

Método Computacional para la Clasificación Automática de Nevus Cancerosos

Víctor A. Ayala-Bryant, Carlos A. Blanco-Ornelas, A. Yael Jasso-Aburto, Gerardo Mendizabal-Ruiz*
Depto. de Ciencias Computacionales, Universidad de Guadalajara, Guadalajara, Jalisco, México
*gerardo.mendizabal@academicos.udg.mx

Resumen — Actualmente en el campo de la dermatología, uno de los principales problemas es la detección temprana de cáncer de piel, la cual requiere la identificación a tiempo de los lunares que podrían potencialmente desarrollarse en melanomas. Mediante la utilización de métodos de visión computacional es posible hacer una clasificación de imágenes de lunares para hacer una evaluación temprana del riesgo que uno de ellos representa. En este trabajo se presenta un método computacional basado en redes neuronales computacionales para la clasificación de imágenes de lunares.

Palabras clave— Melanoma, procesamiento de imágenes, red neuronal convolucional, visión computacional.

I. INTRODUCCIÓN

Hoy en día, una de las tareas más importantes para prevenir el desarrollo de cualquier tipo de cáncer en el cuerpo humano es mediante el uso de diferentes técnicas médicas o dispositivos médicos. Los dermatólogos-oncólogos encargados de su manejo y conocimiento previo, aplican las técnicas necesarias para la detección correcta del cáncer. Su trabajo conlleva un alto costo monetario y tiempo para dar un pronóstico fiable al paciente, que en ocasiones puede resultar erróneo y por lo tanto esto podría traer otro tipo de problemas al paciente. Uno de los tipos de cáncer más común es el melanoma. Una de las causas de esta enfermedad es la alta radiación solar que se tiene en diversas partes del mundo. Su desarrollo puede llevar a la muerte si no es detectado en una etapa temprana. En la especialidad de la dermatología existe una serie de pasos para determinar su clasificación maligna o su descarte de ser canceroso.

El ABCD del melanoma incipiente.

La nemotecnia para identificar los siguientes signos clínicos iniciales del melanoma cutáneo: **A**: asimetría; las dos mitades de la lesión son diferentes. **B**: bordes angulados, con muescas o escotaduras geográficas. **C**: colores diferentes: negro, pardo, y especialmente diferentes tonalidades del marrón. **D**: diámetro mayor de 6 mm. Cuando se puede añadir a la lesión la característica **E**, de elevación, ya no es incipiente sino avanzada. Con muy pocas excepciones, los melanomas comienzan por la proliferación de melanocitos en la unión dermoepidérmica.

La lesión, que se va formando con el transcurso del tiempo, incluso durante años, se empieza a detectar cuando

alcanza un diámetro mayor de 3 mm y por convención y experiencia, se identifica o sospecha como melanoma cuando tiene 6 o más mm. de diámetro. El criterio de tamaño es el menos importante porque hay numerosos ejemplos de melanomas metastásicos con tamaños menores de 6 mm. La importancia del **ABCD** está en que describe criterios útiles para identificar la lesión plana, propia del inicio del melanoma, cuando es intraepidérmico, *in situ*, período en el cual es curable mediante la resección. Estos criterios fueron mencionados primero por Ackerman en 1981 y luego se hicieron populares con la nemotecnia descrita aquí. [1]

Las instrucciones anteriores pueden ser realizadas por cualquier persona, por lo tanto, para tener un diagnóstico más preciso y confiable antes de ir con el especialista. Resultaría ventajoso utilizar una aplicación para móviles y la cámara de éste, donde el usuario pueda seleccionar el lunar solamente y después presionar un botón, para obtener la clasificación del lunar como posiblemente maligno o posiblemente benigno.

I.B. Visión Computacional

La visión computacional es una rama de la inteligencia artificial y el procesamiento de imágenes preocupada por el procesamiento computacional de imágenes desde el mundo real. La visión computacional típicamente requiere un bajo nivel de procesamiento de imagen para mejorar la calidad de la imagen (e.g. remover el ruido, aumentar el contraste) y un alto nivel de reconocimiento de patrones y entendimiento de la imagen para reconocer características en la imagen. [2]

Para el reconocimiento de patrones o características en las imágenes, se pueden emplear diversas técnicas de visión computacional que se ajustan al tipo de problema a solucionar, tales como lo son las redes neuronales convolucionales, las cuales simulan el comportamiento de una neurona humana para aprender alguna característica de una imagen y después transmitir el conocimiento adquirido a una salida u otra neurona que lo necesita para obtener otra nueva característica.

I.C. Red Neuronal Convolucional.

Las redes neuronales convolucionales trabajan dividiendo y modelando la información en partes más pequeñas, y combinando esta información en las capas más

profundas de la red. Por ejemplo, en el caso del tratamiento de una imagen, las primeras capas tratarían de detectar los bordes de las figuras. Las siguientes capas buscarían combinar los patrones de detección de bordes para conseguir formas más simples, y aplicar patrones de posición de objetos, iluminación. Por último, en las últimas capas se intentará hacer coincidir la imagen con todos los patrones descubiertos, para conseguir una predicción final de la suma de todos ellos. Así es como las redes neuronales convolucionales consiguen modelar una gran cantidad de datos, dividiendo previamente el problema en partes para conseguir predicciones más sencillas y precisas [3].

El ABCD para identificar el melanoma por parte de las personas podría tener una detección errónea, por lo tanto, mediante una aplicación intuitiva para los usuarios y una red neuronal convolucional, se propone en este trabajo la implementación de un servidor que opera en una computadora, donde se ejecuta la clasificación del lunar y la respuesta es retornada hacia el dispositivo móvil donde se encuentra la aplicación. El propósito de la creación de este método computacional, no solo se enfoca en la utilización por parte del paciente, sino también en el apoyo hacia el médico especialista a que obtenga una prueba mucha más acertada junto con sus conocimientos. Por otro lado, el ofrecimiento hacia ambas partes puede tener un impacto y beneficio para prevenir miles de muertes, la confianza entre el médico y el paciente es un punto importante. Existe el riesgo de una posible negligencia médica, además el posible daño que alguna persona podría sufrir por haber sido mal diagnosticada. A fin de que sea una herramienta sencilla que permita la reducción del costo monetario por estudios laboriosos y el conocimiento previo de varios médicos especialistas, la inteligencia artificial puede simplificar el diagnóstico de los lunares sobre la piel de cualquier individuo.

II. METODOLOGÍA

Se recolectan fotografías de melanomas de la página web de la Colaboración Internacional de Imágenes de la Piel (*The International Skin Imaging Collaboration*) para después hacer una clasificación donde se agruparon los lunares de acuerdo a su etiqueta (benignos o malignos). Se escalaron debido a que los lunares de las fotografías no tenían la misma distancia a la cámara cuando fue tomada, además, estaban en posiciones diferentes los nevus sobre la imagen, algunas características de los nevus estaban entre una clasificación benigna o maligna, por lo tanto, algunas imágenes fueron desechadas. Por otro lado, se removió el ruido (bellos, piel circundante, etc.) de la imagen, de tal forma que solo quedará el nevus en la imagen, consecuentemente se realizó un enfoque para que todas las imágenes estuvieran a la misma distancia, además tuvieran los mismos pixeles de ancho y largo. El recorte, el enfoque y

el escalamiento de 932 fotografías (476 nevus benignos y 456 nevus malignos) fue llevado a cabo utilizando el sitio web de BeFunky (Fig. 1).

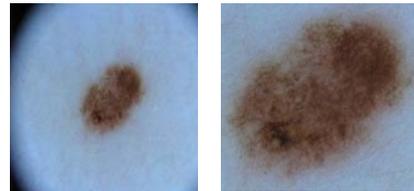


Fig. 1. La imagen de la izquierda es la final donde fue procesada manualmente y la del lado derecho usando BeFunky.

II. Aumento de la Cantidad de Imágenes (*Image Data Augmentation*)

Mientras se entrena un modelo de red neuronal convolucional, no se quiere que el modelo cambie en cualquier predicción basada en el tamaño, ángulo y posición de la imagen. La imagen es presentada como una matriz de valores de pixeles, así que el tamaño, ángulo y la posición tiene un gran efecto en el valor de pixeles. Para hacer el modelo de tamaño más invariante, se puede agregar diferentes tamaños de la imagen al conjunto de entrenamiento. Similarmente, para hacer el modelo más de rotación invariante, se puede agregar imágenes con diferentes tamaños. Este proceso es conocido como Aumento de la Cantidad de imágenes (*Image Data Augmentation*). Esto también ayuda a evitar el sobreajuste que ocurre cuando un modelo está expuesto a muy pocos ejemplares. [4]

Se implementó la técnica de Aumento de la Cantidad de Imágenes (*Image Data Augmentation*) donde a partir de la poca cantidad de imágenes que se tenía de ambas clases, se realizó un aumento de la cantidad de imágenes donde se aplicaba una rotación en diferentes grados, agregación de ruido gaussiano a los canales RGB, flip (dar la vuelta a la imagen) y el ajuste de las imágenes a un tamaño de 512x512 pixeles de todas las imágenes. Finalmente, se obtuvieron 20,000 imágenes de cada clase, para ser utilizadas en la prueba (*test*), el entrenamiento (*training*) y la validación (*validation*). Para dividir la carpeta que contenía ambas clases se siguió el porcentaje de esta manera: entrenamiento - 70% (14,000 malignos y 14,000 benignos), prueba - 10% (2,000 malignos y 2,000 benignos) y validación - 20% (4,000 malignos y 4,000 benignos).

La Figura 2 muestra el diagrama de la red neuronal convolucional utilizada. La figura 3 el diagrama de secuencia del funcionamiento del método computacional propuesto para llevar a cabo la clasificación de los nevus.

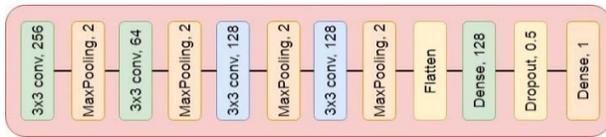


Fig.2. Arquitectura de la RNC, todas las capas usan la función ReLU, excepto la última que es sigmoide para obtener la probabilidad de que sea un nevus maligno (1) o benigno (0).

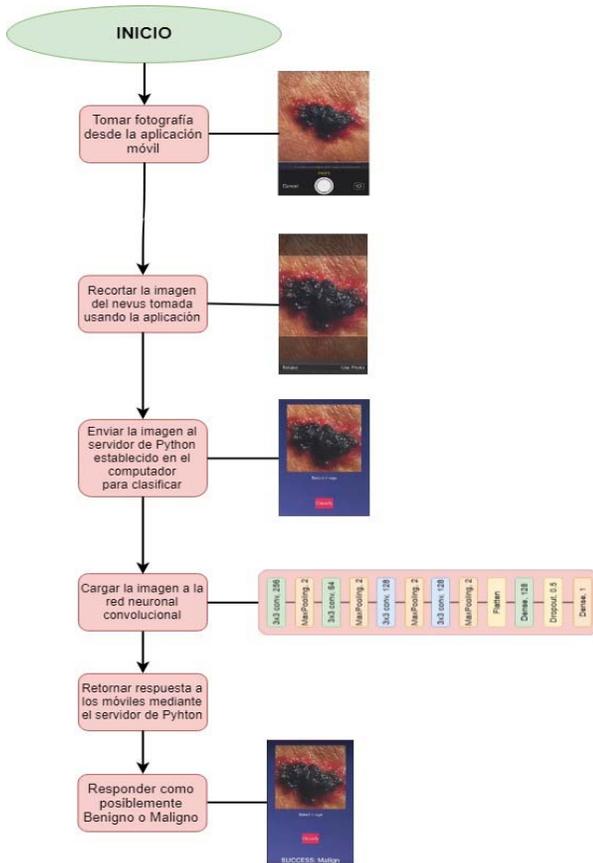


Fig.3. Diagrama de Secuencia del Método Computacional.

III. RESULTADOS

Para la implementación del método computacional de la clasificación de los nevus como posiblemente malignos o posiblemente benignos, se utilizó las librerías de TensorFlow, Keras, Theano y la plataforma de Anaconda. Además, el uso de dispositivos móviles tales como iOS y Android, donde fueron hechas las aplicaciones correspondientes, por otro lado, un servidor en Python que se ejecuta en los ordenadores que usan los sistemas operativos de Apple o Microsoft para después contestar finalmente a los clientes (teléfonos celulares) la predicción hecha por la red neuronal convolucional.

A continuación, se presentan los resultados finales, después de haber utilizado la red neuronal convolucional con un conjunto de imágenes de lunares o nevus que el modelo de aprendizaje hasta cierto punto no había visto. 4,000 imágenes de nevus malignos y 4,000 de nevus benignos.

Los resultados muestran que se han detectado más de la mitad como verdaderos positivos y porcentaje bajo como verdaderos negativos, tanto en el diagnóstico de cada una de las clases.

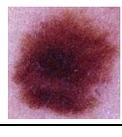
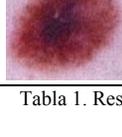
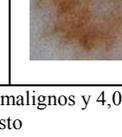
Tipo de Nevus Diagnosticado	Benigno	Tipo de Nevus Diagnosticado	Maligno
Número de Posibles Lunares Malignos Encontrados	48 (Falsos Positivos)	Número de Posibles Lunares Benignos Encontrados	649 (Falsos Negativos)
Número de Posibles Lunares Benignos Encontrados	3952 (Verdaderos Negativos)	Número de Posibles Lunares Malignos Encontrados	3351 (Verdaderos Positivos)
Total	4,000	Total	4,000
Verdaderos Negativos	Falsos Positivos	Verdaderos Positivos	Falsos Negativos
			
			
			
			
			

Tabla 1. Resultados obtenidos en 4,000 muestras de malignos y 4,000 de benignos usando el método propuesto

Los resultados de la precisión y la exactitud que tiene el modelo haciendo una predicción en base a los resultados anteriores.

$$\text{Exactitud} = \frac{3351+3952}{3351+48+649+3952} = 0.913$$

$$\text{Precisión} = \frac{3351}{3351+48} = 0.986$$

Los lunares del lado izquierdo fueron diagnosticados por el modelo correctamente, sin embargo, del lado derecho los nevos fueron detectados erróneamente. Existen algunas similitudes entre los verdaderos positivos y falsos negativos. Sin embargo, se puede observar que los ejemplos de las dos clases de nevos, haciendo hincapié en los verdaderos positivos comparten casi las mismas características y en los falsos negativos varía en ciertas muestras.

IV. DISCUSIÓN

En el trabajo realizado existen desventajas, tales como, el recorte manual de las imágenes por parte del usuario, además, la existencia de ruido estocástico alrededor del lunar (pelos, piel, pequeños cambios de iluminación, etc.) que pudiera estar sobre el lunar segmentado, lo cual podría generar una mala probabilidad de clasificación del nevus. Otro factor importante fue la falta de conseguir un poco más de muestras de lunares, de donde partieron las imágenes resultantes para realizar la técnica de Aumento de la Cantidad de imágenes (*Image Data Augmentation*), al principio se contaba con 476 imágenes de nevos malignos y 457 imágenes de nevos benignos, estas fotografías fueron segmentadas una por una para que solo quedará el lunar y después escaladas manualmente a 512x512 pixeles (ancho y alto), por lo tanto, tomó demasiado tiempo. Por otro lado, si la cantidad de imágenes de partida hubiera sido mayor, se pudieran haber obtenido mejores resultados, pues entre más muestras diferentes de imágenes de nevos se hubieran conseguido, un mejor resultado se habría obtenido. El sobreajuste es poco probable que aumente, por consecuencia, la creación de imágenes aumentadas hubiera sido mayor. Actualmente para que el método sea implementado tiene que estar funcionando la red neuronal convolucional en una computadora que funge como servidor, éste le contesta al dispositivo móvil que funge como cliente, por esta razón, existe la necesidad de tener el cliente-servidor al mismo tiempo encendidos, así pues, sería necesario utilizar alguna librería de los lenguajes de programación donde las aplicaciones móviles han sido desarrolladas para quitar la utilización del computador. Sin embargo, la utilización de esta aplicación podría tener un gran impacto en el ámbito médico, puesto que ayudaría a prevenir de forma mucho más eficiente y barata la detección temprana de uno de los tipos de cáncer muy comunes que se trata de prevenir en la actualidad. La radiación ultravioleta que se tiene en estos días, además de mencionar que gran porcentaje de la población tiene un constante contacto con los rayos solares y los pocos cuidados para la piel, son factores imprescindibles que puede decidir si el desarrollo de un melanoma será una consecuencia para que el crecimiento del nevus continúe durante el transcurso del tiempo. Unas de las limitaciones en este trabajo es que está en proceso de experimentación, es decir, las herramientas

utilizadas como son Anaconda y las aplicaciones desarrolladas son con enfoque para verificar si la funcionalidad de la red neuronal convolucional es viable junto con los teléfonos celulares, cabe mencionar que también el modelo de aprendizaje profundo puede ser ejecutado desde el mismo ordenador y dar la clasificación a un nevus desconocido. Finalmente, para someter el método en situaciones de tiempo real en el área médica, sería interesante crear un dispositivo móvil donde pudiera ser utilizado por los médicos para crear un diagnóstico de predicción por parte de la inteligencia artificial y el especialista. Además, la creación de una base de datos nueva para que la red neuronal convolucional pueda reentrenarse y obtener mejores resultados con base a nuevas muestras de nevos y con las que ya tiene. Adicionalmente, el uso de un servidor donde los clientes puedan obtener acceso al servidor y con sus celulares móviles ellos mismos tomen una fotografía, de esta forma, el servidor les responda para que sea un diagnóstico mucho más rápido y eficaz, evitando la espera de la típica consulta, así mismo el médico podría estar en contacto con varios de sus pacientes mediante la aplicación y observando la etapa de los nevos.

V. CONCLUSIÓN

La visión computacional y el uso del aprendizaje profundo (Deep Learning, en inglés) prometen generar grandes impactos no solo en el ámbito de la dermatología, sino en otras ramas de la ciencia. Actualmente, el uso de las técnicas de visión por computador genera una manera más fácil de como los dermatólogos-oncólogos podrían observar y detectar los melanomas en etapas tempranas y otro tipo de factores internos como la estructura biológica del tumor que se pueda desarrollar.

Concluyendo que el método propuesto es una alternativa en la prevención y diagnóstico gratuito de los nevos cancerosos y el contacto con el especialista, de forma más automática e instantánea mediante el uso de las tecnologías de la información, como lo son el internet y las redes sociales.

BIBLIOGRAFÍA

- [1] Toro, G. R. (2004). *Glosario ilustrado de dermatología y dermatopatología*. Bogotá: Universidad Nacional de Colombia - Facultad de Medicina.
- [2] Nagabhushana, S. (2005). *Computer Vision and Image Processing*. Delhi: New Age International.
- [3] Córtes, C. A. (2017). *Herramientas Modernas en Redes Neuronales: La librería Keras*. Madrid: Universidad Autónoma de Madrid.
- [4] Sewak, M., Karim, M. R., & Pujari, P. (2018). *Practical Convolutional Neural Networks*. Birmingham: Packt.