

CLASIFICACIÓN DE TUMORES EN CÁNCER DE MAMA BASADO EN REDES NEURONALES DE CONVOLUCIÓN

Durán-López, Lourdes*; **Domínguez-Morales, Juan P**; **Luna-Perejón, Francisco**;
Amaya-Rodríguez, Isabel; **Civit-Masot, Javier**; **Vicente-Díaz, Saturnino**; **Linares-Barranco, Alejandro**

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

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

RESUMEN

El cáncer de mama es una de las causas más frecuentes de mortalidad en las mujeres. Con la llegada de los sistemas inteligentes, la detección automática de tumores en mamografías se ha convertido en un gran reto y puede jugar un papel crucial para mejorar el diagnóstico médico. En este trabajo, se propone un sistema de diagnóstico asistido por ordenador basado en técnicas de Deep Learning, específicamente en redes neuronales de convolución (CNN). El sistema está dividido en dos partes: en primer lugar, se realiza un preprocesamiento sobre las mamografías extraídas de una base de datos pública; posteriormente, las CNNs extraen características de las imágenes preprocesadas para finalmente clasificarlas en función de los dos tipos de tumores existentes: benignos y malignos. Los resultados de este estudio muestran que el sistema tiene una precisión del 80% en clasificación de tumores.

PALABRAS CLAVE

Cáncer de mama, Mamografía, Deep Learning, Redes neuronales de convolución.

ABSTRACT

Breast cancer is one of the most frequent causes of mortality in women. With the arrival of the artificial intelligent, the automatic detection of tumors in mammograms has become a big challenge and can play a crucial role in improving medical diagnosis. In this work, a computer-aided diagnosis system based on Deep Learning techniques, specifically in Convolutional Neural Networks (CNN), is proposed. The system is divided into two parts: first, a preprocessing is performed on mammograms taken from a public database; then, the CNN extracts features of the preprocessed images to finally classify them accordingly to the type of tissue. The results of this study show that the system has an accuracy of 80% in the classification.

KEYWORDS

Breast cancer, Mammography, Deep Learning, Convolutional Neural Network (CNN).

INTRODUCCIÓN Y OBJETIVOS

El cáncer de mama es una de las causas más frecuentes de mortalidad en las mujeres [1]. Se origina cuando se produce una multiplicación anormal de células en el tejido mamario.

Actualmente, la mamografía es el método más eficaz para la detección de esta enfermedad. Sin embargo, el diagnóstico por un experto de este tipo de técnica no es siempre efectivo debido a razones incluyendo factores relacionados con el propio experto, como descuido o fatiga ocular, y factores externos, como la calidad de la imagen mamográfica [2]. Un diagnóstico computarizado (CAD) puede proporcionar una segunda opinión reproducible para un radiólogo, que puede reducir los diagnósticos falsos negativos, mejorando así la calidad de vida de los afectados.

Existen varios tipos de anomalías en mamografías. Los tumores y las microcalcificaciones son los principales indicadores de malignidad en las mamografías. Los tumores se atribuyen a cualquier lesión o protuberancia en la mama, pudiendo ser benignas o malignas; mientras que las microcalcificaciones son zonas donde se acumula una gran cantidad de calcio. En este trabajo, estudiaremos un sistema de diagnóstico computarizado para la clasificación de regiones de interés, en este caso de los dos tipos de tumores y tejido sano, aplicando algoritmos de Deep Learning como son las redes neuronales de convolución (del inglés *Convolutional Neural Network*, CNN).

METODOLOGÍA

Base de datos

Las mamografías se obtuvieron de la base de datos pública llamada Digital Database for Screening Mammography (DDSM). La DDSM [3][4] contiene 2.620 mamografías escaneadas. Incluye casos sanos, benignos y malignos con información patológica verificada (Figura 1).




Figura 1. Mamografías extraídas de la DDSM. De izquierda a derecha: mama sin evidencia de anomalía, mama con presencia de tumor maligno y mama con tumor benigno. En rojo: localización del tumor en la imagen.

Estas mamografías se procesaron para obtener el conjunto de datos de entrenamiento (Figura 2). En primer lugar, se extrajeron los tres tipos de regiones de interés (ROIs) de este estudio: tumores benignos, malignos y tejido sano. Debido a que cada tumor tiene un tamaño particular, las imágenes de las ROIs se redimensionaron a 100x100 píxeles con el fin de que tuvieran el mismo tamaño.

Puesto que los algoritmos de Deep Learning requieren una gran cantidad de datos para un entrenamiento adecuado, se utilizó una técnica para aumentar el número de datos de entrenamiento. Este método es un proceso que genera nuevos datos a partir de los originales utilizando diferentes técnicas de transformación [5,6]. Así, aumentamos 9 veces nuestro conjunto de datos de partida al aplicar los siguientes tipos de transformaciones: tres rotaciones con ángulos de 90º, 180º y 270º, modificaciones de brillo y cambios de enfoque, dando lugar a un conjunto de datos de 80.500 imágenes.

Todas las imágenes obtenidas tras realizar el aumento de datos se mezclaron al azar para evitar cualquier sesgo de clasificación.




Figura 2. Esquema del procesamiento de las mamografías. A: mamografía de partida. B: proceso de extracción de la ROI. C: redimensionado. D: técnica de aumento del conjunto de datos.

Red Neuronal de Convolución

La red neuronal de convolución consiste en un conjunto de capas, que, en primer lugar, extraen características de una imagen, y, posteriormente, realizan su clasificación en base a las características extraídas.

I. Arquitectura de la red

La organización de cada una de las capas de la red neuronal constituye la arquitectura de la red. Existen arquitecturas ya definidas, como la AlexNet [7], la cual consta de 15 capas (Figura 3) entre las que figuran:

- **Convoluciones:** conjunto de filtros que se ajustan para la extracción de características de una imagen.
- **LRN (Local Response Normalization):** su función está inspirada en el concepto biológico de inhibición lateral en el cual una neurona se activa con respecto a sus vecinas, permitiendo un aumento en la percepción sensorial, es decir, detecta altas frecuencias en las características de la imagen.
- **Pool:** se encargan de extraer información más profunda, después de recibir las características convolucionales. Realizan un barrido de la imagen de entrada, definido por una ventana de $M \times N$.

- **FC (Fully Connected):** las neuronas en una capa FC tienen conexiones con todas las activaciones en la capa anterior, como se ve en las redes neuronales artificiales no convolucionales, para crear así un modelo.
- **Softmax:** es la capa de salida de la red neuronal, cuyo objetivo es asignar probabilidades decimales a cada clase.




Figura 3. Arquitectura de AlexNet.

En este estudio, aplicamos esta arquitectura como red para clasificar los tres tipos de regiones de interés del estudio.

II. Entrenamiento y testeo

Para entrenar la red, se utilizó el 75% del conjunto total de los datos. Para testar la red una vez ya entrenada y ver su capacidad de clasificación se usó el 15% restante.

RESULTADOS Y DISCUSIÓN

Tras entrenar la AlexNet, se obtuvo un 80% de acierto (accuracy) en clasificación de las imágenes del conjunto de test. En la Tabla 1 se resumen los resultados.

Tabla 1. Resumen de resultados.

	Accuracy			Total
	Tejido sano	Tumor benigno	Tumor maligno	
AlexNet	98%	70%	71%	80%

Los resultados obtenidos muestran que la red es capaz de clasificar con un 98% de acierto las imágenes de tejido sano, mientras que para diferenciar los dos tipos de tumores gira en torno al 70% de acierto. Esto demuestra que es mucho más eficaz distinguiendo de forma binaria entre tejido sano y anómalo.

Se llevó a cabo un estudio comparativo con otras arquitecturas conocidas, como la LeNet [8] (Figura 4).




Figura 4. Arquitectura de LeNet.

Como se puede observar en la Tabla 2, AlexNet es capaz de obtener mejores resultados en cuanto a la clasificación comparando con LeNet, la cual alcanza un 69% de acierto. Es importante mencionar que la primera, AlexNet, está formada por un mayor número de capas de convolución, dando lugar a una estructura mucho más compleja que la que posee LeNet. Esto da lugar a que la red sea capaz de extraer no sólo más características, sino también más complejas y variadas, permitiendo que el clasificador distinga con mayor certeza las distintas clases que se han estudiado para esta aplicación.

Tabla 2. Comparativa de resultados obtenidos.

	Accuracy			Total
	Tejido sano	Tumor benigno	Tumor maligno	
AlexNet	98%	70%	71%	80%
LeNet	90%	59%	60%	69%

CONCLUSIONES

En este trabajo, se ha estudiado la aplicación de algoritmos de Deep Learning para la clasificación de tumores y tejido sano en mamografías. En particular, se ha aplicado una red neuronal de convolución llamada AlexNet, con la cual se ha llegado al 80% de acierto de clasificación para las tres regiones de interés. El sistema ha demostrado tener una gran capacidad de diferenciación entre tejido sano y tumor, con un 98% de

Durán-López, L.; Domínguez-Morales, J. P.; Luna-Perejón, F.; Amaya-Rodríguez, I.; Civit-Masot, J.; Vicente-Díaz, S.; Linares-Barranco, A.

acierto, aunque la clasificación entre los dos tipos de tumores es mejorable. Para la mejora de este sistema, estamos actualmente estudiando la aplicación de otras redes más complejas que se adapten mejor al problema.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R. L., Torre, L. A., y Jemal, A. (2018). Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*.
- [2] Singh, H., Sethi, S., Raber, M., y Petersen, L. A. (2007). Errors in cancer diagnosis: current understanding and future directions. *Journal of clinical oncology*, 25(31), 5009-5018.
- [3] Heath, M., Bowyer, K., Kopans, D., Moore, R., y Kegelmeyer, W. P. (2000). The digital database for screening mammography. En *Proceedings of the 5th international workshop on digital mammography*, pp. 212-218. Medical Physics Publishing.
- [4] Heath, M., Bowyer, K., Kopans, D., Kegelmeyer, P., Moore, R., Chang, K., y Munishkumar, S. (1998). Current status of the digital database for screening mammography. *Digital mammography*, pp. 457-460.
- [5] Jiao, Z., Gao, X., Wang, Y., y Li, J. (2016). A deep feature based framework for breast masses classification. *Neurocomputing*, 197, 221-231.
- [6] Kooi, T., Litjens, G., van Ginneken, B., Gubern-Mérida, A., Sánchez, C. I., Mann, R., ... Karssemeijer, N. (2017). Large scale deep learning for computer aided detection of mammographic lesions. *Medical image analysis*, 35, 303-312.
- [7] Krizhevsky, A., Sutskever, I., y Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, pp. 1097-1105.
- [8] LeCun, Y., Bottou, L., Bengio, Y., y Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp. 2278-2324.