

# Clasificación de hiperintensidades presentes en la sustancia blanca en imágenes de resonancia magnética usando extracción de características y redes neuronales

Miguel de Jesús Martínez Felipe, Oleksiy Pogrebnyak,  
Jesús Alberto Martínez Castro, Edgardo Manuel Felipe Riverón

Instituto Politécnico Nacional, Centro de Investigación en Computación,  
Ciudad de México, México

b160670@sagitario.cic.ipn.mx, {olek, macj, edgardo}@cic.ipn.mx

**Resumen** En este trabajo, se muestra un modelo para clasificar lesiones presentes en la sustancia blanca, usando como clasificador una Red Neuronal Multicapa con Retropropagación (RNMR), la cual es alimentada por un vector característico, cuya propiedad deriva de la extracción de características del histograma y el análisis de textura de las Imagen de Resonancia Magnética (IRM). Dado que se ocupa un aprendizaje supervisado con conocimiento previo, es importante etiquetar las imágenes segmentadas como lesión y no lesión, para lo cual un experto determina las áreas con lesión dentro de las imágenes. Para la serie de entrenamiento se ocuparon 29 imágenes y como resultado, la precisión de clasificación esta por encima del 95 %, para ello se puede determinar precisamente si una zona presenta lesión dentro de la sustancia blanca.

**Palabras clave:** imágenes de resonancia magnética, redes neuronales, extracción de características, hiperintensidades de la materia blanca.

## White Matter Hyperintensities Classification in Magnetic Resonance Imaging Using Feature Extraction and Neural Networks

**Abstract.** In this work, a model to classify lesions present in white matter is shown, using as classifier a Back-Propagation Multilayer Neural Network (BPMNN), which is fed by a featured vector, whose properties derived from the feature extraction of histogram and texture analysis of magnetic resonance images; given that a supervised learning with previous knowledge is used, it is important to label the segmented images as lesion and non-lesion, for which an expert determines areas with lesion from the images. To train the neural network, 29 images was occupied and as a result of classifying we obtain over 95% of accuracy, so we can determine accurately which areas are lesion in white matter.

**Keywords:** Magnetic Resonance Imaging, Neuronal Network, Feature Extraction, White Matter Hiperintensities.

## 1. Introducción

Una lesión de sustancia blanca se manifiesta mediante la presencia de un daño isquémico presente en el cerebro, es decir un daño celular causado por la disminución transitoria o permanente del riego sanguíneo. Las técnicas empleadas en las áreas médico biológicas, específicamente en neurología, detectan la presencia de este tipo de lesiones empleando entre otras, tomografía por emisión de positrones (PET), Tomografía Axial Computarizada (TAC) e IRM. Las lesiones de sustancia blanca encontradas en IRM se manifiestan como zonas hiperintensas (áreas de alta intensidad en un examen de resonancia magnética del cerebro) y pueden encontrarse en la región subcortical, es decir la parte interna o basal del cerebro, así como en la región periventricular, es decir el área que rodea los ventrículos del cerebro [10].

Uno de los casos de lesión por sustancia blanca es la desmielinización, presente en pacientes con Esclerosis Múltiple (EM). Sin embargo, es importante resaltar que la existencia de una lesión por sustancia blanca, no necesariamente implica un diagnóstico de EM. La esclerosis múltiple es una enfermedad que consiste en la aparición de lesiones desmielinizantes, neurodegenerativas y crónicas del sistema nervioso [1].

La precisa identificación y detección de lesiones presente en la sustancia blanca en el cerebro ayuda a detectar enfermedades, no sólo de esclerosis múltiple, sino también hipertensión, diabetes u otras patologías; es por ello que los investigadores se han enfocado en múltiples trabajos de inmersión en el área de la computación anudada a la neurociencia con la finalidad de detectar hiperintensidades de sustancia blanca en el cerebro mediante metodologías de identificación de hiperintensidades automáticas y manuales. Un gran número de métodos [12],[2] y [15] , logran identificar y detectar dichas lesiones automáticamente con una tasa de Verdaderos Positivos (VP) mayor al 90%, es decir que la precisión de encontrar hiperintensidades de sustancia blanca en comparación con la detección visual y segmentación manual por radiólogos expertos es mayor, dichas metodologías pueden ser herramientas muy útiles para identificar hiperintensidades.

El artículo se encuentra organizado así: Sección 2 trabajos relacionados; Sección 3 presenta la metodología usada en este trabajo. Es dividida en 4 subsecciones; Sección 3.1 obtención de la información a priori previamente segmentada; Sección 3.2 muestra la fase de procesamiento de la imagen, Sección 3.3 explica la fase de extracción de características, Sección 3.4 Implementación del entrenamiento y clasificación de la red neuronal; Sección 4 se describen los resultados obtenidos por el clasificador de la red neural. Y finalmente, se describen las conclusiones en la Sección 5. La estructuración del modelo se puede apreciar en la Figura 1.

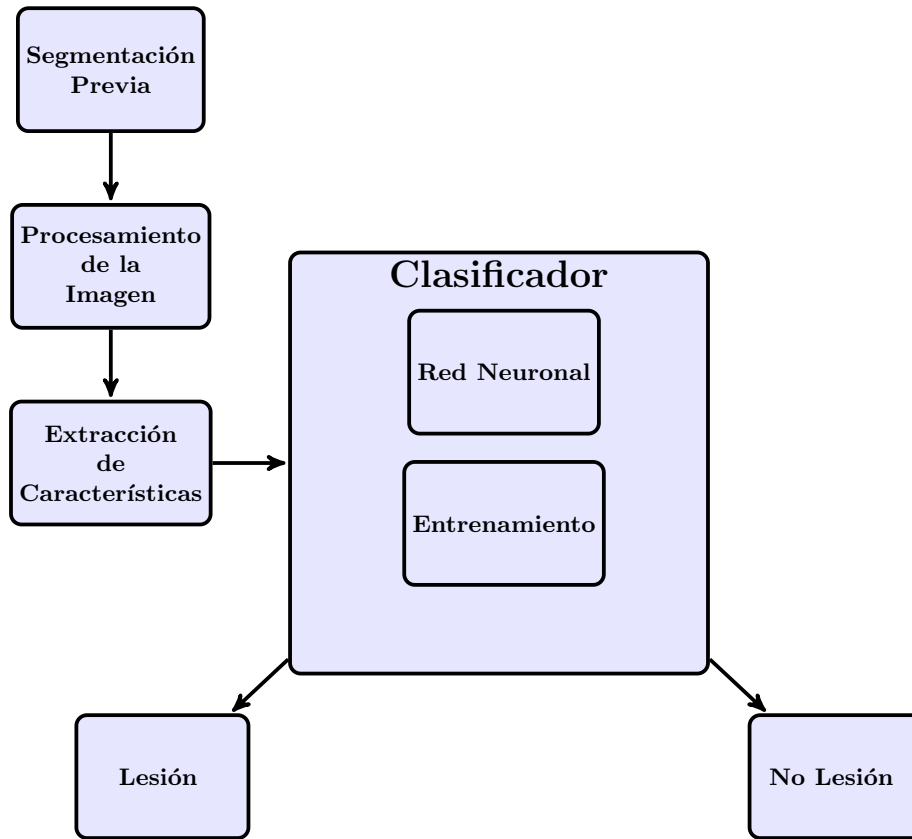


Fig. 1: Diagrama de flujo de la metodología.

## 2. Trabajos relacionados

Existen diversos métodos de trabajo empleados para la identificación y segmentación automática de hiperintensidades presentes en la sustancia blanca, tanto supervisados como no supervisados[8]. Por parte de los aprendizajes supervisados se utilizan IRM previamente segmentadas y dado que se desean resultados con mayor robustez [5], se determinan entradas con información a priori con la finalidad de dar paso a la extracción de rasgos. Una vez obtenida esta extracción se procede a entrenar el clasificador y así generar una función que identifique las salidas deseadas; algunos casos son: la implementación de redes neuronales [9],[16] y [17]; el método del K-vecino más cercano [19], [3] árboles de probabilidad [18],[2]. Las fortalezas de usar aprendizajes supervisados son incluir información local, determinar marcos probabilísticos y utilizar una gran lista de clasificadores, mientras que las debilidades son la necesidad de crear bases de datos con previas segmentaciones y que las previas segmentaciones quizá

contengan errores. Por parte de los métodos no supervisados no se requiere un conjunto de entrenamiento que permita conocer las imágenes segmentadas más bien consiste en aplicar un algoritmo no supervisado para definir específicamente las propiedades usadas en cada imagen de tal forma que las lesiones se encuentran utilizando reglas empíricas, algunos trabajos pueden ser el agrupamiento (Clustering) [7]; lógica difusa[13] y algoritmo Graph Cut [6]. Las fortalezas de ocupar aprendizajes no supervisados son determinar una guía de la segmentación de las lesiones y además sublesiones especiales pueden ser segmentadas, por otro lado las debilidades dependen bastante de la calidad con que se segmente el tejido y la especificación de reglas para cada tipo de lesión. Por ende el presente trabajo se inclinó ante la ventaja inherente de los algoritmos supervisados.

### 3. Metodología propuesta

La Metodología para clasificar las hiperintensidades presentes en la materia blanca, que se catalogan en este trabajo como lesión y no lesión se lleva a cabo mediante una base de datos de IRM axiales del cerebro ponderadas en T2-FLAIR previamente segmentadas [12], estas imágenes fueron proporcionadas por el Instituto Nacional de Rehabilitación (INR), son 29 imágenes con formato BMP con dimensiones de 640 x 600 píxeles.

#### 3.1. Segmentación previa

Primeramente se toman las imágenes previamente segmentadas seleccionadas por expertos con el algoritmo, posteriormente se realiza la diferencia entre la imagen de materia blanca (eliminación del cráneo y extracción de materia gris es especificado en [12]) con respecto a la imagen segmentada, (dado que la imagen segmentada se encuentra en colores es indispensable convertir la imagen a escala de grises para posteriormente identificar el vector con mayor índice de probabilidad en las hiperintensidades) y así obtener únicamente las hiperintensidades que el algoritmo segmentó, se puede apreciar en la Figura 2 b):




Fig. 2: a) Imagen de materia blanca, b) imagen segmentada, c) obtención de hiperintensidades.

### 3.2. Procesamiento de la imagen

Obtenidas las hiperintensidades es necesario recortar la imagen para fijar un área determinada de trabajo, se obtiene una caja delimitadora (Bounding Box), hallando los límites en el conjunto de hiperintensidades que se pueden observar en la Figura 3. Una vez delimitada el área de trabajo es indispensable adquirir únicamente las Regiones de Interés (ROI's) para cada hiperintensidad individualmente, para esto se binariza la imagen recortada con el umbralado por el método Otsu [11], para posteriormente etiquetar las hiperintensidades de componentes conexas y así obtener cada uno de los objetos, recorriendo los objetos de izquierda a derecha de arriba hacia abajo.




Fig. 3: a) Imagen de la caja delimitadora, b) imagen umbralado por método Otsu, c) imagen etiquetada.

### 3.3. Extracción de características

En esta etapa se extraen las características de cada hiperintensidad obtenida, de forma individual, el principal propósito de la extracción de características es reducir el conjunto de datos de la imagen, calculando algunas propiedades que se pueden ocupar en patrones contenidos en las imágenes, al obtener el vector característico con igual dimensionalidad al número de rasgos obtenidos, es de vital importancia para ejecutar una buena clasificación. Con la finalidad de extraer las características de la ROI's de primer orden el resultado escalar obtenido es almacenado en el vector  $\vec{F} = \{f_1, f_2, \dots, f_6\}$ , donde  $f_n \in \mathbb{R}$  para el vector de primer orden, asumiendo que se tiene una ventana de  $W = w_x \times w_y$  para cada hiperintensidad donde se obtiene la probabilidad de los píxeles con la función  $i(x,y)$  siendo  $x,y$  variables del espacio de la imagen siendo que  $i(x,y)$  puede tomar valores discretos  $[1,G]$  donde  $G = \max(i(x,y))$  es el máximo valor de nivel de gris. Inicialmente se utilizan características de la matemática estadística de primer orden, derivado de la obtención de la intensidad de niveles grises, para lo cual se definen las siguientes características de primer orden:

### Extracción de características del histograma (estadística de primer orden)

$$\text{Media: } \mu = \frac{1}{N} \sum_{i=1}^N i * p(i), \quad (1)$$

$$\text{Varianza: } \sigma^2 = \sum_{i=1}^N (i - \mu)^2 * p(i), \quad (2)$$

$$\text{Skewness: } \mu_3 = \sum_{i=1}^N (i - \mu)^3 * p(i), \quad (3)$$

$$\text{Kurtosis: } \mu_4 = \sum_{i=1}^N (i - \mu)^4 * p(i), \quad (4)$$

$$\text{Max: } Max = \operatorname{argmax} p(i), \quad (5)$$

$$\text{Min: } Min = \operatorname{argmin} p(i). \quad (6)$$

Por parte de las características de la ROI's de segundo orden se considera el centro de masa de cada hiperintensidad para determina una ventana máxima de  $\max = w_x \times w_y$  donde  $i(x,y)$ ,  $i \neq 0$ , a partir de esta ventana se puede obtener la matriz de co-ocurrencia de niveles de gris para posteriormente almacenar los resultados escalares en el vector  $\vec{F} = \{f_7, \dots, f_{11}\}$  y finalmente determinar las 11 características. Tomando así las características de segundo orden derivado de la relación espacial a través de las diferentes ROI's, dichas características pueden ser obtenidas de la matriz de co-ocurrencia de niveles de gris, también nombradas características de textura [14] para lo cual se considera lo siguiente:

### Extracción de características del análisis de textura

$$\text{Entropía: } - \sum_{i=1}^N \sum_{j=1}^M p(i, j) * \log(p(i, j)), \quad (7)$$

$$\text{Contraste: } \sum_{i=1}^N \sum_{j=1}^M p(i, j)^2 * (p(i, j)), \quad (8)$$

$$\text{Energía: } \sqrt{\sum_{i=1}^N \sum_{j=1}^M p^2(i, j)}, \quad (9)$$

$$\text{Correlación: } \frac{\sum_{i=1}^N \sum_{j=1}^M p(i, j) - \mu_i \mu_j}{\sigma_i \sigma_j}, \quad (10)$$

$$\text{Homogeneidad: } \sum_{i=1}^N \sum_{j=1}^M \frac{p(i, j)}{1 + (i - j)^2}. \quad (11)$$

### 3.4. Clasificador red neuronal

El modelo de una red neuronal multicapa con retropropagación se encuentra estructurada primeramente por las entradas o vector característico para alimentar la red neuronal, posteriormente se introducen las capas de neuronas (donde inicialmente se encuentra la capa oculta), es importante mencionar que las capas de neuronas contienen una función de activación que para nuestro caso en particular se implementa una función de activación sigmoidea; en la siguiente etapa se implementa un bloque de retraso, el cual se actualiza en pasos discretos y toma solamente valores enteros, finalmente las salidas son conectadas a las entradas, con la finalidad de ajustar los pesos en cada una de las capas, buscando un mínimo a una función de error, este error decrece con el número de iteraciones y la red neuronal converge a la solución deseada, debido a que en futuro las salidas de la red son ajustadas, estas se calculan a partir de las salidas anteriores se puede apreciar el clasificador en la Figura 4. Las redes recurrentes son potencialmente más potentes que las redes multicapa.

Para este clasificador en específico se utilizó una base de conocimiento previa, de la cual se obtuvieron los rasgos característicos de las lesiones y no lesiones dentro de la sustancia blanca, dicho reconocimiento de patrones se utilizan como entradas para alimentar la red neuronal con retropropagación, siendo ésta, capaz de detectar una separación no lineal entre las características dadas y así poder clasificar los patrones en las salidas correspondientes.

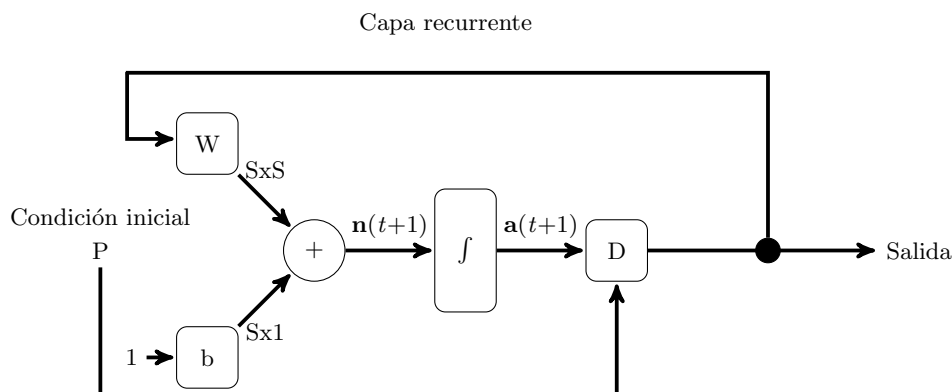


Fig. 4: Red recurrente [4].

**Entrenamiento** Para determinar el vector característico descrito en la sección 3.3, se alimentó la red tomando 24 imágenes de lesión y 5 imágenes de no lesión, siendo un total de 173 subimágenes y 90 subimágenes respectivamente. Al obtener el conjunto de datos característicos, se utiliza la información por secciones para minimizar directamente el error total, por ende se puede actualizar muchas veces las ponderaciones hasta que se cumpla la regla de parada, para ello

es necesario la lectura de varios datos. En este trabajo se utiliza una técnica de optimización, el algoritmo del gradiente conjugado, el cual converge a un mínimo de una función cuadrática en un número finito de iteraciones; Por parte de la clasificación se utiliza la retropropagación previamente explicada.

## 4. Resultados

El grupo de casos del conjunto de datos fueron 70% de las subimágenes como datos de entrenamiento, dentro de las cuales se incluyen los casos de lesión y no lesión, para los datos de validación se ocupó el 15%, de igual forma se utilizó el mismo porcentaje para los datos de prueba, dado que no hay un criterio general para la elección del número de neuronas, inicialmente se ocuparon  $\frac{2}{3}$  de los descriptores de entrada y posteriormente se iteraron pruebas para seleccionar el mejor rendimiento de la red, finalmente se seleccionaron 11 neuronas en la capa oculta.

Para la resolución de la matriz de confusión que se puede observar en la Figura 5 que se obtienen 2 salidas binarias indicando 1 para las lesiones y 0 para no lesiones, si el valor esperado de salida es lesión y la red neuronal clasifica correctamente como lesión, entonces se conoce como un VP, si por otra parte el valor de salida indica que es lesión pero es no lesión entonces se considera como Falso Positivo (FP). Verdaderos Negativos (VN) cuando la salida deseada es no lesión y el resultado esperado también es no lesión, cuando la salida es una lesión pero la red neuronal lo clasifica como no lesión entonces es Falso Negativo (FN). Dichos datos se pueden reflejar en la matriz de confusión indicando que 100% de no lesiones son correctamente clasificadas, 96 % de las lesiones son correctamente clasificadas y 4% de las lesiones son mal clasificadas, la matriz de confusión en general indica que la red neuronal multicapa con retropropagación tiene un alto valor predictivo de clasificación.

## 5. Conclusiones

Este trabajo se aplica en la metodología [12] con la finalidad de derivar un clasificador de hiperintensidades presentes en la sustancia blanca del cerebro; de las cuales se extraen características de estadística de primer orden mediante el histograma, también se ocupan las características de segundo orden análisis de textura correspondiente a las IRM para alimentar la RNMR. Los resultados obtenidos fueron completamente satisfactorios con una precisión del 98.9 %, cuya finalidad es identificar las lesiones y no lesiones presentes en la sustancia blanca. El método propuesto es aplicado únicamente con imágenes T2-Flair y el trabajo futuro a realizar por el presente proyecto es implementar un segmentador automático para precisar la correcta identificación de lesiones en el cerebro.





Fig. 5: Matriz de confusión de la red neuronal.

**Agradecimientos.** Este trabajo fue realizado gracias al apoyo del Consejo Nacional de Ciencia y Tecnología CONACYT y el Instituto Politécnico Nacional SIP-IPN mediante el proyecto No.20171559, COFAA-IPN y BEIFI-IPN.

## References

1. Esclerosis múltiple: Esperanza en la investigación (2012)
2. Akselrod-Ballin, A., Galun, M., Gomori, J.M., Filippi, M., Valsasina, P., Basri, R., Brandt, A.: Automatic segmentation and classification of multiple sclerosis in multichannel mri. *IEEE Transactions on Biomedical Engineering* 56(10), 2461–2469 (Oct 2009)
3. Anbeek, P., Vincken, K., A Viergever, M.: Automated ms-lesion segmentation by k-nearest neighbor classification (01 2008)
4. Demuth, H.B., Beale, M.H., De Jess, O., Hagan, M.T.: *Neural network design*. Martin Hagan (2014)
5. García-Lorenzo, D., Francis, S., Narayanan, S., Arnold, D.L., Collins, D.L.: Review of automatic segmentation methods of multiple sclerosis white matter lesions on conventional magnetic resonance imaging. *Medical image analysis* 17(1), 1–18 (2013)

6. García-Lorenzo, D., Lecoeur, J., Arnold, D.L.: Multiple Sclerosis Lesion Segmentation Using an Automatic Multimodal Graph Cuts, pp. 584–591 (2009)
7. Hill, J.E., Matlock, K., Pal, R., Nutter, B., Mitra, S.: Automated segmentation of ms lesions in flair, dir and t2-w mr images via an information theoretic approach (2016)
8. Lladó, X., Oliver, A., Cabezas, M., Freixenet, J., Vilanova, J.C., Quiles, A., Valls, L., Ramió-Torrent, L., Rovira, L.: Segmentation of multiple sclerosis lesions in brain mri: A review of automated approaches. *Information Sciences* 186(1), 164–185 (2012)
9. Moeskops, P., Viergever, M.A., Mendrik, A.M., de Vries, L.S., Benders, M.J.N.L., Igum, I.: Automatic segmentation of mr brain images with a convolutional neural network. *IEEE Transactions on Medical Imaging* 35(5), 1252–1261 (May 2016)
10. Muñoz-Pérez, M.J., Espinosa-Villaseñor, D.: Deterioro cognitivo y demencia de origen vascular. *Revista Mexicana de Neurociencia* 17(6), 85–96 (2016)
11. Otsu, N.: A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics* 9(1), 62–66 (Jan 1979)
12. Patino-Correa, L.J., Pogrebnyak, O., Martinez-Castro, J.A., Felipe-Riveron, E.M.: White matter hyper-intensities automatic identification and segmentation in magnetic resonance images. *Expert Systems with Applications* 41(16), 7114–7123 (2014)
13. Pham, D.L.: Robust fuzzy segmentation of magnetic resonance images. In: *Proceedings 14th IEEE Symposium on Computer-Based Medical Systems. CBMS 2001*. pp. 127–131 (2001)
14. Regniers, O., Da Costa, J., Grenier, G., Germain, C., Bombrun, L.: Texture based image retrieval and classification of very high resolution maritime pine forest images. In: *International Geoscience and Remote Sensing Symposium (IGARSS)*. pp. 4038–4041 (2013)
15. Schmidt, P., Gaser, C., Arsic, M., Buck, D., Frschler, A., Berthele, A., Hoshi, M., Ilg, R., Schmid, V.J., Zimmer, C., Hemmer, B., Mhlau, M.: An automated tool for detection of flair-hyperintense white-matter lesions in multiple sclerosis. *NeuroImage* 59(4), 3774–3783 (2012)
16. Tian, D., Fan, L.: A brain mr images segmentation method based on som neural network. In: *2007 1st International Conference on Bioinformatics and Biomedical Engineering, ICBBE*. pp. 686–689 (2007)
17. Valverde, S., Cabezas, M., Roura, E.: Improving automated multiple sclerosis lesion segmentation with a cascaded 3d convolutional neural network approach. *NeuroImage* 155(Supplement C), 159 – 168 (2017)
18. Wels, M., Huber, M., Hornegger, J.: Fully automated segmentation of multiple sclerosis lesions in multispectral mri. *Pattern Recognition and Image Analysis* 18(2), 347–350 (2008)
19. Wu, Y., Warfield, S.K., Tan, I.L., Wells III, W.M., Meier, D.S., van Schijndel, R.A., Barkhof, F., Guttmann, C.R.G.: Automated segmentation of multiple sclerosis lesion subtypes with multichannel mri. *NeuroImage* 32(3), 1205–1215 (2006)