



Modelo para la detección de melanoma mediante el escaneo de imágenes con Deep Learning usando el algoritmo K-NN(Abril 2018)

Acerca de los autores...

* Docentes de la División de Ingeniería en Sistemas Computacionales, Tecnológico de Estudios Superiores de Ecatepec.

Leonardo M. Moreno Villalba*, Francisco Jacob Ávila Camacho*, Adolfo Meléndez Ramírez*, Juan Manuel Stein*

Resumen

El melanoma es considerado como el tumor más letal de piel por su gran capacidad de producir metástasis, a nivel mundial se estima que cada año ha sido el causante de cerca de 57,000 fallecimientos; en México, el aumento de esta neoplasia ha tenido una evolución de casi 500%, y su diagnóstico resulta de cierta forma difícil, debido a que al inicio de la neoplasia suele confundirse con verrugas. El presente trabajo de investigación proporciona una aproximación a la detección de cáncer en la piel a través de imágenes termoscópicas realizadas con una cámara web normal, utilizando el framework de Machine Learning Tensorflow como base para la creación de los bancos de datos de imágenes correspondiente, aplicando el Algoritmo K-NN y el lenguaje de programación Python para su implementación y uso.

Index Terms: Deep Learning, Melanoma, K-NN, Clasificación y segmentación de imágenes dermoscópicas

Introducción

La incidencia en la aparición de cáncer de piel mejor conocido como melanoma, ha venido en incremento durante los últimos años, provocando cerca de 57,000 muertes anuales, según cifras de la Organización Mundial de la Salud (OMS) en su último reporte mundial de cáncer [1]; de igual forma, diferentes organizaciones, universidades e institutos estadounidenses alertan sobre el aumento en la aparición de este tipo de cáncer de la piel, principalmente en las mujeres, de acuerdo con el reporte del instituto nacional de los Estados Unidos [2] el melanoma tiene un índice de aparición de 19.7 por cada 100,000 y un índice de mortalidad del 2.7%. Para el caso de México, según N. Estela, H. González, A. Yasmín, y A. Flores [3] en el artículo titulado “El melanoma en México” mencionan que el Instituto Nacional de Cancerología (INCAN) reporta que en los últimos años es evidente el aumento de esta neoplasia, con una evolución de casi 500%, “el diagnóstico de melanoma es difícil, sobre todo al inicio de la neoplasia, ya que ésta suele confundirse con verrugas, hongos, hemangiomas, hematomas y queratosis seborreica, entre otros; por eso, su detección puede tomar largos periodos”[3]. De ahí la importancia de desarrollar nuevos modelos, técnicas y algoritmos que permitan prevenir y detectar a tiempo la aparición del melanoma, siendo el cáncer de piel el más agresivo que existe.



El presente trabajo de investigación proporciona un acercamiento a los mecanismos para la detección de cáncer en la piel, a través de imágenes dermoscópicas realizadas con una cámara Web normal, utilizando el framework de Machine Learning Tensorflow, como base para la creación de los correspondientes bancos de datos de imágenes, aplicando el Algoritmo K-NN y el lenguaje de programación Python para su implementación y uso.

En el caso de este artículo, se presentan los elementos básicos para la construcción del algoritmo, así como el conjunto de elementos que lo conforman y su respectivo estado, mencionando que el algoritmo aún se encuentra en el status de prueba.

1. DESARROLLO

1.1 Estado del Arte

Si bien se ha establecido la importancia que tiene la investigación en el sector de la salud a nivel mundial, existen diferentes autores que funcionaron como eje guía y base teórica para la realización del mismo.

El artículo presentado por J. Johnson y A. Vijayan[4] titulado *“Neural Network Ensemble Model with Back Propagation for Classifying Melanoma on Dermoscopy Images-A Survey”* nos muestra una revisión de la literatura de diferentes investigaciones publicadas con respecto a la aplicación de redes neuronales e inteligencia artificial para la clasificación de imágenes dermoscópicas, mostrando un gran panorama teórico que abarca el uso de técnicas que van desde la clasificación de fotografías de las lesiones mediante el uso de constantes de color, la aplicación de algoritmos genéticos para la segmentación automática de imágenes, y la detección y clasificación de imágenes basadas en aprendizaje supervisado y no supervisado.

En otro trabajo de investigación desarrollado por A. Antony, A. Ramesh, A. Sojan, B. Mathews, M. Tessy[5] titulado *“Skin Cancer Detection Using Artificial Neural Networking”*, se proporciona una aplicación de redes neuronales para la detección de cáncer en la piel; los autores establecen una metodología basada en cinco etapas que son: el ingreso de la imagen, el preprocesamiento de la misma (que se encarga de eliminar el ruido y cualquier error que pueda estar contenido en la imagen y complique el correcto diagnóstico), otra denominada segmentación (que consiste en una colección de operaciones no lineales relacionadas con la forma y morfología de las imágenes), posteriormente la llamada extracción de características (la cual es un procesador de imágenes que se encarga de extraer elementos característicos de las lesiones, previamente cargados en un dataset para poder clasificar la imagen), una cuarta etapa llamada red neuronal (que cuenta con una capa de entrada, una capa oculta y una capa de salida), y por último, la de resultados (que muestra los datos obtenidos para la clasificación de la lesión).

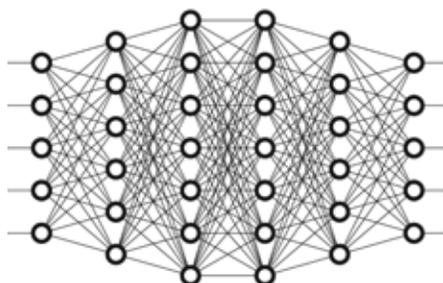
Finalmente, como antecedente teórico se utilizó el artículo [6] de Y. Li and L. Shen, titulado *“Skin Lesion Analysis towards Melanoma Detection Using Deep Learning Network,”* el cual se basa en tres principales tareas: en la primera, se realiza una segmentación y clasificación de la imagen; a continuación, se ocupa una red neuronal convolucional (CNN) para la extracción de las características de la fotografía dermoscópica implementada para mejorar el rendimiento y velocidad en la clasificación de las imágenes, este autor nos da un conjunto de guías o pautas para la utilización de redes neuronales en investigaciones médicas.

2. MÉTODO

Nuestro algoritmo de evaluación en línea revisa los signos de crecimiento no natural de las lesiones cutáneas y se basa en una metodología matemática establecida en biología, llamada geometría fractal. Para esto, se realiza una caracterización dividida en seis etapas, las cuales explicaremos a continuación.

1. Reconocimiento de imagen digital: con el propósito de tener la mejor imagen demoscópica, el algoritmo permite determinar una comparativa de la imagen[7]

$$F = \emptyset + \beta + V$$



Donde:

\emptyset = Previo de la imagen

β = Comparativa de la imagen.

V =Distancia desde el origen (punto del pixel a tratar)

2. Formateo de la imagen a escala de grises: la fotografía se convierte a un formato más apropiado para extraer sus características. En esta primera aproximación se consideró que lo más relevante de las imágenes a tratar era su contorno, y para ello no es necesario tener en cuenta el color de las imágenes (segmentación), por lo que es más conveniente transformarla a una escala de grises. En este proyecto se trabajó con el modelo RGB [8] de intensidad de colores para imágenes.

3. Filtrado de imagen: se busca reducir la amplitud de las variaciones de la fotografía, y una manera simple de hacer esto, es reemplazar cada pixel por la medida del valor de los pixeles de alrededor; de esta forma, las variaciones rápidas de intensidad suelen ser suavizadas y reemplazadas por una transmisión más gradual. La función del algoritmo es la siguiente[9] :

$$G(x,y)=\frac{1}{(2*\pi*O^2)} * e^{-\frac{(x^2+y^2)}{(2*a^2)}}$$

Donde:

x = Eje horizontal.

y = Eje vertical.

O = Desviación estándar.

4. Binarización de la imagen: proceso que transforma una imagen que está en escala de grises a una en dos colores, eliminando pixeles no deseados, y correcciones de sombras[10] :

Función gaussiana:

$$dst(x,y)=\begin{cases} 255 & \text{si } I(x,y) < T(x,y) \\ 0 & \text{si } I(x,y) \geq T(x,y) \end{cases}$$

Donde:

$I(x,y)$ =La imagen original

$dst(x,y)$ =La imagen binarizada

5. Detección de bordes: para ello se determina la diferencia entre dos valores vecinos pertenecientes a la misma estructura de pixeles, el núcleo para la detección de bordes, el gradiente operador ∇ en su forma continua y aplicada a un gradiente de espacio continuo, $f_c=(x,y)$. Es definida por[11] :

$$\nabla f_c(x,y)=\frac{(\partial f_c(x,y))}{\partial x} i_x + \frac{(\partial f_c(x,y))}{\partial y} i_y$$

Donde:

i_x y i_y son los vectores en las direcciones X y Y respectivamente.

Para el desarrollo del algoritmo se utilizó un conjunto de librerías de software *open source* para la computación matemática que usa flujo de datos de grafos[12], esto debido a la su fácil integración con el lenguaje de programación Python, lo cual facilitó obtener una arquitectura flexible, rápida y ágil para el desarrollo.

Una vez determinado el algoritmo, se procedió a crear el dataset con el conjunto de características obtenido de todo el proceso de adquisición, filtrado y detección, a partir de cerca 500 imágenes adquiridas en la Web, correspondientes a diagnósticos médicos de melanoma, las cuales se muestran a continuación:



Figura 1

Carga de una imagen correspondiente a melanoma en el dataset de imágenes.

Una vez cargada nuestra matriz, se procedió al entrenamiento propio de la red neuronal mediante Python. Luego se procedió a crear un *training set*, para verificar la acurancia del modelo propuesto, revisando los verdaderos negativos, y los falsos positivos que arrojó el mismo.

Nombre	Tamaño	Modificado
img1.jpg	10.2 KB	1/1/2018
img1.png	1.1 KB	1/1/2018
img2.jpg	4.3 KB	1/1/2018
img2.png	1.1 KB	1/1/2018
img3.jpg	5.4 KB	1/1/2018
img3.png	1.1 KB	1/1/2018
img4.jpg	1.7 KB	1/1/2018
img4.png	1.1 KB	1/1/2018
img5.jpg	1.8 KB	1/1/2018
img5.png	1.1 KB	1/1/2018
img6.jpg	9.0 KB	1/1/2018
img6.png	1.1 KB	1/1/2018
img7.jpg	1.2 KB	1/1/2018
img7.png	1.1 KB	1/1/2018
img8.jpg	1.2 KB	1/1/2018
img8.png	1.1 KB	1/1/2018

Figura 2

Visualización del dataset de imágenes correspondiente a melanoma.



Figura 3

Dataset de imágenes dermoscópicas de lesiones correspondientes a melanoma.

Actualmente, se está implementando el algoritmo de clasificación llamado “el vecino más cercano” o KNN, el cual está basado en la búsqueda en un conjunto de prospectos de los k prospectos más cercanos al patrón a clasificar; es decir, para realizar la clasificación de una imagen se recurre a ver cómo están clasificadas las imágenes más cercanas a ella. Las predicciones se realizan basándose en los ejemplos más parecidos al que hay que predecir. [13] El costo del aprendizaje es 0, pues todo el coste pasa al cálculo de la predicción. A este algoritmo se le conoce como mecanismo de aprendizaje perezoso (lazy learning). Debemos especificar una métrica para poder determinar la proximidad. En la Figura 4 podemos visualizar la predicción de melanoma en la aplicación de 100 diferentes casos de prueba, la cual nos devuelve 4 casos falsos positivos (puntos verdes en el área roja) y 4 verdaderos negativos, proporcionándonos un asertividad del 84%; actualmente se está trabajando para poder reducir esta cifra, a fin de poder proporcionar un modelo y aplicación confiable.

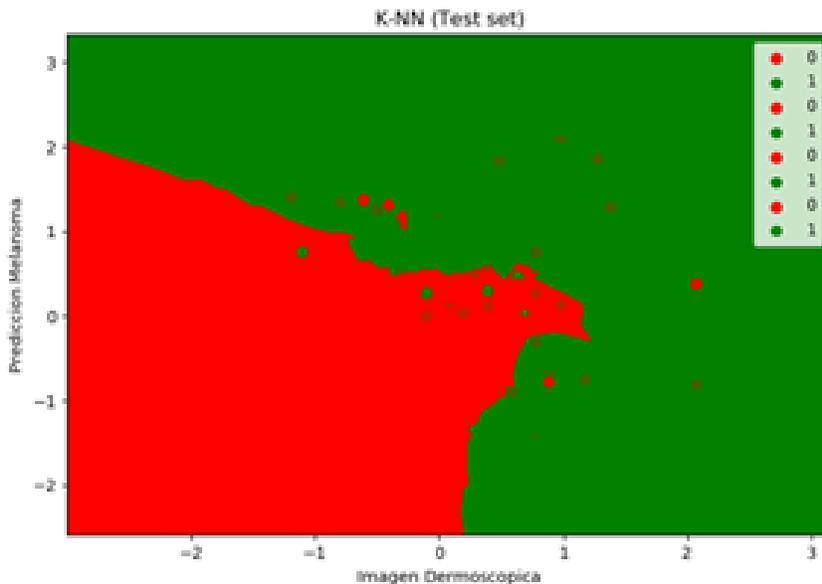


Figura 4

Imagen resultante de la aplicación del Algoritmo K-NN para la predicción de melanoma en un banco de imágenes de pruebas.

Una vez aplicado el algoritmo, el modelo nos genera otra imagen en donde se clasifica y subraya la predicción de melanoma obtenida después de aplicar el algoritmo; esto puede ser observado en la Figura 5, donde se ve el recuadro generado por el modelo sobre la lesión característica de este tipo de patologías.



Figura 5

Resultado de la predicción de la lesión de melanoma basada en una imagen dermoscópica.

Deep Learning proporciona unos resultados muy precisos, que pueden ir mejorando en su clasificación conforme más se vaya entrenando, eso debido a que ofrece modelos que están compuestos por múltiples capas que permiten elaborar representaciones de los datos con diferentes niveles de abstracción[14]; el modelo se evalúa con diferentes algoritmos de clasificación, y actualmente se evalúa aplicando el Reder Neuronales Convolucionales.

Conclusiones

La detección temprana de melanoma mediante diferentes herramientas que faciliten el diagnóstico o generen avisos a los posibles pacientes, permiten mejorar en gran medida el tratamiento de este tipo de cáncer en etapas tempranas. La utilización de herramientas de inteligencia artificial en el ámbito médico hará posible una mejora en el tratamiento, diagnóstico y prevención de enfermedades. Desde abril del 2018, la FDA (Food and Drug Administration) de los Estados Unidos, organismo responsable de la regulación de alimentos, medicamentos, cosméticos, aparatos médicos, productos biológicos y derivados sanguíneos, autorizó la comercialización de dispositivos basados en la inteligencia artificial, permitiendo la unión de dos grandes áreas del conocimiento para la mejora de la salud del ser humano, este modelo busca sentar las bases para futuras investigaciones en el reconocimiento y clasificación de imágenes para su uso en diagnósticos médicos oportunos.

Biografías de los Autores

M. EN I.S.C. LEONARDO M. MORENO VILLALBA. Es Ingeniero en Sistemas Computacionales, Maestro en Ingeniería en Sistemas, Doctorante en Cómputo. Ha impartido conferencias y publicado en memorias de congresos nacionales e internacionales, así como en revistas indexadas y arbitradas, actualmente está dirigiendo proyectos de investigación financiados por el Tecnológico Nacional de México. Sus líneas de investigación incluyen inteligencia artificial, machine learning, aprendizaje profundo, procesamiento natural del lenguaje y visión artificial. Es miembro del Institute of Research Engineers and Doctors, y de la International Association of Engineers. Es profesor-investigador del Tecnológico de Estudios Superiores de Ecatepec, adscrito a la División de Informática.

DR. FRANCISCO JACOB ÁVILA CAMACHO. Nació en Puebla en 1967. Obtuvo el título de ingeniero en electrónica por la Universidad Autónoma Metropolitana, Unidad Azcapotzalco. D.F., México. En 1990, obtuvo el grado de la Maestría en Ingeniería en Sistemas Computacionales en el Tecnológico de Estudios Superiores de Ecatepec (TESE), Estado de México, y el Doctorado en sistemas computacionales por parte de la Universidad Da Vinci en México, D.F. en el año 2015. Del 2003 a la fecha se ha desempeñado como profesor investigador en la División de Ingeniería en Sistemas Computacionales en el TESE; ha impartido conferencias y publicado en memorias de congresos nacionales e internacionales así como en revistas indexadas y arbitradas. Actualmente está dirigiendo proyectos de investigación financiados por el Tecnológico Nacional de México. Sus líneas de investigación incluyen inteligencia artificial, reconocimiento de patrones y algoritmos difusos, minería de datos, internet de las cosas, sistemas distribuidos, sistemas embebidos, brain computer interface. Es socio fundador de la empresa lhualia Software, S.A. de C.V., mantiene dos registros en el Instituto Nacional del Derecho de Autor por el software desarrollado para la empresa miembro activo de la Sociedad Mexicana de Tecnologías de la Información, Mecatrónica y Telemática, A.C.

DR. ADOLFO MELÉNDEZ RAMÍREZ. Nació en Tlaxcala en 1965. Obtuvo el título de ingeniero en comunicaciones y electrónica en el Instituto Politécnico Nacional, Unidad Zacatenco. D.F., México en el año 1990. Obtuvo el grado de la Maestría en Administración y Desarrollo de Negocios de la Universidad del Valle de Toluca en el 2011; obtuvo el grado de Doctor en Sistemas Computacionales de la Universidad Da Vinci en 2015. Del 2003 a la fecha se ha desempeñado como profesor investigador en la División de Ingeniería en Sistemas Computacionales en el Tecnológico de Estudios Superiores de Ecatepec. Ha impartido conferencias y publicado en memorias de congresos nacionales e internacionales y actualmente está dirigiendo proyectos de investigación financiados por la DGEST y el Tecnológico Nacional de México. También cuenta con artículos en revisión en diversas publicaciones arbitradas e indexadas. Sus líneas de investigación incluyen procesamiento paralelo, inteligencia artificial, reconocimiento de patrones, seguridad informática, minería de datos, internet de las cosas, sistemas distribuidos, sistemas embebidos. Es socio fundador de la empresa Pringel, S.A. de C.V. Es miembro activo de la Sociedad Mexicana de Tecnologías de la Información, Mecatrónica y Telemática, A.C. Es miembro (M) de la IEEE en 2015 y miembro de ACM desde 2013.

ING. JUAN MANUEL STEIN: Es candidato a doctor por la Universidad DaVinci; actualmente es profesor de tiempo completo en el Tecnológico de Estudios Superiores de Ecatepec, ha publicado 2 artículos en revistas internacionales y sus líneas de investigación están enfocadas en interfaces humano-computadora, reconocimiento de patrones y otros.

Referencias

- [1] C. P. Stewart, B., Wild, "World Cancer Report 2014," 2014.
- [2] G. P. Guy et al., "Vital signs: melanoma incidence and mortality trends and projections - United States, 1982-2030.," MMWR. Morb. Mortal. Wkly. Rep., vol. 64, no. 21, pp. 591-6, Jun. 2015.
- [3] N. Estela, H. González, A. Yasmin, and A. Flores, "El melanoma en México," Rev. Espec. Médico-Quirúrgicas Vol., vol. 15, no. 3, 2010.
- [4] J. Johnson and A. Vijayan, "Neural Network Ensemble Model with Back Propagation for Classifying Melanoma on Dermoscopy Images-A Survey," Int. J. Adv. Res. Ideas Innov. Technol., vol. 4, no. 1, pp. 112-115, 2018.
- [5] A. Antony, A. Ramesh, A. Sojan, B. Mathews, M. Tessy, and A. Varghese, "Skin Cancer Detection Using Artificial Neural Networking," vol. 4, no. 4, 2016.
- [6] Y. Li and L. Shen, "Skin Lesion Analysis towards Melanoma Detection Using Deep Learning Network," Sensors, vol. 18, no. 2, p. 556, Feb. 2018.
- [7] M. Sonka, V. Hlavac, and R. Boyle, Image Processing, Analysis and Machine Vision. 2014.
- [8] J. Russ, The Image Processing Handbook, Sixth Edition, 6th ed. CRC Press, 2016.
- [9] Zhengguo Li, Jinghong Zheng, Zijian Zhu, Wei Yao, and Shiqian Wu, "Weighted Guided Image Filtering," IEEE Trans. Image Process., vol. 24, no. 1, pp. 120-129, Jan. 2015.
- [10] N. Chaki, S. H. Shaikh, and K. Saeed, "A Comprehensive Survey on Image Binarization Techniques," Springer, New Delhi, 2014, pp. 5-15.
- [11] P. Melin, C. I. Gonzalez, J. R. Castro, O. Mendoza, and O. Castillo, "Edge-Detection Method for Image Processing Based on Generalized Type-2 Fuzzy Logic," IEEE Trans. Fuzzy Syst., vol. 22, no. 6, pp. 1515-1525, 2014.
- [12] G. Zaccane, M. R. Karim, and A. Menshawy, Deep Learning with TensorFlow. Packt Publishing, 2017.
- [13] T.-H. Chan, K. Jia, S. Gao, J. Lu, Z. Zeng, and Y. Ma, "PCANet: A Simple Deep Learning Baseline for Image Classification?," IEEE Trans. Image Process., Vol. 24, No. 12, pp. 5017-5032, Dec. 2015.
- [14] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," Nature, Vol. 521, No. 7553, pp. 436-444, 2015.