proceso de formación cuyas intensidades eran más bajas que las lesiones activas, fue considerable.

No se encontraron reportes en la literatura consultada que muestren el uso de recorridos diagonales como herramienta para mejorar la identificación de las lesiones. Es importante mencionar que esta forma de recorrer la imagen ayuda a definir segmentos de lesiones circulares de manera más acertada que el recorrido horizontal.

CONCLUSIONES Y TRABAJO FUTURO

Es posible identificar lesiones de EM en imágenes cerebrales de RM en secuencia FLAIR y localizarlas espacialmente con precisión superior a 90%, utilizando métodos de análisis de textura. De acuerdo con los resultados de precisión, esta identificación mejora dependiendo del método de análisis y clasificación.

La alta variabilidad en las características de las lesiones como forma, tamaño, intensidad y localización, entre otras, hacen que la tarea de identificación presente dificultades y requiera diferentes opciones de recorrido en su análisis. Por los resultados obtenidos con los recorridos horizontal y diagonal, se observó que el diagonal definió con mayor precisión lesiones de forma circular. Por tanto, sería favorable la implementación de otros recorridos tales como el radial, en abanico o en espiral de la imagen completa, de tal modo que lesiones de menor tamaño y diversas formas sean detectadas. En ese sentido, la utilización de la transformada de Radón, por el tipo de recorrido que realiza, podría minimizar errores de clasificación, particularmente en las regiones de los bordes.

Asimismo, el uso de métodos de segmentación con bancos de filtros en frecuencia o filtros Gabor, por sus características de eliminación de ruido y preservación de orientaciones, serían muy útiles en el análisis de textura, especialmente en etapas de procesamiento.

Por otro lado, la utilización de una base diferente a las wavelets, tal como las bandelets, las cuales indican las direcciones locales en las que los niveles de gris tienen variaciones regulares (Le Pennec, Mallat, 2005), lo que sería sensible a las texturas de las lesiones de EM y, por consiguiente, podría mejorar su identificación.

Es indudable que en las tareas de reconocimiento las SVM superan a las redes neuronales en precisión y tiempo de implementación, puesto que estas últimas, de acuerdo con los resultados mostrados, son menos sensibles a los cambios producidos en los bordes de las lesiones que las primeras, convirtiéndolas en una buena elección como método de clasificación.

El costo computacional que se tiene para el análisis de cada imagen de forma completa y no por ROI como se realiza en la mayoría de los trabajos previos, se ve compensado por la disminución en el tiempo de la selección de dichas regiones, que además requiere experiencia en este tipo de imágenes.

Para lograr una optimización de los algoritmos planteados, utilizando los mismos principios, se propone implementar un sistema que discrimine sustancia blanca de apariencia normal (WMNA) (Zhang, 2008), la denominada sustancia blanca de apariencia sucia, la sustancia gris de apariencia normal y la lesión, lo que permitiría evaluar cambios menos evidentes para el sistema visual humano y con ello proporcionar un diagnóstico temprano de la enfermedad.

Es necesario trabajar con pacientes en Colombia, recopilando inicialmente un banco de imágenes médicas (dado que esta base de datos fue facilitada desde Argentina), con lo cual sea posible realizar un seguimiento a los cambios de textura en las lesiones a través del tiempo y, con ello, mejorar la capacidad de clasificación.

Asimismo, un trabajo importante por desarrollar estaría relacionado con la obtención de imágenes de RM con diferentes secuencias, tales como T2 o T1 con medio de contraste, que son las más utilizadas en Colombia para el diagnóstico de EM. Se plantea incluir imágenes de cordón espinal.

Una reconstrucción en 3D de las lesiones permitiría hacer un seguimiento no solo del desarrollo de la lesión a nivel de volumen, sino también una visualización que permita evaluar el comportamiento de dichas lesiones a un tratamiento específico.

En la revisión bibliográfica hecha para el desarrollo del trabajo no se encuentran publicaciones colombianas que aborden el tema del análisis de textura en imágenes diagnósticas para EM, lo que abre un camino para la utilización de los recursos computacionales y de software como herramientas de apoyo al diagnóstico médico, principalmente en casos en donde no se cuente con personal especializado.

AGRADECIMIENTOS

A la bioingeniera Florencia Rodrigo, de la Universidad Nacional de San Juan, Argentina, por permitir utilizar la base de imágenes de RNM con las que se realizó el proyecto.

Al ingeniero Javier González, docente de la Facultad de Ingeniería Electrónica de la Universidad Santo Tomás, por sus aportes y orientaciones en el desarrollo del trabajo.

FINANCIAMIENTO

Para la realización de este artículo de investigación no se contó con financiamiento puesto que se efectuó como parte del trabajo de grado de los autores, dentro de la especialización en Bioingeniería de la Facultad de Ingeniería de la Universidad Distrital Francisco José de Caldas.

REFERENCIAS

- Barreto, S. (2004). Análisis Comparativo de las Multiwavelets y Wavelets escalares en lo que respecta a los criterios de calidad y Compresión de Imágenes. Bogotá: Universidad Distrital Francisco José de Caldas (Tesis de grado).
- Barreto, S.; E. Betancourt; M. Lesmes (2012). *Transformación de Imágenes a Través del Álgebra Lineal*. Bogotá: Editorial U.D.
- Betancourt, G. (abril 2005). Las máquinas de soporte vectorial. *Scientia et Technica*, año XI, No. 27.
- Bharati, M.; J. Jay Liu, *et al.* (2004). Image texture analysis: methods and comparisons. *Chemometrics and Intelligent Laboratory Systems*, vol. 72, pp. 57–7.
- Boudraa, Abdel-Ouahab Sidi; Mohammed Réda Dehak; Yue-Min Zhu; Chahin Pachai; Yong-Gang Bao; Jérôme Grimaud. Automated segmentation of multiple sclerosis lesions in multispectral MR imaging using fuzzy clustering. *Computers in Biology and Medicine*, vol. 30, Issue 1, 15 January 2000, pp. 23-40. [http://dx.doi.org/10.1016/S0010-4825\(99\)00019-0](http://dx.doi.org/10.1016/S0010-4825(99)00019-0)
- Castellano, G.; L. Bonilha; L.M. Li; F. Cendes. Texture analysis of medical images. *Clinical Radiology*, vol. 59, Issue 12, December 2004, pp. 1061-1069. <http://dx.doi.org/10.1016/j.crad.2004.07.008>
- Dettori, Lucia; Lindsay Semler. A comparison of wavelet, ridgelet, and curvelet-based texture classification algorithms in computed tomography. *Computers in Biology and Medicine*, vol. 37, Issue 4, April 2007, pp. 486-498. <http://dx.doi.org/10.1016/j.combiomed.2006.08.002>
- Filipuzzi, M.; R. Rodrigo; E. Laciari, *et al.* Clasificación automática de lesiones de esclerosis múltiple mediante métodos de conjunto en imágenes de resonancia magnética. Universidad Nacional de San Juan, Facultad de Ingeniería. Gabinete de Tecnología Médica. <http://ofisy.aigroup.com.ar/tric/tric-v/papers>
- García-Lorenzo, D.; S. Francis; S. Narayanan, *et al.* Review of automatic segmentation methods of multiple sclerosis white matter lesions on conventional magnetic resonance imaging. *Medical Image Analysis*, vol. 17, pp. 1-18, 2013.
- Ghazel, M.; A. Traboulsee; R. Ward. Semi-Automated Segmentation of Multiple Sclerosis Lesions in Brain MRI using Texture Analysis. *IEEE International Symposium on Signal Processing and Information Technology*, vol. 6, No. 10, 2006.
- Goldberg-Zimring, D.; A. Achiron; S. Miron, *et al.* Automated detection and characterization of multiple Sclerosis lesions in brain MR images. *Magnetic resonance imaging*, vol. 16, No. 3, pp. 311-318, 1998.
- Gómez, E. (2000). Caracterización de frutos maduros de café mediante visión artificial. Manizales: Universidad Nacional de Colombia. Facultad de Ingeniería, 47 pp. (Tesis: ingeniero electrónico).
- González, R.; R. Woods (2002). *Tratamiento Digital de Imágenes*. Delaware: Editorial Wilmington.
- Haralick, R.; K. Shanmugam; I. Dinstein. Textural Features for Image Classification. *IEEE transactions on systems, man, and cybernetics*, vol. SMC-3, No. 6, pp. 610-621, 1973.
- Herlidou-Même, S.; J.M. Constans; B. Carsin, *et al.* MRI texture analysis on texture test objects, normal brain and intracranial tumors. *Magnetic Resonance Imaging*, vol. 2, pp. 989-993, 2003.
- Kassner, A.; R.E. Thornhill. Texture Analysis: A Review of Neurologic MR Imaging Applications. *American Journal of Neuroradiology*, vol. 31, No. 5, pp. 809-816, 2010.
- Labrador, P. Reconocimiento de patrones utilizando máquinas de soporte vectorial (SVM). Universidad

- Nacional Abierta, San Cristóbal (Venezuela), 2009 (proyecto de grado).
- Le Pennec, E.; S. Mallat. Sparse Geometric Image Representations With Bandelets. *IEEE transactions on image processing*, vol. 14, No. 4, 2005.
- Lladó, Xavier; Arnau Oliver; Mariano Cabezas; Jordi Freixenet; Joan C. Vilanova; Ana Quiles; Laia Valls; Lluís Ramió-Torrentà; Àlex Rovira. Segmentation of multiple sclerosis lesions in brain MRI: A review of automated approaches. *Information Sciences*, vol. 186, Issue 1, 1 March 2012, pp. 164-185. <http://dx.doi.org/10.1016/j.ins.2011.10.011>.
- Loizou, C.P. Quantitative Analysis of Brain White Matter Lesions in Multiple Sclerosis Subjects. *9th International Conference on Information Technology and Applications in Biomedicine*. Noviembre 2009.
- Loizou, C.P. Texture Image Analysis of Normal Appearing White Matter Areas in Clinically Isolated Syndrome that Evolved in Demyelinating Lesions in Subsequent MRI scans, *Multiple Sclerosis Disease Evolution*. 2010.
- Pradilla, G.; F. León. Esclerosis múltiple en Colombia: cerrando la brecha. Disponible en: http://www.acnweb.org/acta/2007_23_1_3.pdf
- Serrano, A.; E. Soria; J. Martín. Redes neuronales artificiales. Escuela Técnica Superior de Ingeniería, Curso de Doctorado, pp. 15-19, 2009-2010.
- Wang, L.; N. Li; X. Zhou, et al. Texture Characteristic Analysis of MRI for Exploratory Study on Early Diagnosis of Multiple Sclerosis. *IEEE/ICME International Conference on Complex Medical Engineering*. pp. 652-655, 2007.
- Yamamoto, D.; H. Arimura; S. Kakeda, et al. Computer-aided detection of multiple sclerosis lesions in brain magnetic resonance images: False positive reduction scheme consisted of rule-based, level set method, and support vector machine. *Computerized Medical Imaging and Graphics*, vol. 34, pp. 404-413, 2010.
- Zhang, J.; L. Wang; L. Tong. Feature "Reduction and Texture Classification in MRI-Texture Analysis of Multiple Sclerosis". *IEEE/ICME International Conference on Complex Medical Engineering*, pp. 752-757, 2007.
- Zhang, J.; L. Tong; L. Wang, et al. Texture analysis of multiple sclerosis: a comparative study. *Magnetic Resonance Imaging*, vol. 26, pp. 1160-1166, 2008.



