
Estudio para determinar melanoma en la piel usando técnicas de minería de datos

Study to determine melanoma on the skin using Data Mining techniques

Rogger Antonio Maita Asmat

<https://orcid.org/0000-0002-0592-5104>

rogger.maita@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos. Lima, Perú

RECIBIDO: 09/05/2021 - ACEPTADO: 08/08/2021 - PUBLICADO: 28/12/2021

RESUMEN

En esta investigación se analizarán y aplicarán redes neuronales como uso de una solución de minería de datos para la determinar si una lesión en la piel es considerada un melanoma o nevus (lunar) debido a que se suele confundir las características visuales parecidas. El melanoma es el tipo más grave de cáncer de piel, es originado en las células productoras de pigmento (melanocitos) localizadas predominantemente en la piel.

Palabras clave: Redes neuronales convolucionales; Minería de datos; Melanoma; Nevus; Inteligencia de Negocios.

ABSTRACT

In this research, neural networks will be analyzed and applied as the use of a data mining solution to determine if a skin lesion is considered a melanoma or nevus (mole) because similar visual characteristics are often confused. Melanoma is the most serious type of skin cancer, it originates in pigment-producing cells (melanocytes) located predominantly in the skin.

Keywords: Convolutional Neural Networks; Data Mining; Melanoma; Nevus; Business Intelligence.

I. INTRODUCCIÓN

Se estima que 91,270 nuevos casos de melanoma invasivo serán diagnosticados en 2018 en los EE. UU. Se espera que unas 9.320 personas mueran de melanoma en (Spiegel et al., 2018). Con imágenes de dermatoscopia, el melanoma es completamente visible en la etapa más temprana, cuando es completamente curable. Sin embargo, muchos expertos en dominios pasan por alto muchos casos de melanoma. La dermatoscopia es una herramienta importante en la detección temprana del melanoma, ya que aumenta la precisión diagnóstica en comparación con la inspección visual clínica en manos de médicos experimentados (Pehamberger et al, 1993). Sin embargo, los dermatólogos que usan la dermatoscopia en cuatro estudios recientes han demostrado una precisión diagnóstica más baja que las técnicas de visión artificial, un estudio que usa técnicas artesanales convencionales y tres que usan aprendizaje profundo (Marchetti et al., 2016). El primer paso en la evaluación clínica de las lesiones cutáneas suele ser el examen visual o la fotografía clínica. Las lesiones sospechosas se determinan a través de esta evaluación y luego a menudo se examinan adicionalmente mediante dermatoscopia. Por lo tanto, el análisis computacional de las imágenes de lesiones cutáneas adquiere una gran importancia en la prevención del cáncer de piel (Oliveira et al. 2016). En el siguiente estudio se aplica técnicas de procesamiento de imágenes y redes neuronales convolucionales para detectar el melanoma mediante el procesamiento de las fotografías tomadas por la dermatoscopia. El papel está organizado de la siguiente manera en la sección II se da a conocer trabajos relacionados, en la sección III se explica la técnica utilizada y la metodología planteada en la IV sección se muestra los resultados obtenidos y por ultimo las conclusiones.

II. ESTADO DEL ARTE

Las redes neuronales convolucionales son un tipo de red bio-inspirado que simula la forma en que funciona la visión del ser humano, es una modificación del perceptrón multicapa. El nombre de "Red Neuronal de Convolución" indica que la red emplea una operación matemática llamada convolución. La convolución es un tipo especializado de operación lineal. Las redes convolucionales son simplemente las redes neuronales que utilizan convolución en lugar de la multiplicación general de matrices en al menos una de sus capas. Las CNN explotan la correlación espacial local mediante la aplicación de un patrón de conectividad

local entre las neuronas de las capas adyacentes. Cada unidad es insensible a variaciones fuera de su campo receptivo con respecto a la retina. Así pues, la arquitectura garantiza que los filtros aprendidos producen la respuesta más fuerte a un patrón de entrada en el espacio local.

a. Automatic skin lesion analysis towards melanoma detection

"Se presenta la técnica para el desarrollo del modelo CNN para clasificar la legión de la piel como melanoma y benigna. La arquitectura del sistema propuesta es la que se muestra en la figura 1."

i. Resultados

La red neuronal que propuesta por el autor fue entrenada con 700 imágenes (350 cada uno para malignos y benignos). Los mejores resultados obtenidos de prueba y evaluación de desempeño creado después de entrenar la estructura de red optimizada fue la que se muestra en la siguiente Tabla 1:

Tabla 1
Resultados de la red optimizada

Parámetros	Valor
Número total de muestras	700
(Entrenamiento y Prueba) Proporción	(70% y 30%)
Número de iteraciones	40
Taza de aprendizaje	0.001
Precisión	79.7%

Finalmente, los autores comparan su método con el método STOLZ que es un método convencional de clasificación de melanoma. La comparación se realiza de acuerdo con el mismo conjunto de datos (700 muestras), el método STOLZ consiguió una precisión del 76.60% según la matriz de confusión que se muestra en la Figura 2. Por lo que se concluye que, para la detección precisa de imágenes de cáncer de piel, la identificación precisa del área de la lesión es de gran importancia (esta era la característica en la que fallaba el método STOLZ). En este trabajo se presentó un método basado en redes de aprendizaje profundo para la extracción de melanoma en imágenes clínicas. La estructura de aprendizaje profundo propuesta mostró la capacidad de detectar casos de melanoma de benignos.

Figura 1

Matriz de confusión del método STOLZ

True	Melanoma	228	122
	Benign	42	308
		Melanoma	Benign
		Predicted	

b. In Vivo Epiluminescence Microscopy: Improvement of Early Diagnosis of Melanoma

El autor propone utilizar el principio de ELM, que trata de examinar de manera no invasiva in vivo las lesiones cutáneas con un microscopio utilizando luz incidente suministrada desde un ángulo agudo e inmersión en aceite, lo que permite al investigador mirar a través de la epidermis hasta la unión dermoepidérmica y, en las lesiones con poca pigmentación, incluso más allá de eso. Utilizando el principio de ELM y comparando sus resultados con diagnósticos clínicos se obtuvo que para un total de 509 lesiones el diagnóstico clínico acertó en el 60% de estos casos (303) mientras que utilizando el principio de ELM se acertó en el 84% de los casos (420).

c. International Skin Imaging Collaboration International Symposium on Biomedical Imaging challenge

Realizó un estudio transversal con 100 imágenes dermatoscópicas seleccionadas al azar (50 melanomas, 44 nevos y 6 lentigos), junto con resultados de algoritmos individuales de 25 equipos. Utilizamos 5 métodos (non-learned and machine learning) para combinar predicciones automatizadas individuales en algoritmos de "fusión". En un estudio complementario, 8 dermatólogos clasificaron las lesiones en las 100 imágenes como benignas o malignas. La sensibilidad y especificidad promedio de los dermatólogos en la clasificación fue de 82% y 59%. Con una sensibilidad del 82%, la especificidad del dermatólogo fue inferior al algoritmo de fusión de mejor rendimiento (59% frente a 76%, $p = 0,02$). Por lo tanto, se concluye que los sistemas de visión por computadora de aprendizaje profundo clasificaron las imágenes de dermatoscopia de melanoma con una precisión que excedió a algunos, pero no a todos los dermatólogos.

III. METODOLOGÍA

La metodología propuesta se divide en dos pasos principalmente, la extracción de características y la clasificación. La extracción de características es la parte en la cual la red neuronal convolucional captura aquellas características más relevantes que permitan identificar el melanoma. Para la realización de la clasificación se utiliza la función de pérdida L2-SVM, la cual se implementa en la última capa, reemplazando la capa clásica de Softmax.

a. Dataset

El dataset utilizado para realizar el entrenamiento y pruebas del modelo planteado es HAM10000 (Humano contra máquina con 10000 imágenes de entrenamiento) que se encuentra disponible en Kaggle.com. El dataset contiene un conjunto de imágenes dermatoscópicas que fueron recolectadas de diferentes poblaciones. El conjunto total de imágenes consta de 10015 imágenes dermatoscópicas que fueron confirmadas por patología por un consenso de expertos. El dataset está estructurado por 7 columnas:

- lesionid
- imageid
- dx
- dxtype
- age
- sex
- localization

b. Preprocesamiento de datos

Para preparar las imágenes para la red neuronal convolucional, cada imagen es redimensionada a 64 x 64 píxeles y luego se normaliza las imágenes dividiendo el valor de cada píxel entre 225, esto se hace para que cada píxel tenga un valor entre 0 y 1, ya que, las entradas con valores grandes pueden ralentizar el proceso de aprendizaje. Luego se aplica la técnica de aumento de datos en la cual se realiza giros aleatorios, zooms aleatorios, volteos horizontales y verticales.

c. Extracción de características

Las imágenes ingresan a la red neuronal con una dimensión de 64x64, las cuales pasan por las capas de convolución para obtener el mapa

de características. Luego que las imágenes son cargadas y pre procesadas, se implementa el modelo presentado en las Figuras 2 y 3. Las imágenes de 64x64x3 (imagen de 64x64 píxeles con 3 canales de color) pasan por las capas de convolución, donde se realiza la operación de convolución entre la imagen de entrada y el filtro o kernel predefinido para obtener el mapa de características. El modelo propuesto está compuesto 4 bloques de convolución, con un bloque de 32 filtros, otro bloque de 64 filtros y dos bloques finales con 128 filtros con un kernel de 3x3. Cada bloque tiene un maxpooling de 2x2, la función de activación ReLU y un dropout de 0.2. Finalmente se aplica el Flattening para convertir las matrices en un vector unidimensional.

Figura 2

Melanoma original

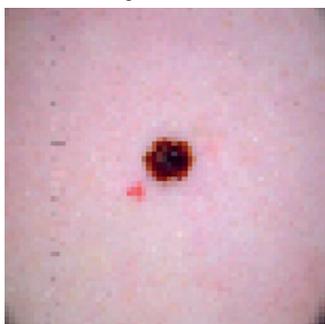


Figura 3

Melanoma girado



d. Clasificación

Para las capas totalmente conectadas están compuestas por dos capas de 512 y 256 neuronas y una capa final de dos neuronas con la función de activación de Softmax y el optimizador Adam.

e. Red neuronal convolucional propuesta

Hemos propuesto una CNN simple para la clasificación del melanoma utilizando algunas de las ideas fundamentales de la revisión de la literatura (Thao et al.,2017) y (Das et al.,2014). La red tiene cuatro capas convolucionales y tres de agrupación que en su última capa tiene dos neuronas para la clasificación de los resultados resultados, como se ve en la Figura 4.

IV. RESULTADOS

Para evaluar el modelo planteado se utilizan los datos de prueba y se obtiene la matriz de confusión, con lo cual podemos calcular las métricas de exactitud, precisión, recall y f1-score. De la matriz de confusión en la Tabla 2, podemos extraer 1499 Verdaderos positivos (VP), 1366 Verdaderos negativos (VN), 203 Falsos negativos (FN) y 278 Falsos positivos (FP).

Tabla 2

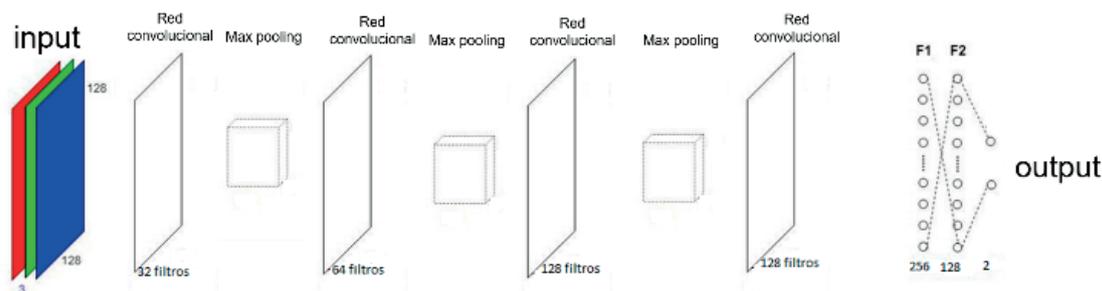
Matriz de Confusión

Clasificación de melanoma	Predicción	
Nevus	1499	203
Melanoma	278	1366

De los VP, VN, FN y FP podemos obtener la métrica de exactitud, en la cual se obtuvo 85.62% el cual se entiende como el total observaciones positivas predichas correctamente entre el total de los datos y para las siguientes métricas de precisión, recall y F1-Score se presenta en la Tabla 3, donde

Figura 4

Modelo CNN



se dividen en métricas para “Nevus”, “Melanoma” y un promedio ponderado de estas métricas.

Tabla 3
Métricas del modelo CNN

	Precisión	Recall
Nevus	84.35 %	88.07%
Melanoma	87.06%	83.09%
Promedio	85.68%	85.61%

La precisión promedio fue de 85.68%, el cual se entiende como la relación entre las observaciones positivas predichas correctamente y el total de observaciones positivas (verdaderos positivos y falsos positivos). Con la métrica de recall promedio obtenido fue de 85.61%, que es la proporción de observaciones positivas predichas correctamente a todas las observaciones en la clase.

En las Figuras 5 y 6, se pueden observar cómo los datos de entrenamiento y pruebas varían en función a las épocas y la reducción del sobreajuste mediante la técnica de dropout.

Figura 5
Resultados con los datos de entrenamiento

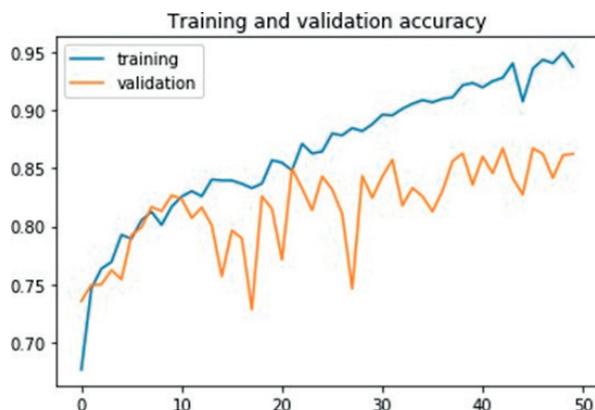
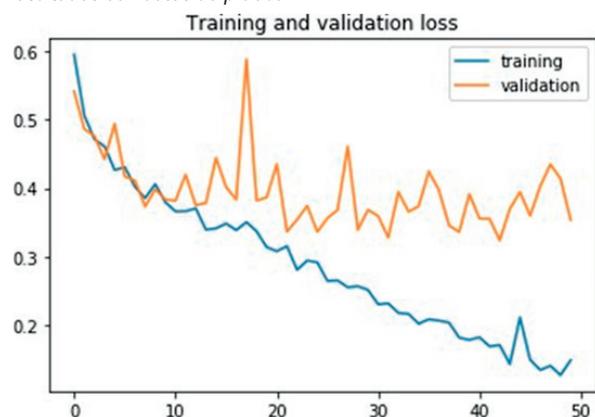


Figura 6
Resultados con datos de prueba



V. CONCLUSIONES

Para la detección precisa de imágenes de melanoma en la piel, la precisión de determinar el melanoma en el área de la lesión es de gran importancia. En este trabajo se presentó las redes neuronales convolucionales como técnica capas para detectar casos de melanoma benignos. Los resultados experimentales mostraron nuestra mejor precisión promedio de 85.68%. Para futuros trabajos relacionados se plantearía la opción de reducir el sobreajuste del modelo y para la mejora de las técnicas de pre procesamiento se puede usar segmentación de imágenes y también conseguir más imágenes de melanomas comprobados para resulte un mejor modelo.

VI. REFERENCIAS

- [1] Siegel, A., Miller, K., & Jemal, A., (2018). Cancer Statistics. CA: Cancer J. Clinicians, vol 6, no. 1, pp. 7-30.
- [2] Pehamberger, H., Binder, M., Steiner, A., & Wolff, K. (1993) . In vivo epiluminescence microscopy: improvement of early diagnosis of melanoma. Journal of Investigative Dermatology., vol. 100, pp. 356S-362S.
- [3] Marchetti, A., Codella, N., Dusza, S., Gutman, D., Helba, B., Kalloo, A., et al.(2017). Results of the 2016 International Skin Imaging Collaboration International Symposium on Biomedical Imaging challenge: Comparison of the accuracy of computer algorithms to dermatologists for the diagnosis of melanoma from dermoscopic images. Journal Am. Acad. Dermatol., vol. S0190-8622(17), pp. 32202-8.
- [4] Oliveira, R., Marranghello, N., Pereira, A., & Tavares, J. (2016). A computational approach for detecting pigmented skin lesions in macroscopic images. Expert System. Applied., vol. 61, pp. 53–63.
- [5] Thao, L.V & Quang, N. (2017). Automatic skin lesion analysis towards melanoma detection. 21st Asia Pacific Symposium on Intelligent and Evolutionary Systems (IES), Hanoi, pp. 106-111.
- [6] Das, D., Koley, S., Chakraborty, C. & Maiti, A. (2014). Automated segmentation of Mitotic Cells for in vitro histological evaluation of oral squamous cell carcinoma. IEEE - International Symposium on Signal Processing and Information Technology (ISSPIT),Noida. pp. 000354-000357.

Fuentes de financiamiento:

Propia.

Conflictos de interés:

El autor declara no tener conflicto de interés.