

EXTRACCIÓN DE CARACTERÍSTICAS DISCRIMINANTES EN IMÁGENES BIOMÉDICAS

Rodriguez Osorio Mario Andres (1), Aviña Cervantes Juan Gabriel (2)

1 [Ingeniería Electrónica, Universidad Francisco de Paula Santander] | [marioandresro@ufps.edu.co]

2 [Departamento de Ingeniería Electrónica, División de Ingenierías, Campus Irapuato-Salamanca, Universidad de Guanajuato] | [avina@ugto.mx]

Resumen

En este trabajo se realiza la identificación de tumores cerebrales en *magnetic resonance imaging (MRI)* mediante un algoritmo que hace uso de la técnica de *Gray Level Co-occurrence Matrix (GLCM)* que permite extraer características de textura por el análisis estadístico de una vecindad entre píxeles. Para lograr la detección de la zona de interés, se toma la imagen de entrada y se visualiza por fragmentos a través de una ventana con tamaño y corrimiento óptimos encontrados en la prueba del algoritmo. Seguidamente se determinan la *GLCM* y los descriptores de Haralick de cada fragmento desconocido y estos últimos son comparados uno a uno con los respectivos descriptores de Haralick de los tumores localizados en cada *MRI* de la base de datos previamente identificados por un experto. El método de comparación empleado es una métrica de distancia correspondiente a la distancia euclidiana normalizada por ser una de las más comunes en el análisis de imágenes, posteriormente se encuentra la distancia mínima que servirá como parámetro determinante en la similitud de textura entre la imagen de entrada y la base de datos para finalmente visualizar la imagen de salida.

Abstract

This work presents a methodology for brain tumors identifying in images magnetic resonance imaging (*MRI*) using an algorithm that uses the techniques of *Gray Level Co-occurrence Matrix (GLCM)*, which allows extracting texture characteristics by the statistical analysis of the neighborhood of the pixel. To extract the interest region, the input image is taken and visualized by sections using a rectangular window, which optimal size and displacement parameters are determined during the algorithm test. Next, the *GLCM* and the Haralick features were determined for each unknown fragment and these were compared with the respective Haralick descriptors of the tumor detected by an expert in an *MRI* database. The detection method uses a distance metric corresponding to the normalized Euclidian distance, being one of the most common in image processing, then the minimal distance is obtained, and it is used as the key parameter into the texture similarity between the input image and database. Finally, the output image with the detected images is visualized.

Palabras Clave

Matriz de co-ocurrencia de escala de grises (GLCM); imagen de resonancia magnética (MRI); descriptores de Haralick; distancia euclidiana.

INTRODUCCIÓN

El análisis convencional de imágenes médicas por medio de la radiología está sujeto a diagnósticos que dependen de la experiencia, juicio personal y capacidad visual del radiólogo por lo que habrá un grado de incertidumbre en la interpretación de una imagen, esta incertidumbre puede ser reducida con la ayuda de herramientas como el análisis computacional de imágenes que aportan información determinante para ayudar a afianzar la decisión del radiólogo [1]. Últimamente, han sido desarrollados variedad de estudios de investigación relacionados con el procesamiento de imágenes médicas de diferentes naturalezas, como lo son las imágenes de resonancia magnética (*MRI*), el ultrasonido (*US*) o la tomografía computarizada (*CT*), entre otras. Esto le ha dado mayor credibilidad al sector clínico en el uso de diagnóstico asistido por computadora. En el análisis de imágenes médicas se procura evitar el pre-procesamiento como el filtrado o eliminación de ruido, con el fin de no alterar en lo posible la información contenida en la imagen y pasar a etapas posteriores como la segmentación y extracción de características [2]. El procesamiento de imágenes médicas basado en técnicas de características de textura presenta un rendimiento confiable para la detección de regiones de interés como masas o tumores, por ejemplo [3]. En el campo del procesamiento de imágenes, en términos generales la textura se entiende como la variación de datos en una escala más pequeña a la escala de interés. Además de ser dependiente de la escala, de manera más específica es una característica propia de la imagen objeto y no algo causado por el instrumento de medición con que se obtuvo [4]. La matriz de co-ocurrencia de niveles de gris (*GLCM*) es la técnica escogida en este estudio por ser la más popular para la obtención de características de textura. Variedad de características pueden ser extraídas de esta técnica, para este estudio se hace uso de 14, de los llamados descriptores de Haralick [4].

MATERIALES Y MÉTODOS

Para la realización de este proyecto se utilizó un conjunto de imágenes de resonancia magnética (*MRI*) del cerebro humano tomadas de un solo paciente en formato mapa de bits (*bmp*) provenientes de la base de datos *MICCAI 2012 Challenge on Multimodal Brain Tumor Segmentation Benchmark* [5], [6]. De estas imágenes, se seleccionaron 30 para conformar la base de datos (entrenamiento) y 1 como imagen de entrada (evaluación). A continuación, en la Figura 1 se presentan tres de las imágenes utilizadas en el estudio, donde se puede visualizar el tumor o zona de interés.

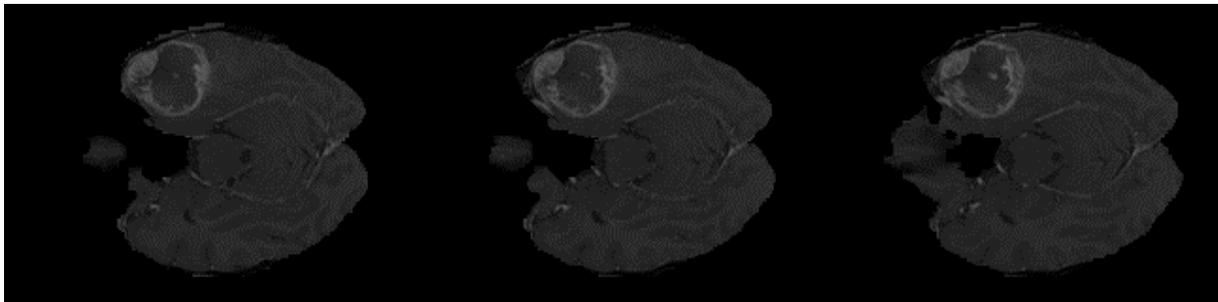


Figura 1. Imágenes de resonancia magnética de un paciente con tumor cerebral.

La extracción de características de textura se hace por medio de un algoritmo desarrollado en la herramienta computacional MatLab®, que resultó útil por las herramientas disponibles para el procesamiento de imágenes. Las fases que componen la metodología que se llevó a cabo para el procesamiento y análisis de las imágenes se presenta en la Figura 2.



Figura 2. Fases de análisis del procesamiento de imágenes.

Matriz de co-ocurrencia de escala de grises.

La *GLCM* es una técnica para el análisis de textura, la cual representa la frecuencia relativa de niveles de gris de pares de píxeles, ocurriendo en cada dirección y distancia [2], [7]. Ésta se define como en (1):

$$P_{d,\theta}(i, j) \quad (1)$$

Siendo L los niveles posibles de intensidad, (i, j) indican el número de veces que cada par de píxeles con intensidades i, j para $i \geq 0, j \leq L - 1$ ocurre en la imagen en la posición especificada por una distancia d y un ángulo θ . El tamaño de la matriz de co-ocurrencia P está determinado por los posibles niveles de intensidad [4].

Extracción de características de textura.

Los algoritmos extractores de características basados en textura resaltan por su efectividad en la discriminación de tejidos, las características de textura encuentran principalmente la granularidad y repetitividad de patrones en la distribución de píxeles [2], [4], [7]. Haralick [2], sugiere 14 descriptores de textura que se pueden extraer de cada una de las *GLCM*:

- Angular Second Moment (Energy).
- Contrast.
- Correlation.
- Sum of Squares (Variance).
- Inverse Difference Moment. (Homogeneity).
- Sum Average.
- Sum Variance.
- Sum Entropy.
- Entropy.
- Difference Variance.
- Difference Entropy.
- Information Measures of Correlation I.
- Information Measures of Correlation II.
- Maximal Correlation Coefficient.

Función distancia

Distancia es una función de valor real de dos puntos de imagen (j_1, k_1) y (j_2, k_2) , que satisfacen las propiedades (2), (3) y (4).

$$d\{(j_1, k_1), (j_2, k_2)\} \geq 0 \quad (2)$$

$$d\{(j_1, k_1), (j_2, k_2)\} = d\{(j_2, k_2), (j_1, k_1)\} \quad (3)$$

$$d\{(j_1, k_1), (j_2, k_2)\} + d\{(j_2, k_2), (j_3, k_3)\} \geq d\{(j_1, k_1), (j_3, k_3)\} \quad (4)$$

Existen varias funciones distancia que cumplen estas propiedades, pero la más común en el análisis de imágenes es la distancia Euclidiana [7], que se expresa en (5).

$$d_E = \sqrt{\{(j_1 - j_2)^2 + (k_1 - k_2)^2\}} \quad (5)$$

Así pues, se aplica este método para medir la distancia entre los vectores que contienen los descriptores de Haralick de cada ventana de la imagen original y los de cada zona patógena en las imágenes de la base de datos, posteriormente se encuentra la distancia mínima y a partir de esta se determina el valor óptimo para el cual el algoritmo ubica de mejor manera el tumor y en la escala adecuada para finalmente ser mostrado en la imagen de salida.

RESULTADOS Y DISCUSIÓN

Para la obtención de las matrices en este estudio se establece $d = 1$ y los niveles de intensidad corresponden a 8 bits para el tipo de imágenes seleccionadas. Las *GLCM* de las imágenes pertenecientes a la base de datos se calculan únicamente para la zona patógena, es decir, en la región que corresponde a la ventana en cada iteración. Por otro lado, para la imagen de entrada el cálculo de la matriz se hace por medio de una ventana de dimensiones determinadas, en este caso de 29 por 35, la cual permite calcular la matriz de co-ocurrencia por secciones de la imagen con un desplazamiento determinado en las pruebas del algoritmo. En primer lugar, se tienen la ubicación del tumor en las imágenes del banco de datos con la previa identificación de un experto (ver Figura 3) y la imagen de entrada lista para ser “ventaneada” (ver Figura 4).

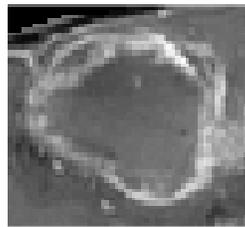


Figura 3. Sección anómala en una imagen de la base de datos.

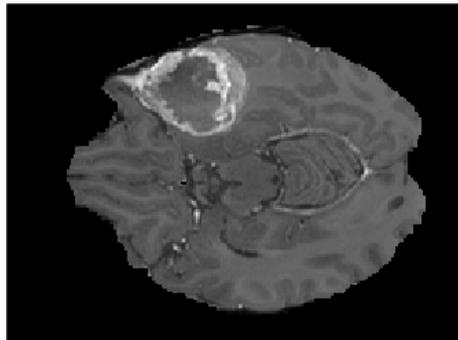


Figura 4. Imagen original.

Seguidamente, se obtuvieron las *GLCM* de cada fragmento desconocido de la imagen original, cada uno de estos se ve a través de la ventana la cual realiza un corrimiento sobre toda la imagen, el tamaño de la ventana y el valor del corrimiento fueron determinados luego de realizar pruebas exhaustivas al algoritmo. A partir de la *GLCM* de cada fragmento se calculó un vector que contiene los 14 descriptores de Haralick, este mismo procedimiento de obtener la *GLCM* y su correspondiente vector se aplicó a cada tumor localizado en cada imagen de la base de datos. Teniendo los vectores que contienen los descriptores se obtuvo la distancia euclidiana entre cada vector de cada fragmento desconocido de la imagen de entrada y los vectores de las zonas patógenas de cada imagen del banco de datos (cabe aclarar que tanto la *GLCM*, como el vector de descriptores fueron inicialmente normalizados, en consecuencia, la distancia). Posteriormente, un análisis

discriminante con la distancia mínima de referencia, permitió determinar la semejanza de textura entre cada fragmento desconocido en la imagen original y cada tumor localizado en las imágenes de la base de datos. Como resultado final se tiene una sub-imagen como se muestra en la Figura 5.



Figura 5. Imagen de salida (tumor de la Imagen de entrada).

CONCLUSIONES

Con la utilización de la *GLCM* y el posterior cálculo de los descriptores de Haralick para cada fragmento de la imagen de entrada y los tumores localizados en cada imagen de la base de datos, se lograron extraer características de textura que comparadas a través de la distancia euclidiana sirvieron para determinar las zonas con mayor similitud de textura y así poder identificar tumores en imágenes del cerebro humano. Se observó mayor eficiencia del algoritmo para mayor cantidad de imágenes en la base de datos (imágenes de entrenamiento) porque así se tienen más características de textura del mismo paciente lo que disminuye la incertidumbre entre los fragmentos desconocidos de la imagen de entrada y el tumor en cada imagen de la base de datos. Entre otros aspectos destacables fueron el ajuste de parámetros como la distancia mínima entre la imagen de prueba y la base de datos y el tamaño de la ventana aplicada a la imagen de entrada, así como su desplazamiento por ésta, con un valor en el cual se identificaba mejor la zona de interés.

AGRADECIMIENTOS

Este trabajo fue desarrollado principalmente gracias al apoyo de la Universidad Francisco de Paula Santander (Colombia) y la División de Ingenierías del Campus Irapuato-Salamanca de la Universidad de Guanajuato (México).

REFERENCIAS

- [1] A. Kassner and R. E. Thornhill, "Texture analysis: a review of neurologic MR imaging applications," *Am. J. Neuroradiol.*, vol. 31, no. 5, pp. 809–816, 2010.
- [2] R. M. Haralick, K. Shanmugam, I. Dinstein, and others, "Textural features for image classification," *IEEE Trans. Syst. Man. Cybern.*, vol. 3, no. 6, pp. 610–621, 1973.
- [3] N. Sharma, A. K. Ray, S. Sharma, K. K. Shukla, S. Pradhan, and L. M. Aggarwal, "Segmentation and classification of medical images using texture-primitive features: Application of BAM-type artificial neural network," *J. Med. physics/Association Med. Phys. India*, vol. 33, no. 3, p. 119, 2008.
- [4] T. M. Deserno, *Biomedical image processing*. Springer Science & Business Media, 2011.
- [5] E. Ilunga-Mbuyamba *et al.*, "Localized active contour model with background intensity compensation applied on automatic MR brain tumor segmentation," *Neurocomputing*, vol. 220, pp. 84–97, 2017.
- [6] B. H. Menze *et al.*, "The multimodal brain tumor image segmentation benchmark (BRATS)," *IEEE Trans. Med. Imaging*, vol. 34, no. 10, p. 1993, 2015.
- [7] W. K. Pratt, "Digital Image Processing: PIKS inside, 2001, John Wiley & Sons," *Inc Ed*.