

# Aplicación de la inteligencia artificial en la clasificación automática de imágenes médicas

Application of artificial intelligence in the automatic classification of medical images

Gustavo Rafael Guzman Loreto<sup>1</sup>, Andrea Zoé Pérez Diosdado<sup>1</sup>, Esther Durán Reyes<sup>2</sup>, Arturo Torres Calderon<sup>1</sup>, Leonardo González Guzman<sup>2</sup>, Haydee Preciado Trujillo<sup>1</sup> y Rafael Guzman Cabrera<sup>2</sup>

<sup>1</sup> CAMPUS LEÓN, DIVISIÓN DE CIENCIAS E INGENIERÍAS

gr.guzmanloreto@ugto.mx, a.torrescalderon@ugto.mx, az.perezdiosdado@ugto.mx, h.preciadotrujillo@ugto.mx

<sup>2</sup> CAMPUS IRAPUATO-SALAMANCA, DIVISIÓN DE INGENIERÍAS

e.duranreyes@ugto.mx, l.gonzalezguzman@ugto.mx, guzmanc@ugto.mx

## Resumen

Durante los últimos 15 años, un número creciente de técnicas referentes a imágenes digitales ha sido introducido en la práctica médica. Uno de los métodos de aprendizaje automático más utilizado en la actualidad son las redes neuronales. La detección temprana del melanoma es esencial para un tratamiento exitoso. Algunos signos de advertencia del melanoma incluyen un cambio en el tamaño, forma o color de un lunar existente, la aparición de un nuevo lunar que parece diferente de los demás, picazón, sangrado o ulceración de una lesión cutánea, y la propagación del pigmento desde el borde de una lesión hacia la piel circundante. En el presente trabajo se presentan resultados de la clasificación de imágenes médicas, específicamente con presencia de cáncer de piel, utilizando aprendizaje automático e inteligencia artificial. Se utilizaron dos bases de datos para llevar a cabo la clasificación de las imágenes, ambas bases de datos contienen imágenes dermatológicas y se encuentran disponibles de manera gratuita en internet, lo cual facilita la comparación de resultados entre distintos autores. Para los experimentos se utilizó una red neuronal la cual permite obtener resultados competitivos.

**Palabras clave:** Clasificación Automática de Imágenes, Redes Neuronales, Clasificación de Imágenes Médicas.

## Introducción

El procesamiento de imágenes se define como el conjunto de técnicas y procesos para descubrir o hacer resaltar información contenida en una imagen usando como herramienta principal una computadora. Intentar manipular, almacenar y transmitir las imágenes, data del año 1920, cuando se desarrolló un sistema de transmisión de fotografías a través de un cable transatlántico usando códigos telegráficos. Este sistema podía permitir una baja codificación de 5 niveles en gris, pero más adelante en 1929 fue mejorado, para así poder codificar 15 niveles de gris [1]. Pocos son los aspectos de nuestra vida actual que no han sido "afectados" por las computadoras. Cada transacción monetaria que se lleva a cabo diariamente en diferentes establecimientos tiene que ver con una computadora. En muchos casos, lo mismo sucede con las imágenes por computadora [2]. Por ejemplo, éstas aparecen en televisión, en los periódicos, en los reportes del tiempo, o en un consultorio médico. Las imágenes por computadora están siempre alrededor de nosotros. Las principales aplicaciones del procesamiento de imágenes son las siguientes:

- Restauración y reconstrucción. El problema está; específicamente en la recuperación de la información codificada en una imagen, esta recuperación de la información está relacionada claramente con el proceso inverso de la convolución: la deconvolución. El método más común (aunque no el único) para llevar a cabo el proceso de deconvolución es el método de deconvolución por mínimos cuadrados o filtrado de Wiener [3].
- Cartografía automatizada y sistemas de información geográfica (SIG). son dos áreas que se han beneficiado enormemente por la utilización del procesamiento digital de imágenes (PDI). La aplicación del PDI en la cartografía automatizada concierne principalmente a las imágenes que de la Tierra se obtienen por diferentes medios. Por ejemplo, es conocido que los satélites envían imágenes de la Tierra. Cuando estas imágenes son procesadas producen información muy clara y precisa de nuestro planeta. De esta forma, al analizar e interpretar estas imágenes los geólogos,

cartógrafos y científicos aprenden cada vez más acerca de nuestro planeta. En estas imágenes no sólo se captura la luz visible sino también gran parte del espectro electromagnético, lo que le da a estos científicos la capacidad de analizar el espectro infrarrojo para determinar el tipo y la cantidad de plantas y árboles en la porción de terreno capturado en la imagen [4].

- Reconocimiento. El reconocimiento de patrones en el PDI se refiere al procesamiento de la imagen resultante del proceso de deconvolución. En esta imagen se manipulan los niveles de gris para mejorar la lectura de esta e identificar propiedades que pudiesen tener algún significado físico. La manipulación de los niveles de gris se lleva a cabo a través de tres subprocesos: resaltamiento de la imagen, reducción de ruido, segmentación y detección de bordes. Existe una gran cantidad de técnicas para resaltar imágenes que en mucho se basan en la calidad de los resultados que se quieran obtener o resaltar [5]. En esta área los campos de estudio son la aerodinámica, la dinámica de fluidos, la modelación molecular, y otras. Por ejemplo, la modelación de los cientos de reacciones en el movimiento de un fluido se puede llevar a través de computadoras que crean imágenes y animaciones sobre un área específica de interés. Sistemas similares se aplican a la predicción del clima. Los sistemas de nubes y tormentas se pueden modelar a través de simulaciones realistas. Aunque muchos de los programas de visualización en las ciencias manipulan datos en tres dimensiones, la salida final se puede reflejar normalmente en una imagen de dos dimensiones. Esta imagen se puede manipular para extraer la información requerida.

Durante los últimos 15 años, un número creciente de técnicas referentes a imágenes digitales ha sido introducido en la práctica médica. Muchos radiólogos y personal de laboratorios médicos conocen y manipulan imágenes digitales como las producidas por Tomografía Asistida por Computadora, resonancia magnética y por métodos de medicina nuclear [6]. Debido al desarrollo, capacidades y gran factibilidad de ejecución de las computadoras, las imágenes en medicina, que eran tradicionalmente grabadas sobre películas, ahora pueden manipularse en forma digital. De esta forma las imágenes de ultrasonido y las de Rayos X se pueden almacenar directamente en forma digital por medio de placas de fósforo de luminiscencia foto-estimulable [7]. El desarrollo de las técnicas de almacenamiento de imágenes digitales en medicina ha estado acompañado por un incremento en el uso de herramientas de manipulación de imágenes.

Uno de los métodos de aprendizaje automático más utilizado en la actualidad son las redes neuronales. Las redes neuronales artificiales son una rama del aprendizaje automático y la inteligencia artificial que se inspira en el funcionamiento del cerebro humano. Estas redes están diseñadas para mejorar su rendimiento aprendiendo de la experiencia reconociendo patrones complejos en los datos [8].

El concepto de redes neuronales tiene sus raíces en la década de 1940, cuando Warren McCulloch y Walter Pitts publicaron un artículo que describía un modelo matemático de una neurona artificial. Debido a la aparición de otras técnicas de aprendizaje, el interés por las redes decayó durante algunas décadas. En la década de 1980, investigadores como John Hopfield y David Rumelhart revivieron el interés por las redes neuronales con conexiones recurrentes, y se desarrolló el algoritmo de retropropagación, que permitió entrenar redes con múltiples capas ocultas. A fines de la década de 1980 y principios de la de 1990, Frank Rosenblatt presentó el perceptrón, una de las primeras arquitecturas de redes neuronales que podía aprender y reconocer patrones en los datos [9].

Las aplicaciones de las redes neuronales en la clasificación de imágenes médicas han sido revolucionarias para la práctica clínica. Estas redes se han utilizado para una variedad de tareas, entre ellas:

- Detección de Tumores y Lesiones: Las redes neuronales han demostrado ser muy efectivas en la detección temprana de tumores y lesiones en imágenes de resonancia magnética, tomografía computarizada, mamografías y ultrasonidos. Algunos estudios han mostrado que las Redes Neuronales Convolucionales (CNN) pueden superar a los radiólogos expertos en la identificación de ciertas anomalías [10].
- Diagnóstico de Enfermedades: Las redes neuronales han sido entrenadas para diagnosticar enfermedades específicas a partir de imágenes médicas, como el diagnóstico de enfermedades cardíacas, detección de cáncer de piel, identificación de patologías en el cerebro y otras afecciones médicas [11].
- Segmentación de Órganos y Tejidos: Las redes neuronales también se han utilizado para segmentar y delinear estructuras específicas en imágenes médicas, como órganos, vasos sanguíneos y tumores. Esta información es valiosa para la planificación de tratamientos y cirugías [12].

Las Redes Neuronales han experimentado un impresionante desarrollo desde sus inicios, y su aplicación en la clasificación de imágenes médicas ha sido especialmente impactante. El uso de redes neuronales, en particular las CNN, ha mejorado significativamente la precisión y la eficiencia en el diagnóstico médico, lo que

lleva a una atención más oportuna y efectiva para los pacientes. A medida que la tecnología y los métodos de aprendizaje automático continúen avanzando, se espera que las redes neuronales sigan desempeñando un papel crucial en el campo de la medicina y contribuyan a mejorar la salud y el bienestar de las personas. Sin embargo, también es importante abordar los desafíos de interpretabilidad y equidad para garantizar que estas herramientas sean utilizadas de manera responsable y ética en el ámbito médico.

En este trabajo se presenta la clasificación de imágenes médicas utilizando redes neuronales. Las imágenes que se clasifican contienen cáncer de piel. Las bases de datos utilizadas y los resultados obtenidos se describen a continuación.

## Imágenes dermatológicas

Un nevus y un melanoma son dos tipos de lesiones en la piel que pueden tener apariencias similares, pero tienen características e implicaciones en la salud diferentes. Un nevus, también conocido como lunar o marca de nacimiento, es una lesión benigna común que se desarrolla en la piel. Los nevus pueden variar en forma, tamaño y color, y generalmente no representan un riesgo para la salud. La mayoría de los nevus son inofensivos y no requieren tratamiento médico, a menos que haya un cambio en su apariencia o se presente molestia física. Los nevus pueden ser planos o elevados, y pueden ser de color marrón claro, oscuro o negro [13].

El melanoma, por otro lado, es un tipo de cáncer de piel que se desarrolla a partir de las células productoras de pigmento llamadas melanocitos. A diferencia de los nevus, el melanoma es una condición maligna y puede propagarse a otras partes del cuerpo si no se detecta y trata a tiempo. Las causas exactas del melanoma no se conocen completamente, pero la exposición excesiva a la radiación ultravioleta (UV) del sol o camas de bronceado es un factor de riesgo importante [14].

La detección temprana del melanoma es esencial para un tratamiento exitoso. Algunos signos de advertencia del melanoma incluyen un cambio en el tamaño, forma o color de un lunar existente, la aparición de un nuevo lunar que parece diferente de los demás, picazón, sangrado o ulceración de una lesión cutánea, y la propagación del pigmento desde el borde de una lesión hacia la piel circundante.

Para la clasificación de las imágenes médicas se implementó una red neuronal convolucional, cuya estructura se muestra en la figura 1.

```

num_classes = 2
model = Sequential()
model.add(Input((150, 150, 3)))
model.add(Conv2D(16, 3, padding='same', activation='relu'))
model.add(MaxPooling2D())
model.add(Conv2D(32, 3, padding='same', activation='relu'))
model.add(MaxPooling2D())
model.add(Conv2D(64, 3, padding='same', activation='relu'))
model.add(MaxPooling2D())
model.add(Dropout(0.2))
model.add(Flatten())
model.add(Dense(128, activation='relu'))
model.add(Dense(64, activation='relu'))
model.add(Dense(num_classes, activation='softmax'))

model.summary()

```

Figura 1. Estructura de la red neuronal utilizada.

A continuación, se presenta una breve descripción de cada una de las dos bases de datos utilizadas así como los resultados obtenidos para cada una de ellas.

## Resultados PH2

Para el procedimiento se utilizan las bases de datos PH2 (40 malignant, 160 benign) e ISBI 2016 (173 malignant, 727 benign), en ambos casos se utilizó el 80% para entrenamiento y el 20% para pruebas, el único preprocesamiento que se le realiza a las imágenes es la redimensión de las imágenes de su tamaño original a 150x150 píxeles.

En el caso de la data PH2, esta base de datos de imágenes contiene un total de 200 imágenes dermatoscópicas de lesiones melanocíticas, incluyendo 80 nevos comunes y 40 melanomas. La base de datos PH2 incluye anotaciones médicas de todas las imágenes, a saber, segmentación médica de la lesión, diagnóstico clínico e histológico y la evaluación de varios criterios dermatoscópicos (colores; red pigmentaria; puntos/glóbulos; rayas; áreas de regresión; velo azul-blanquecino). Las imágenes dermatoscópicas se obtuvieron en el Servicio de Dermatología del Hospital Pedro Hispano (Matosinhos, Portugal) en las mismas condiciones a través del sistema Tuebinger Mole Analyzer utilizando un aumento de 20x. Son imágenes en color RGB de 8 bits con una resolución de 768x560 píxeles. Esta base de datos se encuentra disponible<sup>1</sup>. Para el entrenamiento se utiliza CNN que consta por una capa input, la cual ingresa las imágenes en el canal RGB con 150x 150 píxeles de tamaño. Esta ejecución se realiza para cada una de las bases de datos implementadas anteriormente y cuyos resultados se visualizan en la figura 2 y 3.

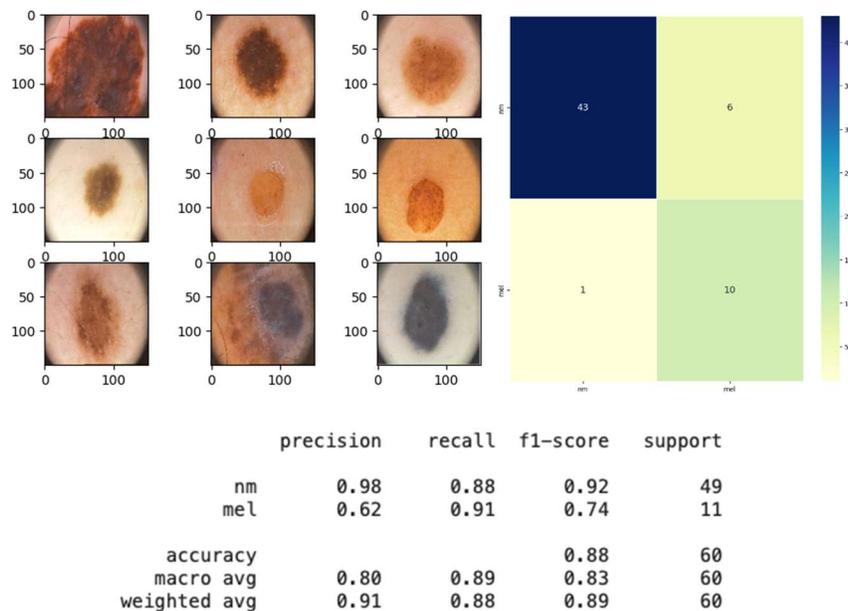


Figura 2. Resultados obtenidos al clasificar las imágenes médicas de la base de datos PH2.

<sup>1</sup> <https://www.fc.up.pt/addi/ph2%20database.html>

En este procedimiento podemos observar como de un grupo de 60 imágenes solo se logran destacar 49 imágenes para verificación del grupo de imágenes no melanoma y 11 para el grupo de imágenes melanomas, teniendo en cuenta el grupo de imágenes ingresados se tiene una precisión de 0.98 y 0.62 respectivamente a los grupos mencionados. De manera general el procedimiento efectuado en la data PH2 presenta un resultado de 0.88 de accuracy para las 60 imágenes utilizadas en la ejecución.

## Resultados ISBI2016

Esta base de datos también se encuentra disponible en internet<sup>2</sup>. Cada imagen fue manualmente etiquetada por expertos: el tono de piel se etiquetó en función de la evaluación en persona en la visita a la clínica, con referencias cruzadas con fotos demográficas y revisión de las imágenes clínicas por dos dermatólogos certificados. Cada diagnóstico se basó en informes de patología de la biopsia, estos informes y la imagen correspondiente fueron revisados por un dermatólogo y dermatopatólogo certificados.

Los grupos de imágenes varían y son mayores al grupo PH2, en este caso se implementan 307 imágenes para no melanomas y 77 imágenes para melanomas alcanzando un resultado igual a 0.83 y 0.42 en las ejecuciones realizadas, en este procedimiento se observa como la distribución de las imágenes analizadas para el grupo melanoma es superior en las falsas positivas evidenciando el resultado de esta muestra, en general la implementación de la arquitectura alcanza un accuracy de 0.78. Los resultados se presentan en la figura 3.

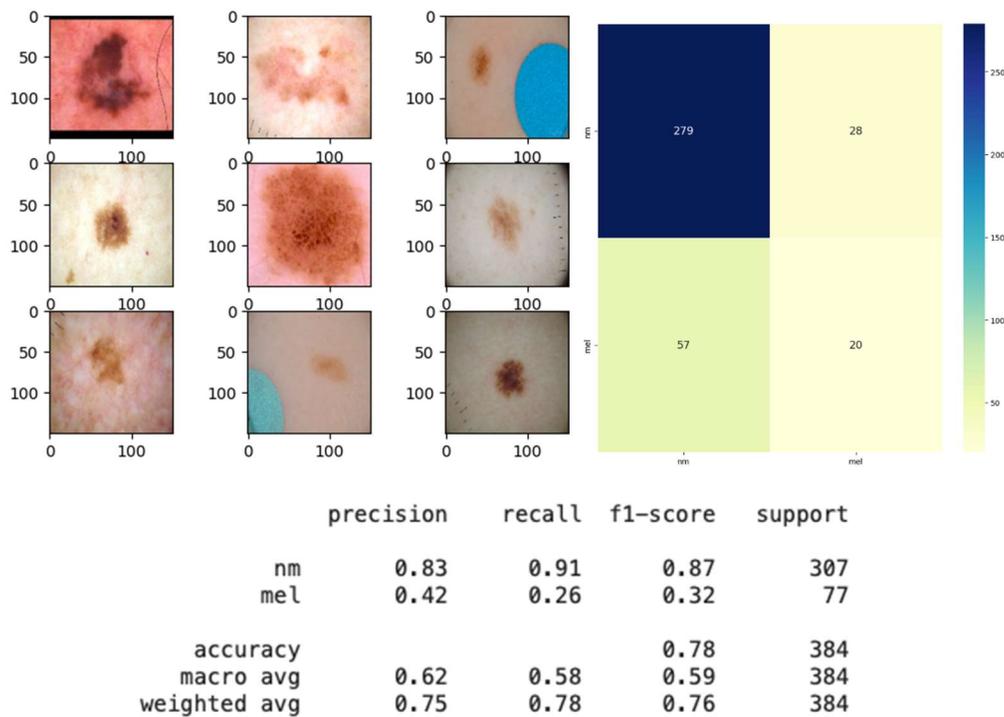


Figura 3. Resultados obtenidos al clasificar las imágenes médicas de la base de datos ISBI2016.

<sup>2</sup> <https://challenge.isic-archive.com/leaderboards/2016/>

## Conclusiones

Durante los últimos 15 años, un número creciente de técnicas referentes a imágenes digitales ha sido introducido en la práctica médica. Uno de los métodos de aprendizaje automático más utilizado en la actualidad son las redes neuronales. En este trabajo se presentan resultados de la clasificación automática de imágenes médicas con presencia de cáncer de piel utilizando una red neuronal. Se utilizaron dos bases de datos para llevar a cabo la clasificación de las imágenes, ambas bases de datos contienen imágenes dermatológicas y se encuentran disponibles de manera gratuita en internet, lo cual facilita la comparación de resultados entre distintos autores. Las bases de datos utilizadas son: PH2 y ISBI2016. El mejor resultado obtenido es un 88 % de precisión, en un escenario en el cual se utilizaron 80% de las imágenes para entrenamiento y 20% para prueba. Estos resultados son relevantes ya que son muy superiores al azar. Una conclusión interesante es que se requieren imágenes de calidad manualmente etiquetadas para lograr que los métodos de aprendizaje automático tengan un mejor desempeño a la hora de llevar a lavabo la clasificación automática de las imágenes médicas. Los resultados obtenidos son muy relevantes ya que permiten llevar a cabo el etiquetado automático de una imagen que no ha sido vista por el conjunto de entrenamiento, permitiendo de esta manera ayudar al especialista de la salud a fortalecer o mejorar su diagnóstico médico.

## Referencias

1. Torres, A.D., *Procesamiento digital de imágenes*. Perfiles Educativos, 1996(72).
2. Buck-Morss, S., *Estudios visuales e imaginación global*. Antípoda. Revista de antropología y arqueología, 2009(9): p. 19-46.
3. Sepúlveda, B.J.E.O., *RESTAURACION DE IMAGENES USANDO TECNICAS DE RECONSTRUCCION DE SENSADO COMPRIMIDO*.
4. Saavedra, N.S., *Los sistemas de información geográfica (SIG) una herramienta poderosa para la toma de decisiones*. Ingeniería e investigación, 1992(28): p. 31-40.
5. Matadamas Ortíz, I.C., *Aplicacion de las redes neuronales pulsantes en el reconocimiento de patrones y analisis de imagenes*. 2013.
6. Pérez-Careta, E., et al., *Clasificación de imágenes médicas mediante aprendizaje automático*. ene, 2022.
7. Alfonso, A.E.S., *Segmentación y procesamiento de imágenes médicas*. REVISTA SAYWA, 2021. **3**(4): p. 13-21.
8. Juan, R.Q. and C.M. Mario, *Redes neuronales artificiales para el procesamiento de imágenes, una revisión de la última década*. RIEE&C, Revista de Ingeniería Eléctrica, Electrónica y Computación, 2011. **9**(1): p. 7-16.
9. Moreno Díaz, R., *De los orígenes y evolución de la teoría de redes neuronales*. 1995.
10. Mondino, C., *Clasificación de tumores en mamografías utilizando redes neuronales convoluciones*. 2021.
11. Delgado, A., *Aplicación de las redes neuronales en medicina*. Revista de la Facultad de Medicina, 1999. **47**(4): p. 221-223.
12. Drozdowicz, B., et al., *Segmentación semiautomática de imágenes de resonancia magnética, basada en redes neuronales artificiales*. Ciencia, Docencia y Tecnología, 2005. **16**(30): p. 117-155.
13. Alarcon Vela, V.M. and D.M. Murga Aguilar, *Algoritmo para el diagnóstico preliminar de melanoma cutáneo basado en redes neuronales, Naive Bayes y árboles de decisión*. 2020.
14. Asmat, R.A.M., *Estudio para determinar melanoma en la piel usando técnicas de minería de datos*. Revista de investigación de sistemas e informática, 2021. **14**(1): p. 19-24.