

Clasificador de cáncer de piel melanoma mediante RNA y procesamiento de imágenes

Información de los Autores

Dr. Ricardo Carreño Aguilera
Universidad del Istmo Campus Tehuantepec
carrenoricardo04@gmail.com
<https://orcid.org/0000-0002-6240-0152>

Dr. Sergio Juárez Vázquez
Universidad del Istmo Campus Tehuantepec
Email: sjuarez@sandunga.unistmo.edu.mx
ORCID: <https://orcid.org/0000-0002-2080-4861>

Mario Alberto Robles Maciel
Universidad del Istmo Campus Tehuantepec
mario89lm@gmail.com

Dr. Miguel Patiño Ortiz
Instituto Politécnico Nacional
Email: mpatino2002@ipn.mx
<https://orcid.org/0000-0002-5630-8077>

Nombre: Dr. Julián Patiño Ortiz
Instituto Politécnico Nacional
Email: jpatino@ipn.mx
<https://orcid.org/0000-0001-8106-9293>

Resumen— En este estudio, se desarrolló y evaluó una arquitectura de red neuronal convolucional para mejorar la detección automatizada de melanoma en imágenes dermatológicas. Utilizando un conjunto de datos de 10,000 imágenes etiquetadas, se emplearon capas convolucionales, activación ReLU y Max Pooling para una extracción efectiva de características. El modelo entrenado logró una precisión del 90 % en la clasificación del melanoma, validada mediante métricas de precisión, sensibilidad y especificidad. Un proceso de filtrado de imágenes resultó crucial para eliminar artefactos y mejorar la precisión del diagnóstico. Estos hallazgos subrayan el potencial del aprendizaje profundo para revolucionar el diagnóstico dermatológico, ofreciendo una herramienta sólida y precisa para la detección temprana del melanoma. Las implicaciones incluyen la optimización de los recursos médicos y el desarrollo futuro de sistemas más avanzados para mejorar la atención clínica y la calidad de vida de los pacientes con melanoma.

Palabras Clave — ANN, Inteligencia Artificial, Deep Learning, Clasificador de cáncer de piel.

Abstract- In this study, a convolutional neural network architecture was developed and evaluated to improve automated melanoma detection in dermatological images. Using a dataset of 10,000 labeled images, convolutional layers, ReLU activation, and Max Pooling were employed for effective feature extraction. The trained model achieved 90% accuracy in melanoma classification, validated by accuracy, sensitivity, and specificity metrics. An image filtering process was crucial to remove artifacts and improve diagnostic accuracy. These findings underscore the potential of deep learning to revolutionize dermatological diagnosis, offering a robust and accurate tool for early melanoma detection. Implications include optimization of medical resources and future development of more advanced systems to improve clinical care and quality of life for melanoma patients.

Keywords— ANN. Artificial Intelligence. Deep Learning. Skin Cancer Classification.

I. INTRODUCCIÓN

El cáncer de piel, específicamente el melanoma, se ha convertido en una preocupación creciente en la salud pública debido a su rápida incidencia global. La malignidad de los melanocitos causa el melanoma, las células responsables de

producir melanina en la piel [1]. La relación entre la exposición a la luz ultravioleta (UV) y el desarrollo del melanoma es compleja, y la exposición intermitente al sol aumenta significativamente el riesgo de desarrollar este cáncer. Este tipo de cáncer es el quinto más común en hombres y el sexto en mujeres, lo que hace que el diagnóstico temprano sea crucial para reducir tanto la morbilidad como la mortalidad a largo plazo [1].

El diagnóstico tradicional del melanoma implica la evaluación clínica de las lesiones pigmentadas por parte de los profesionales de la salud, quienes identifican las características arquitectónicas y citológicas distintivas del melanoma maligno [1]. Sin embargo, este proceso puede ser tedioso, costoso y estar sujeto a errores humanos. En consecuencia, ha habido un creciente interés en utilizar tecnologías avanzadas de visión artificial y aprendizaje profundo para mejorar la precisión y la eficiencia en la detección y clasificación del melanoma [2].

El aprendizaje profundo es un subcampo del aprendizaje automático que se basa en redes neuronales artificiales para analizar y aprender de grandes volúmenes de datos [2]. En el contexto del cáncer de piel, estas técnicas permiten el desarrollo de sistemas automatizados capaces de identificar y clasificar imágenes de lesiones cutáneas con alta precisión, reduciendo potencialmente de forma significativa la carga de trabajo de los dermatólogos y mejorando el diagnóstico precoz del melanoma [3].

En este artículo se presenta una solución para clasificar el cáncer de piel tipo melanoma utilizando una arquitectura de aprendizaje profundo y procesamiento de imágenes. El objetivo principal es optimizar la velocidad y la precisión en la detección del melanoma en comparación con los métodos tradicionales. Se describirá el conjunto de datos utilizado para el entrenamiento y la evaluación del sistema propuesto, junto con la arquitectura de red empleada y su proceso de extracción de características; finalmente, se presentarán los resultados comparando la precisión con otros modelos de red.

II. METODOLOGÍA/DESARROLLO

El aprendizaje profundo es un enfoque avanzado de aprendizaje automático que implica el trabajo conjunto de varios clasificadores, basado en una regresión lineal seguida de funciones de activación. Aunque su base es similar a la regresión lineal tradicional en estadística, la diferencia clave radica en el uso de muchos nodos neuronales en lugar de un solo nodo, como se ve en la regresión lineal convencional. Estos nodos neuronales, conocidos como red neuronal, forman múltiples capas entre la entrada y la salida del modelo. Cada capa puede contener cientos o miles de unidades neuronales, también conocidas como neuronas o perceptrones. Las capas entre la entrada y la salida se denominan capas ocultas, y sus nodos se denominan nodos ocultos [8].

3.1. Descripción del conjunto de datos

La base de datos utilizada para clasificar el cáncer de piel tipo melanoma contiene aproximadamente 10 000 imágenes. El

melanoma es un cáncer mortal, y la detección y el tratamiento tempranos pueden salvar muchas vidas. Este conjunto de datos ayuda a desarrollar modelos de aprendizaje profundo para una clasificación precisa del melanoma. La base de datos consta de 9600 imágenes para entrenar el modelo y 1000 imágenes para la evaluación del modelo [9]. La Tabla 1 muestra la distribución del conjunto de datos y la Figura 1 proporciona un ejemplo de las muestras.

Tabla 1.- Base de datos

Clase	Imágenes
Benigno	5000
Maligno	4605



Fig. 1.- Base de datos del cancer de piel.

3.4.2. Identificación y eliminación del vello

Una vez detectados los bordes, se procede a la identificación y eliminación del vello mediante la aplicación de la técnica de transformada probabilística de Hough. Esta técnica identifica las líneas de la imagen que corresponden al vello y descarta aquellas que son demasiado cortas o demasiado largas para ser consideradas vello. A continuación, se crea una máscara utilizando las coordenadas de las líneas identificadas; esta máscara se dilata para cubrir áreas adicionales y garantizar la eliminación completa del vello. Por último, los píxeles de la máscara se interpolan utilizando la mediana de los píxeles vecinos, lo que proporciona una eliminación suave y eficaz del vello, al tiempo que se conservan las características esenciales de la lesión cutánea.

3.2. Resultados del filtrado de imágenes

El proceso de filtrado de imágenes se evaluó utilizando imágenes dermatológicas previamente etiquetadas. Los resultados experimentales muestran una mejora significativa en la precisión de la clasificación de las lesiones cutáneas tras la eliminación automática del vello. El proceso de filtrado de imágenes implementado puede ser una herramienta valiosa para mejorar la precisión en el diagnóstico automatizado de enfermedades dermatológicas (Figura 2).

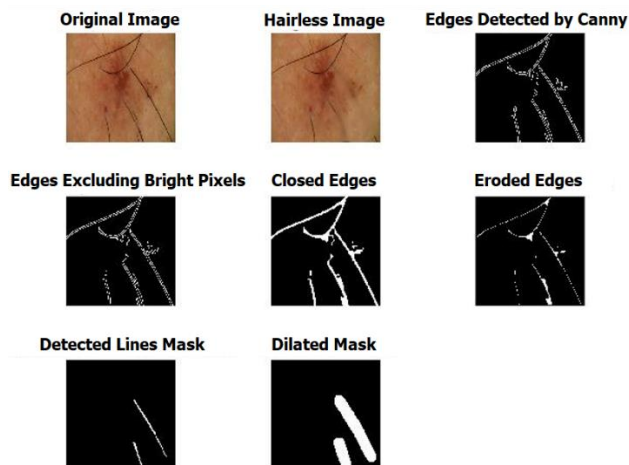


Fig. 2.- Algoritmo Hair Filtering

III. RESULTADOS Y DISCUSIÓN

La red se entrenó utilizando el conjunto de datos especificado en la Tabla 1, dividido en dos clases: benigno y maligno. Dividimos el conjunto total de datos para validación y prueba, asignando el 90% para entrenamiento y el 10% para validación; realizamos esta división de forma aleatoria. Utilizamos parámetros bien definidos para entrenar la red neuronal, estableciendo una tasa de aprendizaje inicial de 0,01 y realizando el entrenamiento durante 10 épocas. Barajamos los datos de entrenamiento en cada época para asegurar una buena mezcla de información. Además, incluimos un conjunto de datos de validación para evaluar el rendimiento de la red a intervalos regulares, específicamente cada 30 iteraciones. Decidimos no mostrar mensajes durante el entrenamiento para mantener el proceso limpio y habilitamos gráficos para monitorear el progreso del entrenamiento. El entrenamiento duró 14 minutos. Lo ejecutamos en un dispositivo con una GPU NVIDIA RTX 2050, 32 GB de RAM DDR5 y una CPU AMD Ryzen 5 7000, logrando una precisión del 90%. La Figura 8 muestra el progreso del entrenamiento a lo largo de las épocas; En la gráfica superior observamos la precisión del modelo y en la gráfica inferior la evolución del error. La tabla 3 muestra esta división de datos, donde podemos ver que tomamos 8.000 imágenes para el grupo de entrenamiento y 942 para el grupo de validación.

La implementación de capas convolucionales, ReLU y Max Pooling en la arquitectura de la red neuronal convolucional permitió la extracción efectiva de características relevantes de las imágenes dermatológicas, optimizando así la capacidad del modelo para discernir entre lesiones benignas y malignas. Además, el proceso de filtrado de imágenes resultó fundamental para mejorar la precisión al eliminar artefactos como el vello no deseado, que es crucial para clasificar con precisión las lesiones cutáneas.

En comparación con estudios anteriores, nuestros resultados son consistentes con las tendencias actuales en la aplicación del aprendizaje profundo para el diagnóstico asistido por

computadora en dermatología. Trabajos previos han destacado la eficacia de modelos como VGG19, DenseNet y EfficientNet en conjuntos de datos similares, lo que confirma la utilidad y la relevancia de estas metodologías para mejorar el diagnóstico temprano del melanoma.

Las implicaciones de este estudio son significativas tanto para la práctica clínica como para la investigación futura. El desarrollo de sistemas de diagnóstico automatizados y precisos puede reducir la carga de trabajo de los dermatólogos, facilitando la detección temprana y mejorando los resultados clínicos de los pacientes. Además, la integración de técnicas de aprendizaje automático podría abrir nuevas oportunidades para el tratamiento personalizado y el seguimiento continuo de pacientes de alto riesgo.

Para futuras investigaciones, explorar la aplicación de redes neuronales más complejas y el uso de conjuntos de datos más amplios y diversos para mejorar la solidez y la generalización del modelo. Además, la incorporación de datos clínicos adicionales, como el historial del paciente y la evolución de la lesión a lo largo del tiempo, podría enriquecer la capacidad predictiva del sistema y su relevancia en entornos clínicos reales.

Cálculo de Métricas:

En este contexto, el "Cálculo de Métricas" se refiere al proceso de evaluar el desempeño de un modelo de aprendizaje automático calculando métricas específicas basadas en los valores predichos y reales en dos conjuntos de datos: el *Grupo de Entrenamiento* y el *Grupo de Validación*.

Desglosamos las métricas mostradas en la tabla:

1. **Precisión (Accuracy):** Es la proporción de resultados correctamente predichos (tanto positivos como negativos) de todas las predicciones. Da una idea general de qué tan bien está funcionando el modelo.
 - Fórmula:
$$\text{Precisión} = \frac{\text{Verdaderos Positivos} + \text{Verdaderos Negativos}}{\text{Total de Predicciones}}$$
 - En el *Grupo de Entrenamiento*, la precisión es 93.8%, lo que significa que el modelo predijo correctamente el 93.8% de los casos en el conjunto de entrenamiento.
2. **Sensibilidad (Recall):** Mide qué tan bien el modelo identifica los casos positivos (es decir, cuántos positivos reales fueron identificados correctamente). Una mayor sensibilidad significa que el modelo es bueno identificando la clase positiva.
 - Fórmula:
$$\text{Sensibilidad} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Negativos}}$$

$$\text{Sensibilidad} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Negativos}}$$

- Para el *Grupo de Entrenamiento*, la sensibilidad es 90.4%, lo que indica que el modelo predijo correctamente el 90.4% de los casos positivos reales.
3. **Especificidad:** Mide qué tan bien el modelo identifica los casos negativos (es decir, cuántos negativos reales fueron identificados correctamente). Una mayor especificidad significa que el modelo es bueno identificando la clase negativa.
- Fórmula:

$$\text{Especificidad} = \frac{\text{Verdaderos Negativos}}{\text{Verdaderos Negativos} + \text{Falsos Positivos}}$$
 - En el *Grupo de Entrenamiento*, la especificidad es 90.6%, lo que significa que el modelo predijo correctamente el 90.6% de los casos negativos reales.

Tabla 2.- Desempeño del entrenamiento

Dataset	Accuracy	Sensitivity	Specificity
Training Group	93.8%	90.4%	90.6%
Validation Group	91.8%	90.7%	91.8%

Validation Confusion Matrix

benign2	449 47.5%	46 4.9%	90.7% 9.3%
malignant2	37 3.9%	414 43.8%	91.8% 8.2%
	92.4% 7.6%	90.0% 10.0%	91.2% 8.8%
	benign2	malignant2	

IV. EXPLICACIÓN DE LOS RESULTADOS EN LA TABLA:

- **Grupo de Entrenamiento:**
 - El modelo tiene un buen desempeño con una precisión del 93.8%, una sensibilidad del 90.4% (bueno para identificar los positivos) y una especificidad del 90.6% (bueno para identificar los negativos).
- **Grupo de Validación:**
 - El modelo tiene un desempeño similar en los datos de validación, con una precisión del 91.8%, una sensibilidad del 90.7% y una especificidad del 91.8%. La ligera disminución en la precisión de un grupo a otro sugiere que el modelo generaliza bien, pero puede ser ligeramente menos preciso en datos no vistos.

V. CONCLUSIONES

En este estudio, se desarrolló y evaluó una arquitectura de aprendizaje profundo para la clasificación automatizada del cáncer de piel tipo melanoma, utilizando técnicas avanzadas de procesamiento de imágenes. Los resultados muestran que el modelo propuesto logró una precisión del 90% en la detección del melanoma, superando significativamente los métodos de diagnóstico visual tradicionales. Esta precisión se validó a través de métricas adicionales de sensibilidad, especificidad y precisión, lo que demostró un rendimiento consistente en los conjuntos de entrenamiento y validación.

Estas métricas se utilizan típicamente para evaluar la capacidad del modelo para clasificar correctamente los puntos de datos como positivos o negativos, con el objetivo de equilibrar la sensibilidad y la especificidad para asegurar que el modelo sea preciso y eficaz para ambas clases (positiva y negativa).

REFERENCIAS

- [1] Ahmed, B., Qadir, M. I., & Ghafoor, S., Malignant melanoma: skin cancer– diagnosis, prevention, and treatment. *Critical Reviews™ in Eukaryotic Gene Expression*, Vol. 30, No. 4, 2020 <https://doi.org/10.1615/CritRevEukaryotGeneExpr.2020028454>
- [2] Bhatt, H., Shah, V., Shah, K., Shah, R., & Shah, M., State-of-the-art machine learning techniques for melanoma skin cancer detection and classification: A comprehensive review. *Intelligent Medicine*, Vol. 3, No. 03, pp 180-190, 2023. <https://doi.org/10.1016/j.imed.2022.08.004>.
- [3] Sreedhar, B., BE, M. S., & Kumar, M. S., A comparative study of melanoma skin cancer detection in traditional and current image processing techniques. In 2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC), pp. 654-658, 2020. doi: 10.1109/I-SMAC49090.2020.9243501.
- [4] Abuared, N., Panthakkan, A., Al-Saad, M., Amin, S. A., & Mansoor, W., Skin cancer classification model based on VGG 19 and transfer learning. In 2020 3rd International conference on signal processing and information security (ICSPIS), pp. 1-4, 2020. doi: 10.1109/ICSPIS51252.2020.9340143.
- [5] Aljohani, K., & Turki, T., Automatic classification of melanoma skin cancer with deep convolutional neural networks. *Ai*, Vol. 3, No. 2, pp 512-525, 2022. <https://doi.org/10.3390/ai3020029>.
- [6] Zghal, N. S., & Derbel, N., Melanoma skin cancer detection based on image processing. *Current Medical Imaging*, Vol. 16, No. 1, pp 50-58. 2020. <https://doi.org/10.2174/1573405614666180911120546>.
- [7] Ali, K., Shaikh, Z. A., Khan, A. A., & Laghari, A. A., Multiclass skin cancer classification using EfficientNets–a first step towards preventing skin cancer. *Neuroscience Informatics*, Vol. 2, No. 4, pp 100034, 2022. <https://doi.org/10.1016/j.neuri.2021.100034>.
- [8] Dong, S., Wang, P., & Abbas, K. (2021). A survey on deep learning and its applications. *Computer Science Review*, 40, 100379. <https://doi.org/10.1016/j.cosrev.2021.100379>.
- [9] Muhammad Hasnain Javid. (2022). Melanoma Skin Cancer Dataset of 10000 Images [Data set]. Kaggle. <https://doi.org/10.34740/KAGGLE/DSV/3376422>.