

Clasificación de microcalcificaciones mediante la red neuronal Inception V3

Classification of microcalcifications usign the Inception V3 neural network

RODRIGUEZ-RAMIREZ, Rodrigo† & SÁNCHEZ, María Guadalupe*

Instituto Tecnológico de Cd. Guzmán / Tecnológico Nacional de México, Departamenteo de Sistemas y Computación, México

ID 1^{er} Autor: *Rodrigo, Rodriguez-Ramirez* / ORC ID: 0000-0001-8347-8795, Researcher ID Thomson: I-5904-2018, CVU CONACYT ID: 842738

ID 1^{er} Coautor: *María Guadalupe, Sánchez* / ORC ID: 0000-0002-5517-9816, CVU CONACYT ID: 544127, SNI-CONACYT ID: 64957

Recibido Marzo 30, 2018; Aceptado Junio 30, 2018

Resumen

El cáncer de mama es el cáncer más común entre las mujeres en todo el mundo, es la segunda causa principal de muerte en América, donde se estima que 2.8 millones de personas son diagnosticadas con esta enfermedad y 1.3 millones mueren cada año. La mejor manera de prevenirlo es su detección temprana. Una mamografía puede arrojar datos útiles para conocer si la persona tiene o no indicios de cáncer. Existen muchos avances en la Inteligencia Artificial, específicamente en el área de reconocimiento de imágenes y en problemas de clasificación. El objetivo principal de este artículo es clasificar las imágenes mamográficas con y sin microcalcificaciones, mediante el uso de la red neuronal convolucional Inception V3, con la finalidad de apoyar al médico a dar un diagnóstico fiable de esta patología. Para las pruebas se utilizaron imágenes mamográficas de la base de datos MIAS. Se entrenó la red neuronal con imágenes originales y con imágenes pre-procesadas. Los resultados muestran mejores aproximaciones en la clasificación cuando se pre-procesa la imagen aplicando las operaciones morfológicas con una exactitud del 80%.

Cáncer de mama, Microcalcificaciones, Redes neuronales

Abstract

Breast cancer is the most common cancer among women worldwide; it is the second leading cause of death in America. It is estimated that 2.8 million people are diagnosed with this disease, and 1.3 million dies from cancer each year. The best way to prevent it is its an early detection. A mammogram can yield useful data to know if the person has or not signs of cancer. There are many advances in Artificial Intelligence, specifically in the area of image recognition and classification problems. The main aim of this article is to classify mammographic images with and without microcalcifications, through the use of Inception V3 convolutional neural network, with the goal of supporting the doctor to a reliable diagnosis of this pathology. Mammographic images are used from MIAS database. The neural network was trained with original and pre-processed images. The results show better approximations in the classification when the image is pre-processed using morphological operations with a accuracy of 80%.

Breast cancer, Microcalcifications, Neural networks

Citación: RODRIGUEZ-RAMIREZ, Rodrigo & SÁNCHEZ, María Guadalupe. Clasificación de microcalcificaciones mediante la red neuronal Inception V3. Revista de Cómputo Aplicado. 2018, 2-6: 20-26.

* Correspondencia al Autor (Correo Electrónico: msanchez@itcg.edu.mx)

† Investigador contribuyendo como primer autor.

Introducción

El cáncer de mama es el cáncer más común entre las mujeres en todo el mundo, sobre todo en países en desarrollo. Según la Organización Mundial de la Salud (OMS) se estima que el cáncer es la segunda causa principal de muerte en América, donde 2,8 millones de personas son diagnosticadas cada año y 1,3 millones mueren por esta enfermedad. Aproximadamente el 52% de los nuevos casos de cáncer y el 35% de las muertes por esta enfermedad ocurren en personas de 65 años o menos. La incidencia es 25 por cada 100,000 personas, de los cuales el 99% de los casos son mujeres. En ausencia de una efectiva prevención, el diagnóstico precoz es un importante medio para reducir la mortalidad. Se estima que la tasa de mortalidad con esta enfermedad va del 10 % en el primer año al 80% en 5 años, una vez realizado el diagnóstico (Gordo, JM Alonso, 2000).

La mamografía es una de las herramientas principales a la hora de hacer un examen detallado de las mamas. Es un procedimiento indoloro y lo único que se requiere es tomar como mínimo dos imágenes por mama, y dependiendo de los resultados el especialista pedirá más mamografías en algún tiempo determinado. Estas imágenes brindan un gran panorama a la hora de detectar el cáncer de mama en etapas tempranas del desarrollo. Al llevarse a cabo estos estudios se puede observar en las imágenes microcalcificaciones y masas.

Las microcalcificaciones son pequeños depósitos de minerales que aparecen como puntos blancos en las mamografías y las masas son visualmente caracterizados por medio de regiones blancas y grises en el área del pecho de la mamografía (Breastcancer, 2018). Detectar depósitos de calcio (microcalcificaciones) es una buena opción para el tratamiento temprano de cáncer, debido a que sólo 55% de los cánceres de mama no palpables presentan microcalcificaciones visibles (Arancibia, P, et al., 2013). Gracias al avance de la tecnología es posible desarrollar poderosas herramientas para la manipulación de las imágenes, permitiendo mostrar información que normalmente no es visible. Una de las herramientas muy utilizadas son las redes neuronales, las cuales se usan para muchas aplicaciones, entre las que se encuentran, aplicaciones de clasificación, procesamiento de la información, demostración de teoremas, entre otras.

En (Guerra, Aníbal & Rivas, Joel, 2011) se describe el desarrollo de un software para la detección de microcalcificaciones, através del estudio de imágenes mamográficas. El software trabaja a partir de una mamografía digitalizada, la cual es procesada para ingresarla como dato de entrada a una Red Neuronal Artificial (RNA) del tipo perceptrón multicapa; ésta se encarga de detectar si la imagen presenta o no microcalcificaciones. La efectividad alcanzada fue de un 94.4% de aciertos en su predicción.

Martínez Rodríguez, F. C., (2016) presenta una serie de pasos para detectar el cáncer de mama mediante una mamografía digital. Estos pasos incluyen el tratamiento digital de imágenes, segmentación, extracción de características y clasificación. Se utilizó la base de datos MIAS. El autor muestra un porcentaje de 85% de exactitud en la clasificación.

En (Bhowmick, B. et al., 2006), proponen un sistema para la detección de microcalcificaciones en mamografías digitalizadas. Los experimentos se llevan a cabo con la base de datos MIAS. Usan 87 características por cada píxel seleccionado y con ellas se entrena un Perceptrón Multicapa (MLP, por sus siglas en inglés). El sistema es capaz de clasificar una imagen como normal o anormal, y también señalar la zona sospechosa con microcalcificaciones en imágenes anormales.

En (Pratiwi, M., et al., 2015), hacen uso de redes neuronales de base radial (RBFNN, por sus siglas en inglés) para clasificar las mamografías en normales, anormales, benignas y malignas. Para la extracción de características se basan en las matrices de co-ocurrencia de los niveles de grises. Se utilizan las imágenes de la base de datos MIAS. Ellos demuestran que el uso de RBFNN es mejor que las redes neuronales back-propagation (BPNN), teniendo una exactitud de 93.89%, 14% más que las BPNN para la clasificación de las imágenes en normal y anormal. Mientras que el promedio de benigno y maligno es de 94.29%, 2% más que las BPNN. Para realizar este proceso ellos lo llevan a cabo en tres etapas: el procesamiento, extracción de características y la clasificación.

A diferencia de las anteriores investigaciones, en el presente trabajo se utilizó la red neuronal convolucional Inception-V3 para la clasificación de las imágenes, debido a su alto rendimiento en la clasificación.

El objetivo de este trabajo fue realizar una clasificación de las imágenes mamográficas que contienen o no microcalcificaciones, por medio del uso y entrenamiento de la red neuronal convolucional Inception V3, con la finalidad de apoyar al médico a dar un diagnóstico fiable de esta anomalía.

La clasificación en el presente trabajo se lleva a cabo a través de las etapas de: segmentación, pre-procesamiento, entrenamiento de la red neuronal y clasificación.

Redes Neuronales

Las Redes Neuronales Artificiales o RNAs, son pequeñas “máquinas” que tratan de emular ciertas características del cerebro humano, tales como: clasificación, asignación, detección, reconocimiento y predicción, entre otras. Se basan en el funcionamiento biológico de las neuronas del cerebro (Sánchez, E. & Alanís, A., 2006). Existen diferentes tipos de redes neuronales, entre los que se encuentran las convolucionales, el perceptrón de capas múltiples, autoencoder, jerárquica, entre otras (Li, F. & Jhonson, J. & Karpathy, A., 2015).

Las Redes Neuronales Convolucionales (CNN, por sus siglas en inglés) son parecidas en muchos aspectos a las redes neuronales ordinarias. Cada neurona recibe algunas entradas, realiza un producto escalar y luego aplica una función de activación. Las redes neuronales convolucionales suponen explícitamente que las entradas son imágenes, lo que permite codificar ciertas propiedades en la arquitectura y permite ganar eficiencia y reducir parámetros en la red (Li, F. & Jhonson, J. & Karpathy, A., 2015).

Algunas arquitecturas de CNN son: LeNet-5, AlexNet, Inception y MobileNets (Gèron, A, 2017). Inception su uso es factible en escenarios con procesamiento de datos grandes. En este tipo de red, solo se re-entrena la capa final, encargada de proporcionar los resultados para las clases en las que se clasifican las imágenes.

Procesamiento digital de imágenes

El procesamiento digital de imágenes es un campo de la computación que se encarga de aplicar técnicas a imágenes tales como, rotación, segmentación, extracción de características, realzado de contraste, filtrado, etc., con la finalidad de preparar las imágenes para un posterior procesamiento.

El ruido impulsivo es el tipo de ruido más frecuente en las imágenes digitales, se genera principalmente al momento de la transmisión de las imágenes (Cervantes, M.G.S, 2013). Existen muchos filtros para la eliminación de ruido impulsivo, uno de ellos se basa en el concepto de peer-group y métrica euclídea (Sánchez, M.G, 2014). En este trabajo se utilizó este tipo de filtro.

Entre las operaciones morfológicas más comunes que se aplican en el pre-procesamiento de imágenes se encuentran:

- Binarización
- Ecuilizado del histograma
- Dilatación
- Erosión

La binarización consiste en convertir el valor de los píxeles de una imagen a valores 0 y 1, haciendo que la imagen luzca en colores blanco y negro (Cuevas, E. & Zaldívar, D. & Pérez, M.,2010). El ecualizado del histograma son las distribuciones que describen la frecuencia con la que se presentan los valores de intensidad (píxeles) de la imagen. Ecuilizar el histograma significa, cambiar mediante la utilización de una operación de píxel la imagen de tal forma que muestre un histograma en la mejor medida distribuidos a lo largo de todos los niveles de intensidad (Cuevas, E. & Zaldívar, D. & Pérez, M.,2010).

Las operaciones de dilatación y erosión no pueden ser consideradas inversas, debido a que no es posible reconstruir completamente una imagen erosionada mediante la aplicación sucesiva de dilataciones. Sin embargo, presentan una relación, ya que una dilatación de los píxeles con valor 1 de una imagen puede llevarse a cabo realizando una erosión del fondo o de los píxeles en 0 (Cuevas, E. & Zaldívar, D. & Pérez, M.,2010).

Metodología

La metodología utilizada para el desarrollo del presente proyecto fue la siguiente:

- Segmentación manual
- Pre-procesamiento de las imágenes
- Conexión y entrenamiento con la red neuronal
- Clasificación

La base de datos que se utilizó para los experimentos fueron las imágenes de la Sociedad de Análisis de Imágenes Mamográficas (MIAS, por sus siglas en inglés) (Suckling, J., 2015) que contiene 322 imágenes de mamografías en formato PGM (Portable Graymap Format). Las imágenes tienen una resolución de 1024x1024 píxeles.

Las imágenes de la base de datos se separan en dos conjuntos: de entrenamiento y de pruebas. Se utilizaron 100 imágenes para entrenar la red neuronal (50 pertenecen a mamografías sin microcalcificaciones y 50 con microcalcificaciones) y 10 imágenes para las pruebas. A continuación se explica en que consiste cada una de las fases de la metodología.

Segmentación

El área que ocupa el seno en la mamografía es menor al total del tamaño de la imagen a analizar. Por lo tanto, es necesario seleccionar (reducir) sólo la parte del seno (área de interés), ya que es la zona que se utiliza para entrenar la red neuronal. El tamaño de la imagen una vez que se realizó este proceso fue de 512x180 píxeles en lugar de 1024x1024 píxeles. La imagen reducida se guarda en formato JPG, ya que la red neuronal solo acepta imágenes con formato JPG o PNG.

Pre-procesamiento

Se lleva a cabo una etapa de pre-procesamiento de las imágenes donde se considera la supresión de ruido impulsivo y se aplican algunas operaciones morfológicas con la finalidad de conservar las principales características de forma de los objetos.

Una vez que las mamografías están reducidas al área de interés, se pasan por el filtro de eliminación de ruido impulsivo, con la finalidad de remover el ruido presente en la imagen que pueda perjudicar los resultados finales.

Después de que la imagen está libre de ruido, se lleva a cabo el tratamiento de las imágenes con las operaciones morfológicas, con la finalidad de resaltar las características más relevantes de éstas y así obtener mejores resultados en la clasificación. Estas operaciones son:

- Binarización
- Ecuilibrado del histograma
- Dilatación
- Erosión
- Erosión - Dilatación

Entrenamiento de la red Neuronal

Las imágenes resultantes del pre-procesamiento, son evaluadas en esta etapa. Para llevar a cabo el entrenamiento de la red neuronal, primero se tiene que realizar la conexión a ella, en la que se especifica la ruta de las imágenes con las que se trabajará.

La figura 1 muestra el diagrama de seguimiento del proceso de entrenamiento y clasificación.




Figura 1 Diagrama de seguimiento del proceso de entrenamiento y clasificación de imágenes

Fuente: Elaboración propia

La clase 1 y clase 2 de la figura 1, se refiere a las dos clases de imágenes que vamos a clasificar: con y sin microcalcificaciones. Estas dos clases son las que se introducen a la red neuronal para su entrenamiento.

Clasificación

Para probar la exactitud de la clasificación con la red entrenada, se introducen algunas imágenes de prueba para clasificarlas, arrojando como resultado una probabilidad para cada una de las clases definidas: con microcalcificaciones y sin microcalcificaciones.

Resultados

Las pruebas experimentales se realizaron en una computadora con las siguientes características: CPU Intel Core i7 Octa Core a 3,5 GHz y con 16 GB de capacidad de la memoria RAM. La eliminación del ruido se llevó a cabo en el lenguaje C y con el uso de la biblioteca OpenMP. Se utilizó Python para realizar la conexión, entrenamiento de la red neuronal y la clasificación y Matlab para aplicar las operaciones morfológicas a las imágenes.

En la Figura 2 se muestran dos de las imágenes que se utilizaron en los experimentos, por un lado se encuentra las imágenes originales (Figura 2a y 2c), y por otro lado, las imágenes reducidas al área de interés (Figura 2b y 2d). Algunas de las imágenes resultantes de la etapa de filtrado se muestran en la Figura 3.

La Figura 4 presenta los resultados obtenidos al aplicar las operaciones morfológicas a una de las imágenes utilizadas en las pruebas.




Figura 2 Mamografía, a) Original, b) Reducida, c) Original, d) Reducida

Fuente: <http://peipa.essex.ac.uk/pix/mias/>




Figura 3 Imágenes de mamografías filtradas después de la etapa de pre-procesamiento

Fuente: *Elaboración Propia*




Figura 4 Resultados de las imágenes con operaciones morfológicas: a) Original, b) Binarizada, c) Ecuilizado, d) Dilatación, e) Erosión, f) Erosión-Dilatación

Fuente: *Elaboración Propia*

En la Figura 4b se puede observar la imagen binarizada, la cual es descartada para la etapa de entrenamiento de la red neuronal debido a que no muestran ninguna característica visible que pueda ayudar al buen entrenamiento de la red neuronal. Por el mismo motivo las imágenes con erosión-dilatación (ver Figura 4f) han sido descartadas.

Con la finalidad de verificar que la red neuronal se haya entrenada correctamente para realizar la clasificación de las imágenes que contienen microcalcificación de las que no. Una de las pruebas fue introducir 10 imágenes originales sin ningún tratamiento morfológico y obtener la probabilidad de que contenga microcalcificación o no. La tabla 1 muestra los resultados obtenidos. La nomenclatura utilizada en las tablas posteriores es: CM (Con Microcalcificación) y SM (Sin Microcalcificación).

Imagen	Clase candidata	Probabilidad CM	Probabilidad SM	Clasif. correcta
1	CM	0.61736	0.27622	Si
2	CM	0.76234	0.20123	Si
3	CM	0.61023	0.30012	Si
4	CM	0.70230	0.24323	Si
5	CM	0.69290	0.24978	Si
6	SM	0.72023	0.20989	Si
7	SM	0.26909	0.70232	Si
8	SM	0.34982	0.60025	Si
9	SM	0.29012	0.69989	Si
10	SM	0.31098	0.61034	Si

Tabla 1 Clasificación de las imágenes originales de la base de datos mini-MIAS

Fuente: *Elaboración Propia*

Como puede observarse en la Tabla 1, en todas las imágenes de prueba se realizó una correcta clasificación. Además, se puede observar que la probabilidad de estar clasificado en la clase correcta es el doble de la de no pertenecer a esa clase.

Otras pruebas fueron introducir 10 imágenes para cada tratamiento morfológico: histograma ecualizado, dilatación y erosión. La tabla 2 muestra los resultados de la exactitud de la clasificación utilizando la operación morfológica de erosión. Como puede observarse, para todas las imágenes coincide la clasificación, además solo en un caso probabilidad de clasificación no es muy significativo, sin embargo, se hace la clasificación correcta.

Estos resultados fueron similares en las pruebas con las operaciones morfológicas de histograma ecualizado y dilatación (ver Tabla 3 y 4).

Imagen	Clase candidata	Probabilidad CM	Probabilidad SM	Clasif. correcta
1	CM	0.51092	0.48902	Si
2	CM	0.71023	0.27092	Si
3	CM	0.65792	0.30872	Si
4	CM	0.70234	0.25656	Si
5	CM	0.60979	0.38279	Si
6	CM	0.67802	0.39799	Si
7	SM	0.20893	0.79023	Si
8	SM	0.36098	0.61098	Si
9	SM	0.24837	0.71982	Si
10	SM	0.34823	0.62912	Si

Tabla 2 Clasificación de las imágenes con erosión

Fuente: *Elaboración Propia*

Imagen	Clase candidata	Probabilidad CM	Probabilidad SM	Clasif. correcta
1	CM	0.75673	0.24734	Si
2	CM	0.74234	0.25233	Si
3	CM	0.77435	0.21323	Si
4	CM	0.73123	0.25343	Si
5	CM	0.70912	0.27097	Si
6	SM	0.23892	0.73921	Si
7	SM	0.18900	0.80312	Si
8	SM	0.19072	0.79823	Si
9	SM	0.19907	0.78907	Si
10	SM	0.19232	0.79667	Si

Tabla 3 Clasificación de las imágenes con histograma ecualizado

Fuente: *Elaboración Propia*

Imagen	Clase candidata	Probabilidad CM	Probabilidad SM	Clasif. correcta
1	CM	0.70736	0.23622	Si
2	CM	0.80232	0.18123	Si
3	CM	0.69023	0.20012	Si
4	CM	0.71238	0.24323	Si
5	CM	0.66276	0.20978	Si
6	SM	0.24989	0.73573	Si
7	SM	0.19239	0.69232	Si
8	SM	0.22982	0.65025	Si
9	SM	0.22837	0.70238	Si
10	SM	0.33432	0.64034	Si

Tabla 4 Clasificación de las imágenes con dilatación

Fuente: *Elaboración propia*

Como conclusión de los experimentos se puede decir que los datos de entrenamiento fueron suficientes para una buena clasificación. Para finalizar, se realizó el promedio de las probabilidades de clasificación con y sin microcalcificaciones para cada una de los experimentos realizados, con la finalidad de conocer en cual de las operaciones morfológicas se obtiene mejor la clasificación. La tabla 5 muestra dicho promedio. En esta tabla se puede visualizar que la operación morfológica "Histograma ecualizado" obtuvo los mejores resultados al momento de clasificar las imágenes con un promedio de probabilidad de 0.78526.

Tipo de imagen	Promedio de las probabilidades de coincidencia CM	Promedio de las probabilidades de coincidencia SM
Originales	0.6842	0.6532
Histograma ecualizado	0.742754	0.78526
Dilatación	0.71501	0.684204
Erosión	0.64487	0.6875375

Tabla 5 Promedio de probabilidad de clasificación de microcalcificaciones

Fuente: *Elaboración Propia*

Conclusiones

Para obtener mejores resultados en la clasificación de las microcalcificaciones es necesario aplicar operaciones morfológicas a las mamografías para obtener realces de sus características, lo que permite un mejor entrenamiento y por lo tanto una mejor clasificación de las imágenes. El histograma ecualizado es la operación morfológica con la que se obtuvo mejores resultados, logrando una exactitud del 80%.

Agradecimientos

Agradecemos al CONACYT por la beca Nacional PNP: 626527 y ID SNI: 64957.

Referencias

Arancibia, P., Taub, T., De Grazia, K., José, A., Díaz, C., Lorena, M., ... & Cermenati, T. (2013). Microcalcificaciones mamarias: revisión de los descriptores y categorías BI-RADS. *Revista chilena de obstetricia y ginecología*, 78(5), 383-394.

Bhowmick, B., Pal, N. R., Pal, S., Patel, S. K., & Das, J. (2006, April). Detection of Microcalcification with Neural Networks. *In Engineering of Intelligent Systems, 2006 IEEE International Conference on* (pp. 1-6). IEEE.

Breastcancer.org. (2018). Qué revelan las mamografías. [online] Available at: https://www.breastcancer.org/es/sintomas/analisis/tipos/mamografias/revelan_mamografias [Accessed 27 Sep. 2018].

Cervantes, M. G. S. (2013). *Algoritmos de detección y filtrado de imágenes para arquitecturas multicore y manycore (Doctoral dissertation)*.

Cuevas, E. & Zaldívar, D. & Pérez, M., (2010). *Procesamiento digital de imágenes con Matlab y simulink*. México: RA-MA Editorial.

Géron, A. (2017). *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*. " O'Reilly Media, Inc."

Gordo, JM Alonso, (2000). Cáncer de mama. Manejo desde atención primaria, *SEMERGEN Medicina de Familia*, Elsevier Doyma.

Guerra, A., & Rivas, J. (2011). Detección de microcalcificaciones en imágenes mamográficas usando redes neuronales. *Revista de la Facultad de Ingeniería Universidad Central de Venezuela*, 26(3), 7-14.

Li, F. & Jhonson, J. & Karpathy, A.. (2015). Convolutional Neural Networks for Visual Recognition. 2016, de Stanford Sitio web: <http://cs231n.stanford.edu/>

Martínez Rodríguez, F. C. (2016). Detección automática de anomalías presentes en mamografías digitales.

Pratiwi, M., Harefa, J., & Nanda, S. (2015). Mammograms classification using gray-level co-occurrence matrix and radial basis function neural network. *Procedia Computer Science*, 59, 83-91.

Suckling, J. (2015). The mini-MIAS database of mammograms. Society TMIA, editor. *Digital Mammography Database ver, 1*.

Sánchez, E. & Alanís, A., (2006). *Redes neuronales: conceptos fundamentales y aplicaciones a control automático*. Madrid : Pearson Educación.

Sanchez, M. G., Gimeno, V. E. V., Arnal, J., & Meló, A. V. (2014). Image Noise Removal on Heterogeneous CPU-GPU Configurations.