

DEEP LEARNING AS A TOOL FOR IMPROVING EFFICIENCY OF GLIAL TUMOR DIAGNOSIS

Amaya Rodríguez, Isabel R. *; Duran López, Lourdes; Civit Masot, Javier; Luna Perejon, Francisco; Civit Balcells, Antón; Vicente Díaz, Saturnino; Linares Barranco, Alejandro

Arquitectura y Tecnología de Computadores. Escuela Superior de Ingeniería Informática. Universidad de Sevilla.

*E-mail: iamaya@atc.us.es

RESUMEN

La aplicación de técnicas basadas en Inteligencia Artificial como apoyo a la detección y diagnóstico de cáncer mediante imagen es una práctica muy extendida hoy día. Además, el reconocimiento por regiones de interés y otros algoritmos constituyen una rama de investigación amplia que mejoran considerablemente la calidad de la clasificación. En este trabajo, se propone como caso de estudio la identificación del tumor glial con Imágenes por Resonancia Magnética de pacientes sanos y enfermos mediante la combinación de algoritmos de Deep Learning de detección de regiones que se basan en la extracción de regiones de interés en la imagen utilizando una red Spatial Pyramid Pooling combinado con la modificación de las imágenes de entrada con el algoritmo Fuzzy c-means. Obteniendo un acierto cercano al del personal sanitario.

PALABRAS CLAVE

Deep Learning, Cáncer, SPP, Fuzzy c-means, MRI.

Amaya Rodríguez, I. R.; Duran López, L.; Civit Masot, J.; Luna Perejon, F.; Civit Balcells, A.; Vicente Díaz, S.; Linares Barranco, A.

ABSTRACT

Nowadays, existing Artificial Intelligent techniques are used as a support for cancer detection and diagnosis. Moreover, regional object interest and other related algorithms have become common place for improving the quality of the classification. Opening a wide field of interest and research. In this work, a deep neural network based on a new pooling strategy and image segmentation (Fuzzy c-means) [1] is proposed for glial tumor in Magnetic Resonance Imaging (MRI) images by using Region of Interests methods as Spatial Pyramid Pooling. The power of SPP-net is the possibility of working with feature maps from images with different sizes, and then subsampling these features to generate a fixed-length set and to implement finally a classification step.

KEYWORDS

Deep Learning, Convolutional Neural Networks, Spatial Pyramid Pooling, MRI, Cancer diagnosis.

INTRODUCCIÓN Y OBJETIVOS

La técnica de aprendizaje Deep Learning es una tendencia creciente en el análisis de datos generales y se ha calificado como una de las tecnologías más innovadoras como una forma de automatizar el análisis predictivo. Concretamente, en el uso para el apoyo al diagnóstico clínico. Las decisiones clínicas con respecto al tratamiento de las neoplasias cerebrales se basan, en parte, en Resonancias Magnéticas (RM en adelante) en varias etapas del proceso de tratamiento. El diagnóstico radiológico se basa en el perfil de imagen multiparamétrico (Tomografía Computarizada (CT), MRI convencional, MRI avanzado). La caracterización del tumor es difícil porque el tejido neoplásico es a menudo heterogéneo en los perfiles espaciales y de imagen [2], y para algunas técnicas de imagen a menudo se superpone con el tejido normal (especialmente la parte infiltrante) [3]. Los gliomas pueden mostrar características mixtas; por ejemplo, demostrando características tanto de bajo como de alto grado. El estándar de referencia para caracterizar las neoplasias cerebrales se basa actualmente en el análisis histopatológico después de una biopsia o resección quirúrgica, pero esto también tiene limitaciones, como el error de muestreo y la variabilidad en la interpretación. [2][4]

En este artículo, se muestra la aplicación de una metodología basada en redes convolucionales como apoyo al diagnóstico clínico de este tipo tumor cerebral.

METODOLOGÍA

Dataset

El conjunto de muestras utilizado para el estudio pertenece a una base de datos pública [5] que contiene 481.158 imágenes con subdivisiones de distintas pruebas por cada paciente. Las imágenes seleccionadas son las obtenidas a partir de RM, aunque dentro del repositorio también hay imágenes de pruebas por tomografía computarizada (CT) y radiografía digital (DX).




Figura 1. Imagen RM con tumor glial.

De todas las imágenes en el dataset se clasificaron de forma manual en bruto 509 imágenes con tumor glial y 507 imágenes sin tumor glial.

Convolutional Neural Networks (CNN)

En una primera fase de la investigación se comenzó por implementar una red neuronal convolucional para una clasificación binaria con las etiquetas con y sin tumor. En este tipo de arquitectura se emplean modelización de redes neuronales artificiales donde las neuronas corresponden a campos receptivos similares a las neuronas en la corteza visual de un cerebro humano. Estas redes son muy efectivas para tareas de:

- Detección y categorización de objetos
- Clasificación y segmentación de imágenes

El objetivo de las CNN es aprender características de orden superior utilizando la operación de convolución. Puesto que las redes neuronales convolucionales aprenden relaciones de entrada-salida (donde la entrada es una imagen), en la convolución, cada píxel de salida es una combinación lineal de los píxeles de entrada. [6]

Spatial Pyramid Pooling Networks

Durante el proceso de reconocimiento tumoral, los resultados tras utilizar CNNs, únicamente no obtuvieron la precisión esperada. Por lo tanto, se hizo uso de la implementación de una capa que funcionaba a partir de una búsqueda de mapa de características, debido a que la diferencia entre los píxeles de tejido sano y tejido enfermo era prácticamente nula respecto a la intensidad. Por lo que se formuló la hipótesis de clasificación sobre la búsqueda de las zonas con condensación de píxeles enfermos con intensidad parecida.




Figura 2. Esquema Spatial Pyramid Pooling.

SPP-net, puede generar una representación de longitud fija independientemente del tamaño / escala de la imagen. La agrupación de pirámides también es robusta para deformaciones de objetos. El poder de SPP-net también es significativo en la detección de objetos. Usando SPP-net, calculamos los mapas de características de toda la imagen solo una vez, y luego agrupamos las características en regiones arbitrarias para generar representaciones de longitud fija para entrenar a los detectores. [7]

Método de segmentación de imágenes basado en el método Fuzzy c-means

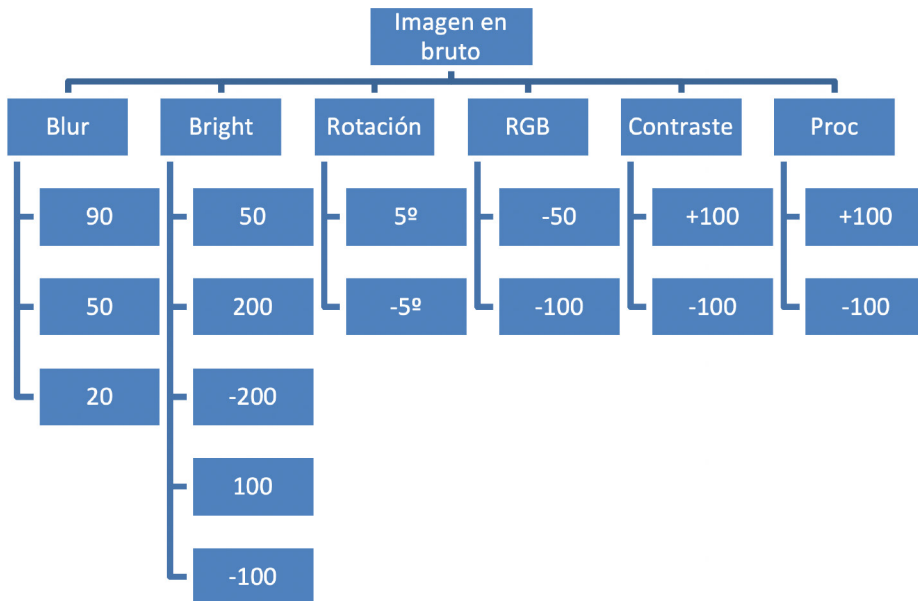
Los métodos de segmentación pueden resultar muy útiles en imágenes donde la zona de interés no tiene mucha diferenciación con otras. La detección asistida por computadora del crecimiento anormal de tejidos está motivada principalmente por la necesidad de lograr la máxima precisión posible. La segmentación manual de estos tejidos anormales no se puede comparar con las máquinas de computación de alta velocidad de hoy en día que nos permiten observar visualmente el volumen y la ubicación de los tejidos no deseados.

La agrupación de datos es un método por el cual grandes conjuntos de datos se agrupan en agrupaciones de conjuntos más pequeños de datos similares. El algoritmo de agrupamiento Fuzzy c-means (FCM) es una de las técnicas de agrupamiento sin supervisión más utilizadas en el campo de la imagen médica. La segmentación de imágenes médicas se refiere a la segmentación de estructuras anatómicas conocidas a partir de imágenes médicas. Fuzzy C-means (FCM) es un método de agrupación en clúster que permite que una parte de los datos pertenezca a dos o más agrupaciones. La lógica difusa es una lógica de múltiples valores derivada de la teoría de conjuntos difusos. FCM se usa popularmente para segmentaciones suaves como el modelo de tejido cerebral. Y también FCM puede proporcionar mejores resultados que otros algoritmos de agrupamiento en clústeres como KM, EM y KNN. [8]


RESULTADOS Y DISCUSIÓN

Operaciones sobre el Dataset

Partiendo de las 1000 imágenes aproximadamente seleccionadas y etiquetadas de forma manual se hizo un aumento de la base de datos mediante técnicas de data augmentation para tener mayor cantidad de casos de aprendizaje. Entre los que cuentan los siguientes filtros:



Además, se hicieron conjuntos de datos resultantes de aplicar varios filtros sobre la misma imagen y se redimensionaron las imágenes a 256x256 píxeles.



Fruto de aplicar los filtros, se obtuvieron un total de 46.878 imágenes de entrenamiento y 7.030 imágenes de prueba.

Con el método de segmentación Fuzzy Cmeans se obtuvieron imágenes donde claramente se diferencia en zonas enfermas de las sanas, en este caso tras hacer uso de prueba y error sobre el número de clusters necesarios según el grado de diferenciación de los tejidos elegido fue de cinco clusters debido a la diferenciación de los tejidos que nos interesaban.




Figura 3. Imagen segmentada Fuzzy c means cinco clústers.

Operaciones sobre la red neuronal

Para la aplicación de la red neuronal convolucional se hizo uso de la red básica Lenet-5, que es una red convolucional pionera de 7 niveles propuesta por LeCun *et al.* Fue diseñada para clasificar los dígitos, para reconocer números escritos a mano en cheques (cheques) digitalizados en imágenes de escala de grises de 32x32 píxeles. La capacidad de procesar imágenes de mayor resolución requiere capas más grandes y más convolucionales, por lo que esta técnica está limitada por la disponibilidad de recursos informáticos. [9]




Figura 4. Red Lenet-5.

A la red se le añadió la capa de SPP para intentar conseguir una mejora en la captura de características en los resultados.

Los resultados aquí representados son con las imágenes sin segmentar, en primer lugar, tras aplicar la red Lenet-5 sobre las imágenes se obtuvo un accuracy del 52%. En el segundo caso, en el que se aplicó la capa de SPP se mejoró consiguiendo un 60%.

CONCLUSIONES

Tras emplear una red simple y posteriormente añadir una capa de Spatial Pyramid Pooling, se consiguió mejorar los resultados en la detección de cáncer en la glía. Sin embargo, los resultados son mejorables. Para ello, como propuesta de estudios futuros se propone el uso del método de segmentación Fuzzy Cmeans y de redes más complejas añadiendo la capa SPP. En base a los datos actuales, el accuracy obtenido por médicos expertos en glioblastomas, ronda en torno a un 63-66% cuando el diagnóstico no se apoya en otro tipo de pruebas como, por ejemplo, el análisis de tejidos [10]. Por lo tanto, el nivel de acierto del sistema propuesto, no supera al de una persona, pero se acerca a los resultados. Como mejoras para el futuro, se propone aplicar el algoritmo de segmentación aquí expuesto.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Suganya, R. y Shanthi, R. (2012). Fuzzy C-Means Algorithm-A Review. *International Journal of Science and Research*, 2. Recuperado de: www.ijsrp.org (accessed December 5, 2018).
- [2] Aronen, H.J., Gazit, I. E., Louis, D. N., Buchbinder, B.R., Pardo, F. S., Weisskoff, R.M., ... Hochberg, F.H. (1994). Cerebral blood volume maps of gliomas: comparison with tumor grade and histologic findings. *Radiology*, 191, pp. 41–51. doi: <https://doi.org/10.1148/radiology.191.1.8134596>
- [3] Krabbe, K., Gideon, P., Wagn, P., Hansen, U., Thomsen, C., y Madsen, F. (1997). MR diffusion imaging of human intracranial tumours, *Neuroradiology*, 39, pp. 483–489. doi: <https://doi.org/10.1007/s002340050450>
- [4] De Wolde, H., Pruijm, J., Mastik, M.F., Koudstaal, J., y Molenaar, W.M. (1997). Proliferative Activity in Human Brain Tumors: Comparison of Histopathology and L-[I-¹¹C]TyrosinePET. doi: <https://doi.org/10.1.1.132.5805&rep=rep1&type=pdf> (accessed December 5, 2018).
- [5] The Cancer Imaging Archive (TCIA) - A growing archive of medical images of cancer, (n.d.). Recuperado de: <http://www.cancerimagingarchive.net/> (accessed December 10, 2018).
- [6] Deep learning & Convolutional Neuronal Network: qué es y en qué consiste, (n.d.). Recuperado de: <https://www.itelligent.es/es/deep-learning-convolutional-neuronal-network-cnn-consiste/> (accessed December 10, 2018).

- [7] He, K., Zhang, X., Ren, S., y Sun, J. (n.d.). Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. Recuperado de: <http://research.microsoft.com/en-us/um/people/kahe/> (accessed December 5, 2018).
- [8] Christ, M.C.J. y Parvathi, R.M.S. (2011). Fuzzy c-means algorithm for medical image segmentation. En: 2011 International Conference on Electronics Computer Technology, IEEE, pp. 33–36. doi: <https://doi.org/10.1109/ICECTECH.2011.5941851>
- [9] CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more. Recuperado de: <https://medium.com/@sidereal/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5> (accessed December 11, 2018).
- [10] Un robot vence a 15 médicos en el diagnóstico de tumores cerebrales. Recuperado de: <https://www.redaccionmedica.com/secciones/tecnologia/un-robot-vence-a-15-medicos-en-el-diagnostico-de-tumores-cerebrales-6435> (accessed December 15, 2018).