

Identificación automática y segmentación de las hiperintensidades de la materia blanca en imágenes de resonancia magnética

Lizette Johanna Patiño Correa, Oleksiy Pogrebnyak,
Edgardo Manuel Felipe Riverón, Jesus Alberto Martinez Castro

*Centro de Investigación en Computación, Instituto Politécnico Nacional,
México, D.F., México*

Resumen. En este trabajo, se presenta una nueva metodología para la identificación automática y la segmentación de hiperintensidades de la materia blanca que aparecen en las imágenes de resonancia magnética de cortes axiales del cerebro. Para ello, primero se emplea una secuencia de técnicas de procesamiento de imágenes para formar la imagen, donde las hiperintensidades de la materia blanca notablemente difieren del resto de los objetos. Esta etapa de preprocesamiento facilita el proceso posterior de identificación y segmentación de las regiones de hiperintensidades. La metodología propuesta fue probada en 55 imágenes diferentes de resonancia magnética de seis pacientes. Estas imágenes fueron analizadas por el sistema propuesto y las imágenes resultantes de hiperintensidades fueron comparadas con las imágenes manualmente segmentadas por un experto. Los resultados experimentales muestran la tasa promedio de positivos verdaderos de 0.9 y el índice de similitud de 0.7. Al mismo tiempo, los falsos positivos se encuentran en la mayoría de los casos dentro de la materia gris que no causa problemas para el diagnóstico temprano. La metodología propuesta del procesamiento y análisis de imágenes de resonancia magnética puede ser útil para la detección temprana de lesiones de la materia blanca del cerebro.

Palabras clave: imágenes de resonancia magnética, segmentación de imágenes, hiperintensidades de la materia blanca.

Abstract. In this work, a new methodology for automatic identification and segmentation of white matter hyperintensities that may appear in magnetic resonance images of brain axial cuts is presented. For this purpose, firstly a sequence of image processing techniques is employed to form an image where the white matter differ notoriously from the rest of the objects. This pre-processing stage facilitates the posterior process of identification and segmentation of the hyperintensity regions. The proposed methodology was tested on different 55 images magnetic resonance images of six patients. These images were analysed by the proposed system and the resulted images were compared to the images manually segmented by an expert. The experimental results show the mean rate of true positives of 0.9 and the similarity index of 0.7. At the same time, the false positives are found in the most cases within the grey matter that does not cause problems for early diagnosis. The proposed methodology of magnetic resonance image processing and analysis may be useful in early detection of brain white matter deceases.

Key words: magnetic resonance images, image segmentation, white matter hiperintensities

1 Introducción

Actualmente, las imágenes de resonancia magnética (MRI) son instrumentos importantes usados ampliamente en diferentes aplicaciones médicas. Entre los diferentes tipos de posibles males que se pueden detectar con MRI, las imágenes de cortes axiales del cerebro se usan para detectar varias enfermedades caracterizadas por anomalías de la materia blanca. Las lesiones de la materia blanca se caracterizan por la presencia de hiperintensidades dentro de ella (WMH), las que se pueden encontrar dentro de los tejidos de la materia blanca normal como objetos más brillantes cuando el sistema MRI usa las técnicas de ponderación T-2 y la recuperación de inversión atenuada del líquido (FLAIR) [1].

El problema de la segmentación de la WMH es difícil porque las diferencias en brillo entre regiones normales y dañadas son pequeñas y puede variar en toda la imagen. La segmentación manual es posible, pero es una tarea que consume mucho tiempo y está sujeta a la variabilidad del operador; por ello, la reproducción del resultado de la segmentación manual es difícil; por otra parte, el nivel de confianza atribuida sufre también [2]. Por estas razones, la segmentación automática de la WMH es preferible, pero es una tarea bastante difícil y pertenece al área de investigaciones activas [3, 4, 5]. Recientemente, un gran número de métodos de segmentación de la WMH fueron propuestos en la literatura. En [2], describen tres generaciones de tales métodos.

En este artículo, presentamos una metodología para la segmentación de WMH completamente automática usando imágenes de escala de grises de ponderación T2 FLAIR. La metodología propuesta puede ser útil para los radiólogos que analizan y diagnostican los males cerebrales sin la necesidad de costosas técnicas basadas en muchos cortes multiespectrales y diferentes ponderaciones que producen un gran volumen de datos para cada paciente. El trabajo está organizado así: después de la Introducción, la sección 2 describe la metodología de segmentación de la WMH; en la sección 3 se presentan los resultados, y las conclusiones se brindan en la sección 4.

2 Metodología de la segmentación de las WMH

La metodología propuesta de la segmentación de las WMH en imágenes MRI consta de varios pasos que se pueden dividir en dos etapas: preparación de la imagen y procesamiento final. En la primera etapa, la imagen es preprocesada para el tratamiento posterior, mediante la eliminación del cráneo y la separación de la materia gris. Una vez que la imagen es preparada, en la etapa final diferentes tipos de tejidos del cerebro se analizan y la materia blanca se separa. Finalmente, las hiperintensidades en la materia blanca se detectan y segmentan. El diagrama de bloques de la metodología propuesta se presenta en la figura 1.

2.1. Etapa de preparación de la imagen

En esta etapa se realizan diferentes técnicas de tratamiento: preprocesamiento, eliminación del cráneo y extracción de la materia gris.




Fig.1. Diagrama de bloques de la metodología propuesta para la segmentación de las WMH.

2.1.1. Preprocesamiento

El paso de preprocesamiento permite disponer de la imagen lista para la eliminación del cráneo. El resultado de este paso es la imagen etiquetada cuyos objetos son el cerebro y partes del cráneo que después se eliminan. El preprocesamiento consiste en el umbralado por el método de Otsu [6], el filtrado morfológico por apertura y clausura, el suavizado con promedio deslizando y el etiquetado de las componentes conectadas.

La técnica de Otsu segmenta los objetos de la imagen que obviamente difieren del fondo, esto es, el cerebro y las cavidades del cráneo en MRI como se muestra en la figura 2. Después del umbralado se aplican tres filtros de mejoramiento de imágenes: filtros de apertura y clausura [7] con el tamaño del elemento de estructura de 4x4 píxeles, y el filtro de promedio deslizando [8] con la ventana de 5x5 píxeles. El objetivo del filtro de apertura es eliminar las uniones indeseables entre objetos después del umbralado Otsu y separar en las imágenes MRI el cráneo y los artefactos que tienen mucho menor tamaño que el cerebro. El filtro de clausura suaviza el contorno del cerebro y rellena hoyos; el filtro de promedio deslizando suaviza la imagen y repone los puntos de las esquinas perdidos en el procesamiento previo.

En el paso siguiente los componentes conectados se etiquetan. Para ello, se empleó el algoritmo de conectividad 8 [9], el cual considera todos los píxeles vecinos tratados que permite etiquetar de una manera más correcta el objeto completo. El objetivo del etiquetado es distinguir los objetos en la imagen por sus etiquetas para poder contarlos y determinar su eventual tamaño. La figura 3 ilustra el etiquetado: en la imagen preprocesada se asigna una etiqueta a cada objeto de diferente nivel de gris.




Fig. 2. Umbralado Otsu: a) imagen original; b) imagen resultante del umbralado. Las flechas indican las uniones indeseables entre los objetos.




Fig. 3. Componentes conectadas etiquetadas de la imagen del cerebro.

2.1.2 Eliminación del cráneo y separación de la materia gris

La eliminación del cráneo se realiza sobre la base de que el tamaño del cerebro es mucho mayor que el tamaño de los artefactos obtenidos con el preprocesamiento de la imagen. Para ello, primero se cuentan todos los objetos, las etiquetas se guardan y se determina el tamaño de cada objeto. Segundo, los objetos de mayor tamaño se seleccionan y los de menor tamaño se eliminan, separando así los objetos de tejidos del cerebro del resto. Como resultado se obtiene la imagen de los dos lóbulos cerebrales.

En el paso siguiente, solo algunas partes de la materia gris se extraen porque ellas no están bien definidas en la imagen original y sólo se pueden reconocer mejorando el contraste. Ello se ilustra en figura 4a, donde después de mejorar el contraste las regiones de materia gris deben eliminarse ya que representan las hiperintensidades de la materia blanca, las cuales se pueden confundir con las hiperintensidades de la materia blanca, resultando la identificación de WMH erróneas.

Para extraer la parte informativa de la materia gris, primero se aplica el algoritmo de relleno de hoyos [7] a las regiones del cerebro porque en algunos casos las WMH se encuentran en los bordes de los hoyos. Después, se aplica el algoritmo de tamaño/porcentaje especialmente diseñado para eliminar un porcentaje de los objetos externos del cerebro.




Fig. 4. Imágenes de las regiones de materia gris después del aumento de contraste y la extracción de la parte informativa de la materia gris: a) regiones de contraste aumentado; b) extracción de la parte informativa de la materia gris.

Algoritmo de erosión tamaño/porcentaje

Este algoritmo elimina las regiones usando erosión morfológica [7] con un elemento de estructura de 3 píxeles de diámetro. El algoritmo erosiona la imagen hasta que la diferencia entre la imagen original obtenida después del aumento de contraste de las regiones de materia gris y el relleno de hoyos, $f_h(x,y)$, y la obtenida por erosión, $f_e(x,y)$, se aproxima al porcentaje predeterminado:

- 1) Calcular el tamaño de los píxeles diferentes de cero V_0 en la imagen $f_h(x,y)$;
- 2) Realizar la erosión con un elemento de estructura de 3 píxeles de diámetro de la imagen de entrada la cual se designa como $f_e(x,y)$.
- 3) Calcular el tamaño V_e de los píxeles diferentes de cero en la imagen $f_e(x,y)$.
- 4) Comparar V_0 y V_e . Si $(V_0 - V_e/V_0) \cdot 100\% < 35.55\%$, regresar al paso 2.

La imagen obtenida con el algoritmo de tamaño/porcentaje propuesto se intersecta con la imagen binaria del cerebro. Como resultado se obtiene la parte de materia gris (ver la figura 4). La figura 4b muestra que todos los objetos con el contraste mejorado pertenecientes a las hiperintensidades de materia gris se eliminaron.

2.2. Procesamiento final

En esta etapa la imagen se procesa hasta que se obtenga la WMH segmentada. La etapa consta de tres pasos: tratamiento de la imagen, identificación de la WMH y segmentación de la WMH.

2.2.1. Tratamiento de la imagen

El objetivo de este paso es mejorar el contraste de la imagen. Para ello, el filtro de promedio deslizante [8] con la ventana de tamaño 5x5 se aplica a la imagen original del cerebro segmentado. Después la imagen se delimita y se corta en los límites del cerebro usando una caja delimitadora. Seguidamente, el fondo de la imagen se sustituye por el valor promedio de los píxeles diferentes de cero como se muestra en la figura 5.

Después, se mejora el contraste de la imagen mediante el algoritmo de corrección gamma [8] con un factor de 30. Así, se acentúan las lesiones y el fondo de la imagen y sus tamaños se reestablecen. Finalmente, el contraste se mejora agregando la imagen resultante a la imagen original del cerebro segmentado; como se muestra en la figura 6.

La imagen $f(x,y)$ obtenida así es la imagen de entrada para el paso de crecimiento de regiones.




Fig. 5. Tratamiento de la imagen mediante la caja delimitadora y el fondo promedio: a) delimitación de la imagen del cerebro; b) corte de la imagen del cerebro con el fondo promediado.




Fig. 6. Mejoramiento del contraste: a) aumento del contraste por saturación; b) la imagen después de aplicar la corrección gamma.

2.2.2. Segmentación e identificación de las WMH

En esta etapa, primero se determinan las regiones de interés con base en los píxeles más brillantes, pues ellos representan las regiones más significativas. Una vez que las regiones de interés se han determinado, se halla el centroide de cada región. Los píxeles del centroide resultante son las semillas para el proceso siguiente de crecimiento de regiones; ellas forman la matriz de semillas $S(x,y)$. La figura 7a muestra el resultado del proceso de crecimiento de regiones donde a cada región se asocia sólo un píxel de semilla.




Fig. 7. Segmentación de la WMH: a) detección de las regiones de interés; b) la imagen segmentada.

Los píxeles centroides de las regiones de interés de la imagen resultante del proceso de identificación de la WMH son semillas para la segmentación por crecimiento de las regiones [8, 10]; para este fin se utilizó el algoritmo con conectividad de 8. El resultado obtenido por el procedimiento de crecimiento de regiones es la imagen $g(x,y)$ mostrada en la figura 7b.

3 Discusión de resultados

En esta sección se presentan los resultados de la evaluación del proceso de identificación de las WMH. Para la evaluación se usaron 55 imágenes ponderadas T2 FLAIR de 6 pacientes diferentes con esclerosis múltiple proporcionadas por el Instituto Nacional de Rehabilitación. Estas imágenes son de escala de grises de tamaño 600x600 píxeles. Para la comparación estas imágenes fueron segmentadas manualmente por un radiólogo experto y comparadas con las imágenes segmentadas automáticamente con la metodología propuesta. El criterio empleado para el análisis comparativo fue la diferencia de tamaño: $V_{dif} = ((V_{man} - V_{aut})/V_{man}) \cdot 100\%$, donde V_{aut} es el tamaño de la imagen segmentada automáticamente y V_{man} es el tamaño de la imagen segmentada manualmente.

Las segmentaciones manual y automática fueron comparadas utilizando la tasa de verdaderos positivos (TPR), la tasa de falsos positivos (FPR) y el índice de similitud (SI). La tasa media de los positivos verdaderos (TPR) se define como (Ong et al., 2012): $TPR = V(AS \cap MS)/V(MS)$, donde $V(\cdot)$ es el número de elementos en el conjunto, MS es el conjunto obtenido de la segmentación manual de WMH, AS es el conjunto obtenido de la segmentación automática de WMH y $\cap$ denota el operador de intersección. La tasa media de falsos positivos (FPR) se define como (Ong et al., 2012): $FPR = V(AS \cap \overline{MS})/V(MS)$, donde $\overline{MS}$ es el conjunto de puntos diferentes del conjunto de segmentación de WMH manual. El índice de similitud (SI) se define, como (Ong et al., 2012): $SI = 2V(AS \cap MS)/V(AS) + V(MS)$.

El promedio de verdaderos positivos obtenido es $TPR = 0.9$, lo que significa que la mayoría de las WMH segmentadas manualmente también fueron detectadas automáticamente: 86% de las imágenes tienen TPR en el rango de 0.8 a 1, 7% tienen $TPR = 0.7$, y 7% tienen TPR en el rango de 0.4 a 0.6.

Al mismo tiempo la tasa media de falsos positivos fue $FPR = 0.7$: 50% de las imágenes tienen FPR en el rango de 0 a 0.5, 48% tienen FPR en el rango de 0.8 a 1, y 2% tienen FPR en el rango de 0.6 to 0.7.

El índice promedio de similitud es $SI = 0.7$ que indica una coincidencia significativa entre las dos segmentaciones manual y automática. El 70% de las imágenes tienen SI en el rango de 0.7 a 1 y el 30% restante tienen SI en el rango de 0.3 a 0.6.




Fig. 8. Diferencia de tamaño entre las segmentaciones manual y automática de las WMH.




Fig. 9. Gráfica comparativa de los resultados obtenidos por el método de detección automática de valores atípicos y el método propuesto.

Los resultados de la comparación de la segmentación de las WMH en términos de diferencia de tamaño se muestran en la figura 8.

La metodología propuesta fue comparada con el método de detección automática de valores atípicos [3]. Los resultados obtenidos con la metodología propuesta son mejores en términos del índice de similitud y de la tasa de verdaderos positivos, pero existen más falsos positivos al compararla con el modelo de intensidad local [3]. La figura 9 muestra esto gráficamente.

4 Conclusiones

Se ha propuesto una metodología automática para la identificación y segmentación de las hiperintensidades de la materia blanca (WMH) del cerebro. Los resultados finales obtenidos en la identificación y segmentación de las WMH se acercan a los resultados obtenidos con la segmentación de las WMH manual supervisada por un experto. La exactitud de la identificación de las WMH obtenida fue de 87.8%. Las WMH identificadas se segmentan mediante el algoritmo de crecimiento de regiones, obteniéndose una tasa de verdaderos positivos y de índice de similitud de 70%. El trabajo futuro ha de ser orientado hacia la reducción de la tasa de falsos positivos, para

lo que deberán incluirse etapas adicionales de procesamiento de imágenes en la metodología propuesta.

Reconocimientos

Este trabajo ha sido apoyado por el Instituto Politécnico Nacional a través de los proyectos SIP 20140119 y 20141215. Los autores expresan su agradecimiento al Instituto Nacional de Rehabilitación por los datos de MRI brindados.

Referencias

1. Raniga, P., Schmitt, P., Bourgeat, P., Fripp, J., Villemagne, V. L., Rowe, C.C., Salvado, O.: Local intensity model: An outlier detection framework with applications to white matter hyperintensity segmentation. In: Proceedings of 2011 IEEE International Symposium on Biomedical Imaging: From Nano to Macro 2057 – 2060 (2011)
2. Withey, D.J., Koles, Z.J. Medical image segmentation: Methods and software. In: Proceedings of NFSI-ICFBI Joint meeting of the 6th international symposium on noninvasive functional source imaging of the brain and heart and the international conference on functional biomedical imaging 140 – 143 (2007)
3. Ong, K.H., Ramachadam, D., Mandava, R., Shuaib, I.L. Automatic white matter lesion segmentation using an adaptive outlier detection method. *Journal of Magnetic Resonance Imaging* 30(6), 807 – 15 (2012)
4. Khademi, A., Venetsanopoulos, A.: Robust White Matter Lesion Segmentation in FLAIR MRI. *IEEE Transactions on Biomedical Engineering* 39 (3), 860 – 872 (2012)
5. Samaille, T., Fillon, L., Cuingnet, R., Jouvent, E., Chabriat, H., Dormont, D., Colliot, O., Chupin, M. Contrast-Based Fully Automatic Segmentation of White Matter Hyperintensities: Method and Validation. *PLoS ONE* 7(11): e48953 (2012)
6. Otsu, N. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1), 62-67 (1979)
7. Soille, P.: *Morphological Image Analysis: Principles and Applications*. Second edition. Springer (2004)
8. Gonzalez, R.C., Woods, R.E.: *Digital image processing*. Third Edition, Pearson, Prentice Hall, (2008)
9. Cheng, C.C., Peng, G.J., Hwang, W.L.: Pixel Connectivity. *IEEE Transactions on Image Processing* 18 (1), 52 – 59 (2009)
10. Pratt, W.K.: *Digital Image Processing 4th Edition*, John Wiley & Sons, Inc., Los Altos, California (2007)

