

Aplicación web para la detección de cáncer de piel basada en aprendizaje profundo

Web application for skin cancer detection based on deep learning

Fátima Katiushka Farías Rivera¹ , Nancy Magaly Loja Mora¹ , Fausto Juvenal Loja Mora¹ 

¹Carrera de Tecnologías de la Información, Universidad Técnica de Machala, Machala, Ecuador, 070151;

ffarias_est@utmachala.edu.ec; faustol@gmail.com

*Correspondencia: nmloja@utmachala.edu.ec

Citación: Farías, F.; Loja, N. & Loja, F., (2026). Aplicación web para la detección de cáncer de piel basada en aprendizaje profundo. *Novasinergia*. 9(1). 41-58.

<https://doi.org/10.37135/ns.01.17.03>

Recibido: 10 mayo 2025

Aceptado: 22 septiembre 2025

Publicado: 08 enero 2026

Novasinergia
ISSN: 2631-2654

Resumen: El desarrollo de tecnologías avanzadas en salud es una de las áreas más apasionantes y desafiantes del siglo XXI. La aplicación del aprendizaje profundo para el diagnóstico médico representa un avance significativo en la capacidad de los sistemas automatizados para asistir a los profesionales en la toma de decisiones. Este trabajo presenta una aplicación web para la detección temprana de cáncer de piel mediante redes neuronales convolucionales, específicamente ResNet; la misma permite la detección automática de ocho tipos de cáncer de piel: Melanoma, Nevo melanocítico, Carcinoma de células basales, Queratosis actínica, Dermatofibroma, Carcinoma de células escamosas, Lesión vascular y Queratosis seborreica. La metodología CRISP-DM utilizada en este estudio incluye el preprocesamiento de datos utilizando TensorFlow y la evaluación del desempeño del modelo mediante métricas como: precisión, sensibilidad, pérdida promedio y mAP (mean Average Precision). Se trabaja con un conjunto de datos de 25,331 imágenes, divididas en 20,265 para entrenamiento y 5,066 para prueba. Con los resultados de este trabajo se obtuvo, el 94% de precisión y 87% de sensibilidad. Se plantea como trabajo futuro la optimización del modelo y la exploración de su aplicación en otras patologías dermatológicas, con el objetivo de ampliar su utilidad en contextos clínicos asistidos por inteligencia artificial.

Palabras clave: Aplicación web, Aprendizaje profundo, Cáncer de piel, Redes neuronales convolucionales, TensorFlow.

Abstract: Developing advanced healthcare technologies is one of the most exciting and challenging areas of the 21st century. The application of deep learning to medical diagnosis represents a significant advance in the ability of automated systems to assist professionals in critical decision-making. This work presents a web application for early skin cancer detection using convolutional neural networks, specifically ResNet. It enables the automatic detection of eight types of skin cancer: melanoma, melanocytic nevus, basal cell carcinoma, actinic keratosis, dermatofibroma, squamous cell carcinoma, vascular lesion, and seborrheic keratosis. The CRISP-DM methodology used in this study includes data preprocessing using TensorFlow and model performance evaluation using metrics such as accuracy, sensitivity, average loss, and mAP (mean average precision). The model uses a dataset of 25,331 images, divided into 20,265 for training and 5,066 for testing. The results of this study yielded 94% accuracy and 87% sensitivity. Future work is proposed to optimize the model, explore its application in other dermatological pathologies, and expand its usefulness in clinical contexts assisted by artificial intelligence.

Keywords: Web Application, Deep Learning, Skin Cancer, Convolutional Neural Networks, TensorFlow.



Copyright: 2026 derechos otorgados por los autores a Novasinergia. Este es un artículo de acceso abierto distribuido bajo los términos y condiciones de una licencia de Creative Commons Attribution (CC BY NC). (<http://creativecommons.org/licenses/by/4.0/>).

1. Introducción

Los informes de la Organización Mundial de la Salud (OMS) muestran que una de las principales causas de decesos a nivel mundial es el cáncer [1], y se prevé que el número de casos diagnosticados se duplique en las próximas dos décadas. El cáncer de piel afecta a millones de personas [2] debido a su capacidad de desarrollarse en cualquier tipo de piel, especialmente en aquellos individuos que están expuestos de manera frecuente o prolongada a la radiación ultravioleta. Se genera cuando hay un crecimiento anormal y descontrolado de las células de la piel. Este proceso puede ser desencadenado por varios factores, los cuales alteran el ADN de las células cutáneas. Durante las últimas tres décadas, se ha observado un aumento progresivo, diagnosticándose más de 132,000 casos en todo el mundo [3].

Las lesiones cutáneas se pueden agrupar en melanocíticas y no melanocíticas. Las lesiones melanocíticas incluyen melanoma y nevos melanocíticos [4]. Del mismo modo, las lesiones no melanocíticas incluyen: el carcinoma de células basales, la queratosis actínica (forma anticipada de carcinoma de células escamosas y también conocida como enfermedad de Bowen), dermatofibroma y lesión vascular. Tanto las lesiones melanocíticas como las no melanocíticas tienen tipos malignos y benignos [5]. Las lesiones cutáneas malignas son cancerosas e incluyen melanoma, carcinoma de células basales y queratosis actínica. Para [6], la dermatoscopia es una técnica de imagen popular entre los dermatólogos, mejora la visualización de la superficie y estructura de las lesiones cutáneas para un examen más preciso. Sin embargo, esta técnica requiere de profesionales capacitados, ya que depende de la agudeza visual y experiencia del médico [7].

Actualmente, también existen diversos métodos asistidos por computador, como los enfoques basados en el aprendizaje profundo que han evidenciado resultados alentadores en la segmentación y clasificación de lesiones cutáneas, gracias a su habilidad para extraer características complejas de las imágenes de manera más detallada. Los algoritmos de aprendizaje profundo también tienen la capacidad de aprender características específicas para la tarea, lo que los hace mucho más eficientes que otros métodos [8]. La tecnología DL (Deep Learning) se considera uno de los temas más relevantes dentro del área del aprendizaje automático, así como la ciencia y el análisis de datos, debido a sus capacidades de aprendizaje a partir de los datos proporcionados [9]. Recientemente, se han utilizado redes neuronales convolucionales (CNN) y enfoques basados en el aprendizaje profundo para la detección del cáncer [10]. Estudios han demostrado que las CNN tienen un rendimiento de alto nivel en la detección de cáncer de piel. En particular, el modelo ResNet50 alcanzó una especificidad del 93% y una sensibilidad del 79%, evaluado con un conjunto de datos limitado. Además, la combinación de modelos como InceptionV3 y ResNet50 mejoró aún más la precisión, logrando un área bajo la curva (ROC-AUC) comparable o incluso superior a la de dermatólogos certificados [11]. Otro estudio mostró que un enfoque basado en múltiples modelos de CNN logró una precisión significativa en la clasificación de lesiones cutáneas, con un rendimiento similar al de los dermatólogos en la detección de melanoma y otras lesiones cutáneas, destacando la robustez y eficacia de las CNN en aplicaciones de diagnóstico médico [12]. A pesar de estos avances en el uso de inteligencia artificial, detectar y tratar esta enfermedad en etapas tempranas sigue siendo

crucial para reducir las tasas de mortalidad, por lo que el diagnóstico debe ser lo más preciso [13]. Sin embargo, la identificación del cáncer de piel continúa representando un desafío para los dermatólogos, lo que puede provocar retrasos en el tratamiento y, en consecuencia, resultados subóptimos para los pacientes. Debido a ello, los investigadores están enfocados en desarrollar estrategias de detección como una prioridad, generando la siguiente problemática: ¿Cómo puede el aprendizaje profundo ayudar a la detección de cáncer de piel, superando los obstáculos actuales y ofreciendo resultados más efectivos para los pacientes? Se justifica que la detección a tiempo del cáncer de piel es crucial, dado que la identificación precoz de la enfermedad puede incrementar las oportunidades de recuperación. Estos desafíos han motivado a la comunidad investigadora a desarrollar nuevas técnicas de visualización y detección del cáncer de piel que puedan superar las limitaciones de la dermatoscopia y brindar opciones más efectivas y accesibles para la detección de esta enfermedad, es aquí en donde el entrenamiento de un modelo automatizado basado en Aprendizaje Profundo para detectar cáncer de piel puede desempeñar un papel fundamental.

En este contexto, el objetivo de este estudio fue desarrollar una aplicación web que implemente un modelo basado en redes neuronales convolucionales (CNN) para la detección automática de cáncer de piel a partir de imágenes dermatoscópicas. El modelo fue entrenado para identificar ocho tipos específicos de lesiones cutáneas: melanoma, nevo melanocítico, carcinoma de células basales, queratosis actínica, dermatofibroma, carcinoma de células escamosas, lesión vascular y queratosis seborreica. La aplicación fue diseñada para operar en dispositivos tecnológicos, con el fin de facilitar su integración en contextos clínicos y no clínicos.

2. Metodología

Para el presente estudio se adoptó un enfoque metodológico de tipo cuantitativo y experimental, orientado a evaluar el desempeño de un modelo de aprendizaje profundo para la detección de cáncer de piel a partir de imágenes dermatológicas. El proceso de desarrollo siguió la metodología CRISP-DM (Cross Industry Standard Process for Data Mining), la cual es un modelo de proceso independiente de la industria para la minería de datos que proporciona un enfoque sistemático y adaptable que guía desde la comprensión del problema de negocio hasta la implementación de soluciones basadas en datos. [14]. La Figura 1 muestra la estructura de la metodología empleada.

Se implementó una red neuronal convolucional (CNN) utilizando el lenguaje de programación Python y las bibliotecas TensorFlow, Keras, OpenCV y NumPy. El conjunto de datos utilizado fue el ISIC 2019 Challenge Dataset, obtenido de la plataforma Kaggle, el cual contiene 25,331 imágenes de lesiones cutáneas etiquetadas por expertos. Como parte del preprocesamiento de los datos, se aplicaron técnicas de normalización de imágenes, aumento de datos (data augmentation) para mitigar el sobreajuste, y ajuste de tamaños de entrada para cumplir con los requisitos del modelo CNN. Además, se realizaron pruebas para determinar la cantidad óptima de épocas necesarias para el entrenamiento del modelo, con el objetivo de alcanzar un alto porcentaje de aciertos en la detección de cáncer de piel. Las métricas utilizadas para la evaluación del desempeño incluyeron precisión (accuracy),

sensibilidad (recall), especificidad, y la puntuación F1, con el objetivo de medir de manera integral la capacidad del modelo para identificar las lesiones sospechosas de cáncer. Las fases de entrenamiento y validación se diseñaron para reproducir los resultados y la evaluación del modelo después de aplicar técnicas de ajuste y optimización.



Figura 1. Estructura de la Metodología CRISP-DMCRTL.

2.1. *Comprensión del negocio*

Evaluación de la situación

La aplicación de CNN en la interpretación de imágenes dermatológicas, como las proporcionadas por el dataset ISIC-2019 de Kaggle [15] permite combinar la capacidad de datos del conjunto con el aprendizaje automático para identificar patrones complejos asociados con diversas condiciones de la piel. Con el fin de realizar el desarrollo de la aplicación web para la detección de cáncer de piel, se identificaron las principales partes interesadas del sistema, junto con sus responsabilidades específicas (Tabla 1).

Tabla 1. Partes interesadas del sistema.

ROL	APLICACIÓN WEB PARA DETECTAR CÁNCER DE PIEL
Responsabilidades:	
• Precisión y Fiabilidad: El sistema debe ser capaz de identificar los casos de cáncer de piel, minimizando tanto los falsos positivos como los falsos negativos. Debe someterse a pruebas de validación continua para asegurar su fiabilidad. • Accesibilidad: Debe ser accesible para una amplia gama de usuarios, incluyendo aquellos con diferentes niveles de habilidad tecnológica y aquellos que utilizan tecnologías asistidas. • Soporte al Usuario: Debe ofrecer soporte para ayudar a los usuarios a entender cómo utilizar el sistema correctamente.	
ROL	USUARIO FINAL
Responsabilidades:	
• Uso Adecuado: Los usuarios deben seguir las instrucciones de uso del sistema, incluyendo la preparación para la toma de imágenes de la piel. • Comprensión de Limitaciones: Los usuarios deben comprender que el sistema es una herramienta de apoyo a la decisión y no debe ser utilizado como sustituto de la consulta médica profesional. • Consulta Médica Profesional: En caso de un resultado positivo o si existen preocupaciones, los usuarios deben buscar evaluación y confirmación por parte de un profesional de la salud.	

2.2. Comprensión de datos

En esta investigación se utilizó el conjunto de datos ISIC-2019, que es parte de la competición ISIC Challenge en la detección automática de lesiones cutáneas. Como se puede observar en la Figura 2, incluye ocho categorías de diagnóstico dermatológico: Melanoma, Nevo melanocítico, Carcinoma de células basales, Queratosis actínica, Dermatofibroma, Carcinoma de células escamosas, Lesión vascular y Queratosis seborreica. Estas categorías fueron seleccionadas por estar contenidas de forma oficial y estructurada dentro del dataset, con disponibilidad y confiabilidad de los datos para fines de entrenamiento y evaluación de modelos computacionales. Además, el conjunto incluye 25,331 imágenes dermatoscópicas que abarcan lesiones tanto benignas como malignas, lo que proporciona una base sólida para el desarrollo de modelos de aprendizaje profundo con buen desempeño y capacidad de generalización.



Figura 2. Ejemplos de cada categoría del conjunto de datos [15].

Las imágenes del conjunto de datos están en formato PNG con 300 DPI [16], lo que permite el procesamiento y análisis posterior. Esta estructura de datos, con imágenes etiquetadas y metadatos, facilita el entrenamiento y evaluación de modelos de aprendizaje profundo para la detección y clasificación de las 8 lesiones cutáneas.

De acuerdo con [17] cada imagen está acompañada de metadatos que proporcionan información adicional relevante para el análisis. Estos metadatos incluyen:

- Edad del paciente: Indica la edad en años (Figura 3). se observa que las lesiones están distribuidas principalmente entre personas de 40 a 80 años, siendo el rango más común entre los 60 y 70 años.
- Sexo del paciente: El conjunto de datos contiene imágenes de hombres y mujeres, con una representación ligeramente mayor de pacientes masculinos en lesiones como carcinoma basocelular y queratosis actínica, mientras que en nevus melanocíticos y melanoma predomina la participación femenina (Figura 4).

- Ubicación anatómica: Detalla la parte del cuerpo donde se tomó la imagen de la lesión (Figura 5). Las ubicaciones más frecuentes incluyen el tórax anterior, extremidades superiores e inferiores y la región de cabeza/cuello.




Figura 3. Edad promedio por tipo de lesión del conjunto de datos.




Figura 4. Sexo por tipo de lesión del conjunto de datos.




Figura 5. Ubicación anatómica por tipo de lesión del conjunto de datos.

2.3. Preparación de datos

Integración de datos:

La preparación de datos involucró la consolidación de imágenes dermatológicas junto con su metadata asociada, que puede incluir información demográfica del paciente, detalles de la lesión y anotaciones específicas de diagnóstico. La integración efectiva aseguró que cada imagen esté vinculada a su información relevante, facilitando un análisis holístico y la aplicación de técnicas de aprendizaje automático.

Formateo de datos

Esta etapa se centró en asegurar que todas las imágenes y sus correspondientes metadatos estén en un formato homogéneo y listo para ser procesado por el modelo. Esto implicó estandarizar las dimensiones, dado que las CNN requieren que todas las entradas tengan el mismo tamaño. Esto se logró mediante técnicas de redimensionamiento aplicando padding para mantener la proporción de aspecto sin distorsionar la imagen original.

Para optimizar el rendimiento del modelo en la detección de cáncer de piel, se aplicó un proceso de preprocesamiento y aumento de datos utilizando la clase ImageDataGenerator de TensorFlow Keras [18]. Este procedimiento permitió normalizar las imágenes y aplicar transformaciones aleatorias, lo que ayudó a mejorar la capacidad de generalización del modelo y a reducir el sobreajuste. El conjunto de entrenamiento fue sometido a diversas transformaciones, incluyendo reescalado de los valores de los píxeles ($\text{rescale}=1./255$), rotaciones de hasta 40 grados, desplazamientos en el eje horizontal y vertical, cortes diagonales (shear), zoom aleatorio y volteo horizontal. Estas modificaciones permitieron que el modelo aprenda a reconocer patrones de lesiones cutáneas en distintas orientaciones

y condiciones. Para el conjunto de validación, se aplicó el reescalado, asegurando que las imágenes se mantuvieran en su formato original sin alteraciones adicionales.

2.4. *Modelado*

Selección de técnicas

Para seleccionar los modelos preentrenados se tomó como referencia el estudio [10], en donde se evalúan los modelos ResNet152V2, VGG19 y MobileNetV3Large, obteniendo métricas de precisión mayores al 70% en la detección de cáncer de piel. Estos modelos, preentrenados en grandes conjuntos de datos como ImageNet, permiten aplicar técnicas de transferencia de aprendizaje, adaptando el conocimiento adquirido a la detección de lesiones cutáneas con conjuntos de datos más pequeños, mejorando la eficiencia del entrenamiento y la precisión del modelo [4].

Es por ello, que para este estudio se seleccionaron los modelos preentrenados ResNet, VGG y DenseNet para la detección de los ocho tipos de cáncer de piel; estos modelos alcanzaron un rendimiento superior al 90 % en la clasificación de imágenes médicas.

Construcción del modelo

La construcción del modelo para la detección de cáncer de piel se desarrolló en varias etapas, comenzando con la preparación y procesamiento de los datos. Se utilizó el conjunto de datos ISIC-2019, dividido en 80 % para entrenamiento y 20 % para validación, siguiendo una práctica ampliamente aceptada en el desarrollo de modelos de aprendizaje profundo. Esta proporción permite que el modelo aprenda a identificar patrones de las lesiones cutáneas, mientras se evalúa su capacidad de generalización en datos no vistos. Aunque las divisiones entrenamiento/prueba pueden parecer arbitrarias, estudios recientes [19] respaldan que proporciones como 80/20 ofrecen un balance adecuado entre entrenamiento efectivo y validación confiable, especialmente cuando se cuenta con un volumen de datos considerable. Antes del entrenamiento, las imágenes pasaron por un proceso de preprocesamiento con el objetivo de mejorar la calidad visual y estandarizar su formato para la entrada al modelo. Para ello, se utilizó la biblioteca OpenCV para realizar el ajuste de tamaño de cada imagen a una dimensión uniforme de 224×224 píxeles, asegurando así la compatibilidad con las arquitecturas de redes neuronales utilizadas. A través de NumPy, se aplicó la normalización de los valores de los píxeles, transformándolos al rango [0, 1], lo cual facilitó la convergencia del modelo durante el entrenamiento al mantener una escala numérica estable. Asimismo, se implementaron técnicas de aumento de datos (data augmentation) como: rotaciones, volteos horizontales y variaciones leves de brillo y zoom, con el objetivo de incrementar la diversidad del conjunto de datos y mejorar la capacidad de generalización del modelo frente a nuevas imágenes.

Una vez preprocesadas las imágenes, se seleccionaron y compararon diferentes arquitecturas de redes neuronales convolucionales preentrenadas, entre ellas ResNet, VGG16 y DenseNet. Estas redes, previamente entrenadas con grandes conjuntos de datos como ImageNet, permiten reutilizar pesos aprendidos y detectar características visuales complejas desde las primeras capas [20], optimizando así el rendimiento en tareas específicas como la clasificación de imágenes dermatológicas. Tras la experimentación con

todas las arquitecturas, ResNet fue la que alcanzó el mejor desempeño en términos de precisión y capacidad de generalización, por lo que fue seleccionada como la arquitectura base para la fase final del entrenamiento y evaluación del modelo.

El modelo se entrenó ajustando los pesos durante 10 épocas, con una estrategia de validación cruzada para evaluar su rendimiento. Finalmente, se evaluó el modelo con los datos de validación, obteniendo métricas de pérdida y precisión, y se guardó el modelo entrenado en un archivo con formato .h5 para su posterior implementación y análisis en la detección de cáncer de piel. Finalmente, el modelo entrenado se integró en una aplicación web que permite a los usuarios cargar imágenes de lesiones cutáneas para su análisis. Utilizando tecnologías como Python, TensorFlow y Keras, el sistema procesa las imágenes y proporciona un diagnóstico preliminar de cáncer de piel. El código fuente asociado al entrenamiento está disponible en el siguiente repositorio: [21]

Arquitectura de la Red Neuronal

El modelo implementado para la detección de cáncer de piel se basó en una red neuronal convolucional (CNN) de tipo funcional, estructurada en múltiples capas especializadas para la extracción de características y clasificación. La arquitectura se compone por una serie de capas convolucionales, de normalización por lotes (*BatchNormalization*), funciones de activación, capas de *pooling* y conexiones residuales, siguiendo la estructura de ResNet. El modelo comienza con una capa de entrada (*InputLayer*), que acepta imágenes de tamaño variable con tres canales de color (RGB). Luego, se aplican capas de convolución inicial (*Conv2D*) con 64 filtros y un tamaño de kernel de 7x7, seguidas de una normalización por lotes para estabilizar el aprendizaje y mejorar la convergencia. Posteriormente, se aplica una función de activación ReLU (Rectified Linear Unit) y una capa de *max pooling* para reducir la dimensionalidad de los datos sin perder información relevante.

Después de la extracción de características, el modelo incorpora una capa de Global Average Pooling (GAP) que reduce las dimensiones del tensor de características, convirtiéndolo en un vector de tamaño 2,048. Esta estrategia ayuda a disminuir la cantidad de parámetros y mejora la generalización del modelo. Finalmente, la fase de clasificación está compuesta por una capa totalmente conectada (Dense) de 1,024 neuronas, seguida de una capa de dropout para prevenir el sobreajuste. La salida del modelo se realiza a través de una capa densa de 8 neuronas, correspondiente a las ocho clases de cáncer de piel, utilizando la función de activación softmax, que permite obtener probabilidades normalizadas para cada una de las categorías.

El modelo cuenta con un total de 76,976,026 parámetros, de los cuales 25,640,968 son entrenables, mientras que 53,120 permanecen congelados debido a la reutilización de pesos preentrenados de ResNet. Esta configuración permite aprovechar el aprendizaje previo en imágenes médicas y mejorar la capacidad de clasificación. Para la optimización del modelo, se empleó un optimizador eficiente con más de 51,281,938 parámetros destinados a mejorar la convergencia durante el entrenamiento.

Esta arquitectura, basada en ResNet y mejorada con técnicas de transfer learning, proporciona la capacidad de generalización y rendimiento en la detección de cáncer de piel,

permitiendo la clasificación de las lesiones dermatológicas en imágenes médicas como se visualiza en la Tabla 2.

Tabla 2. Modelo Funcional de la Red Neuronal Convolutacional.

Layer (type)	Output Shape	Param #	Connected to
input_layer (InputLayer)	(None, None, None, 3)	0	-
conv1_pad (ZeroPadding2D)	(None, None, None, 3)	0	input_layer[0][0]
conv1_conv (Conv2D)	(None, None, None, 64)	9,472	conv1_pad[0][0]
conv1_bn (BatchNormalization)	(None, None, None, 64)	256	conv1_conv[0][0]
conv5_block3_add (Add)	(None, None, None, 2,048)	0	conv5_block2_out[0][0], conv5_block3_3_bn[0][0]
conv5_block3_out (Activation)	(None, None, None, 2,048)	0	conv5_block3_add[0][0]
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2,048)	0	conv5_block3_out[0][0]
dense (Dense)	(None, 1,024)	2,098,176	global_average_pooling2d[0][0]
dropout (Dropout)	(None, 1,024)	0	dense[0][0]
dense_1 (Dense)	(None, 8)	8.2	dropout[0][0]
Total params:	76,976,026 (293.64 MB)		
Trainable params:	25,640,968 (97.81 MB)		
Non-trainable params:	53,120,872 (202.51 MB)		
Optimizer params:	51,281,938 (195.63 MB)		

3. Resultados

3.1. Evaluación

Matriz de confusión

Para la evaluación de la precisión de la red neuronal se utilizó la matriz de confusión (Tabla 3), esta matriz permite una visualización detallada del comportamiento del modelo, al comparar las etiquetas predichas con las verdaderas etiquetas de un conjunto de datos. Cada fila de la matriz corresponde a las instancias en una clase real, mientras que cada columna representa las instancias en una clase predicha [22]. Los elementos diagonales de la matriz reflejan las predicciones correctas, y los elementos fuera de la diagonal, los errores. Esto facilita la identificación de tipos específicos de errores y proporciona patrones cruciales para optimizar la red, como el ajuste de hiperparámetros y la mejora del equilibrio entre sensibilidad y especificidad del modelo.

Tabla 3. Matriz de Confusión

		Predicción	
		Positivos	Negativos
Observación	Positivos	Verdadero Positivo	Falso Negativo
	Negativos	Falso Positivo	Verdadero Negativo

Métricas

A partir de la matriz se obtienen las métricas de calidad para la detección de cáncer de piel:

$$\text{Precisión} = \frac{\text{Verdadero Positivo}}{(\text{Verdadero Positivo} + \text{Falso Positivo})} \quad (1)$$

$$\text{Sensibilidad} = \frac{\text{Verdadero Positivo}}{\text{Verdadero Positivo} + \text{Falso Negativo}} \quad (2)$$

$$\text{Valor de Referencia} = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}} \quad (3)$$

La matriz de confusión obtenida reflejó el desempeño del modelo ResNet (Figura 6), el cual fue seleccionado por su alta precisión después del entrenamiento y comparación con los modelos VGG16 y Densenet. Para este análisis, se realizó una evaluación utilizando un subconjunto de 500 imágenes con el fin de verificar su capacidad de generalización y analizar su comportamiento en distintas clases. El modelo demostró 69 clasificaciones correctas en la identificación de "Melanoma", aunque con confusión con "Melanocytic Nevus" (5 errores) y "Actinic Keratosis" (8 errores). Asimismo, "Basal Cell Carcinoma" se clasificó correctamente en 38 casos, con errores hacia "Actinic Keratosis" (9 errores) y "Benign Keratosis-like Lesion" (7 errores).




Figura 6. Matriz de Confusión.

Resultados de la evaluación

Cada modelo se entrenó bajo condiciones homogéneas; se analizaron métricas como: precisión, sensibilidad, pérdida promedio y mAP (mean Average Precision), con el propósito de determinar qué arquitectura ofrece el mejor rendimiento en la clasificación de imágenes dermatológicas. Esta comparación permitió identificar el modelo para ser aplicado en este estudio.

Como se observa en la Tabla 4, que presenta los indicadores de desempeño de los modelos ResNet, VGG16 y DenseNet, cada arquitectura mostró distintos niveles de precisión, sensibilidad, pérdida y mAP al ser evaluadas con el conjunto de datos ISIC-2019. ResNet obtuvo una precisión de 0.94, una sensibilidad de 0.87 y un mAP del 94.01% y una pérdida promedio del 14.04%, lo que refleja un desempeño equilibrado. Aunque VGG16 alcanzó un mAP ligeramente más alto (77.28%), su precisión fue menor (0.69). DenseNet registró resultados cercanos, pero con la mayor pérdida entre los tres modelos (15.67%).

Tabla 4. Resultados de los modelos preentrenados.

Modelo	Precisión	Sensibilidad	Valor de Referencia	Pérdida Promedio	mAP (%)
ResNet	0.94	0.87	0.90	14.04%	94.01
VGG16	0.69	0.79	0.75	13.67%	77.28
DenseNet	0.72	0.76	0.74	15.67%	74.28

El modelo seleccionado en este estudio para la detección de ocho tipos de cáncer de piel fue ResNet, dado que en los resultados obtenidos (Figura 7), en comparación a los otros modelos presentó una mejor relación entre precisión, sensibilidad y el valor de referencia en la clasificación de imágenes dermatológicas, con una precisión del 94%.




Figura 7. Resultados en estadística de la red neuronal.

La tabla 5, muestra que el modelo ResNet consiguió la clasificación de los ocho tipos de cáncer de piel, con valores mínimos de 0.84 y máximos de 0.96 para las métricas evaluadas de: precisión, sensibilidad y valor de referencia. En general, los resultados indican que el modelo logró diferenciar las lesiones de piel, aunque con algunas confusiones en clases con características similares.

Tabla 5. Pruebas de observación.

	Precisión	Sensibilidad	Valor de Referencia	Cantidad de imágenes
Melanoma	0.95	0.87	0.91	66
Nevus melanocítico	0.98	0.89	0.94	71
Carcinoma basocelular	0.91	0.86	0.89	58
Queratosis actínica	0.94	0.85	0.90	66
Lesión benigna queratósica	0.96	0.90	0.93	80
Dermatofibroma	0.90	0.84	0.87	44
Lesión vascular	0.92	0.85	0.89	53
Carcinoma de células escamosas	0.96	0.90	0.93	62
Promedio Global	0.94	0.87	0.90	500
Promedio macro	0.92	0.91	0.94	500
Promedio de pesos	0.92	0.91	0.94	500

Los resultados obtenidos son consistentes con la literatura investigada, en concordancia con lo descrito en [23] que presenta los siguientes hallazgos (Tabla 6) sobre la aplicación de redes neuronales convolucionales (CNN) en el diagnóstico automatizado de enfermedades cutáneas.

Tabla 6. Modelos.

Data	Clasificador	Precisión	Sensibilidad	Valor de Referencia	Promedio
ISIC2017	Resnet152	0.91	0.33	0.99	0.90
	VGG16	0.91	0.43	0.99	0.91
	EfficientNetB2	0.90	0.02	1.00	0.81
ISIC2018	Resnet152	0.76	0.91	0.97	0.90
	VGG16	0.76	0.94	0.96	0.90
	EfficientNetB2	0.76	0.06	1.00	0.89

Finalmente, a este modelo se lo exportó en formato JSON para su compatibilidad con la aplicación web (Figura 8). Las imágenes son cargadas por el usuario, ya sea a través de la cámara o seleccionadas desde su dispositivo, para luego proceder con la inferencia del modelo, proporcionando un diagnóstico probabilístico sobre la posible presencia de lesiones cancerígenas en la piel.




Figura 8. Implementación de la aplicación.

4. Discusión

Según investigaciones como las de [24], el uso de redes neuronales profundas ha demostrado superar la precisión de dermatólogos en la clasificación de ciertos tipos de lesiones. En este contexto, los resultados obtenidos en nuestro estudio refuerzan la viabilidad de modelos de deep learning como ResNet para la detección automatizada de cáncer de piel con una precisión superior a los métodos tradicionales. De acuerdo con los resultados obtenidos, ResNet superó a los demás modelos en precisión y capacidad de generalización. Este hallazgo coincide con trabajos previos como el de Attallah [25], quien desarrolló el sistema SCaLiNG utilizando una combinación de Gabor wavelets y modelos compactos como ResNet-18, alcanzando una precisión del 91.7% en la clasificación de siete tipos de cáncer de piel. Asimismo, el algoritmo HASCC propuesto por Niño-Rondón et al. [26] combinó VGG16, PCA y XGBoost para su ejecución en un entorno embebido, logrando resultados de hasta 93.2% de precisión, aunque con limitaciones de escalabilidad para plataformas web.

Otros estudios también confirman la eficacia de las redes neuronales convolucionales para esta tarea. Riaño et al. [27] emplearon una CNN de arquitectura básica entrenada con el dataset ISIC, obteniendo un 88.75% de precisión en la clasificación binaria de melanoma. En [28], se propuso un modelo basado en CNN combinado con técnicas de mejora de imágenes como ESRGAN, logrando una precisión del 85.7% con la arquitectura InceptionV3 al clasificar lesiones benignas y malignas en el conjunto de datos ISIC 2018. Por su parte, en [29], se exploraron diversas arquitecturas CNN optimizadas por técnicas de transferencia, destacando el impacto del preprocesamiento y la normalización en el desempeño del modelo. Finalmente, el estudio presentado en [30] utilizó un enfoque híbrido entre aprendizaje automático tradicional y modelos de deep learning para segmentar y clasificar

imágenes de lesiones cutáneas, destacando el valor del análisis de características y su integración con arquitecturas como MobileNetV2 y ResNet.

El rendimiento del modelo ha sido particularmente alto en la clasificación de Melanocytic Nevus y Squamous Cell Carcinoma, con precisiones de 0.95 y 0.94, respectivamente. Esto indica que el modelo ha logrado diferenciar estas clases con exactitud, lo que es crucial en el ámbito clínico, dado que el Melanoma a menudo puede confundirse con Nevus benignos y otros tipos de cáncer de piel. Sin embargo, algunas clases presentan un desempeño ligeramente inferior, como Dermatofibroma, con una precisión de 0.88, lo que sugiere que el modelo puede estar enfrentando dificultades para distinguir esta categoría de otras lesiones con características visuales similares.

Según [13], la combinación de pruebas clínicas tradicionales con modelos de IA basados en imágenes dermatológicas puede mejorar la detección temprana y la estratificación de riesgo en pacientes con lesiones sospechosas. En este estudio, la capacidad del modelo para identificar correctamente múltiples tipos de cáncer de piel respalda la idea de que los sistemas de IA pueden complementar y mejorar la precisión del diagnóstico dermatológico.

Un aspecto relevante de los resultados es que, a pesar de la variabilidad en el número de imágenes utilizadas para cada categoría, el modelo mantiene una precisión estable en la mayoría de las clases. Esto sugiere que el uso de técnicas de aumento de datos y ajuste fino del modelo (fine-tuning) ha permitido mejorar su capacidad de generalización [31]. Sin embargo, en clases con menor cantidad de imágenes, como Dermatofibroma y Vascular Lesion, se observan niveles de sensibilidad más bajos, lo que indica que el modelo puede beneficiarse de técnicas adicionales para equilibrar mejor la distribución de clases y mejorar su capacidad de detección en condiciones de datos desbalanceados.

Además, estudios como los de [7], han demostrado que el transfer learning, empleado en este estudio a través del uso de ResNet, permite mejorar la precisión de los modelos en conjuntos de datos limitados, sin necesidad de grandes volúmenes de imágenes de entrenamiento. La capacidad del modelo para alcanzar un rendimiento alto en la clasificación de cáncer de piel con un conjunto de entrenamiento de 20,265 imágenes y validación con 5,066 imágenes sugiere que el enfoque basado en deep learning es adecuado para este tipo de problemas de clasificación médica.

A pesar de los resultados favorables, existen ciertos desafíos que deben considerarse. La sensibilidad del modelo a características específicas de las imágenes y la posible variabilidad en las predicciones para distintos casos clínicos sugieren que aún puede haber margen de mejora en términos de generalización y robustez. Investigaciones como las de [32] han señalado la importancia de utilizar enfoques multimodales que combinen imágenes clínicas con otros datos biomédicos (como información genética o antecedentes clínicos del paciente) para mejorar la precisión de los modelos predictivos.

5. Conclusiones

El La aplicación web desarrollada para la detección de cáncer de piel, basada en el modelo ResNet, alcanzó una precisión del 94%, tal como se muestra en el promedio global de la Tabla 5. Estos resultados indican la capacidad de las redes neuronales convolucionales

(CNN) para procesar imágenes dermatoscópicas y clasificar lesiones cutáneas en diferentes categorías clínicas. La incorporación de este tipo de modelos en herramientas digitales permite automatizar el análisis de imágenes médicas, con posibles aplicaciones en contextos clínicos y de apoyo diagnóstico.

Se identificaron y analizaron diversas técnicas y algoritmos, como la segmentación de imágenes, la detección de bordes y el uso de modelos de redes neuronales convolucionales (CNN). Estas técnicas se evaluaron en términos de su precisión, eficiencia y aplicabilidad en la detección de tipos de cáncer de piel, proporcionando una base sólida para la implementación en la aplicación web.

Los modelos de CNN fueron entrenados y evaluados utilizando un dataset de imágenes de tipos de cáncer de piel y lesiones benignas. Los resultados mostraron una alta precisión en la detección, validando la eficacia de este enfoque. Además, se identificaron áreas de mejora, como el aumento de la diversidad del conjunto de datos de entrenamiento para mejorar la generalización del modelo.

El modelo fue entrenado para identificar ocho tipos de lesiones cutáneas relacionadas con el cáncer de piel, además la interfaz web implementada permite su despliegue en plataformas digitales disponibles para los usuarios. Entre las principales limitaciones del presente trabajo, tenemos que el modelo no ha sido validado con datos clínicos externos o en entornos hospitalarios.

Contribuciones de los autores

Conceptualización: F.K.F., N.M.L. y F.J.L.; curación de datos: F.K.F.; análisis formal: N.M.L.; adquisición de financiamiento: N.M.L.; investigación: F.K.F.; metodología: F.K.F., N.M.L.; administración de proyectos: F.J.L.; recursos: F.J.L.; software: F.K.F.; supervisión: N.M.L.; validación: F.J.L.; visualización: F.J.L.; escritura – borrador original: F.K.F. y N.M.L.; escritura – revisión y edición: F.K.F. y N.M.L. Todos los autores han leído y aprobado la versión publicada del manuscrito.

Conflicto de Interés

Los autores no reportan conflictos de interés relacionados con esta investigación.

Declaración sobre el uso de Inteligencia Artificial Generativa

No se utilizó inteligencia artificial generativa en la preparación de este artículo.

Referencias

- [1] A. Naeem, M. S. Farooq, A. Khelifi, y A. Abid, "Malignant Melanoma Classification Using Deep Learning: Datasets, Performance Measurements, Challenges and Opportunities," IEEE Access, vol. 8, pp. 110575–110597, 2020, doi: <https://doi.org/10.1109/ACCESS.2020.3001507>.
- [2] H. Zanddizari, N. Nguyen, B. Zeinali, y J. M. Chang, "A new preprocessing approach to improve the performance of CNN-based skin lesion classification," Med. Biol. Eng. Comput., vol. 59, no. 5, pp. 1123–1131, abr. 2021, doi: <https://doi.org/10.1007/s11517-021-02355-5>.

- [3] A. Esteva et al., "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115–118, ene. 2017, doi: <https://doi.org/10.1038/nature21056>.
- [4] S. Kaymak, P. Esmaili, y A. Serener, "Deep Learning for Two-Step Classification of Malignant Pigmented Skin Lesions," 2018 14th Symp. Neural Networks Appl. NEUREL 2018, pp. 1–6, nov. 2018, doi: <https://doi.org/10.1109/NEUREL.2018.8587019>.
- [5] A. K. Morales, D. R. Lepe, y J. F. Díaz, "Redes Neuronales Convolucionales para Detección de Carcinoma Basocelular (Cáncer de Piel) por Medio de Imágenes para Pacientes Adultos en la Región Facial," *Ciencia Latina*, vol. 8, no. 4, pp. 582-599, ago. 2024, doi: https://doi.org/10.37811/cl_rcm.v8i4.12300.
- [6] Y. Fontaine Pérez, D. Sotolongo Díaz, I. Espinosa Carballosa, M. Roque Morgado, M. Montes de Oca Álvarez, y M. Figueroa García, "Utilidad del dermatoscopio en la correlación clínica e histológica de nevus pigmentados," *Rev Cubana Inv Bioméd*, vol. 40, no. 2, ago. 2021.
- [7] B. S. Ankad, S. S. Mukherjee, y B. Pralhadrao, *Dermoscopy - Histopathology Correlation*. Springer Singapore, 2021. doi: <https://doi.org/10.1007/978-981-33-4638-3>.
- [8] S. Rajarajeswari, J. Prassanna, M. Abdul Quadir, J. Christy Jackson, S. Sharma, y B. Rajesh, "Skin Cancer Detection using Deep Learning," *Res. J. Pharm. Technol.*, vol. 15, no. 10, pp. 4519–4525, oct. 2022, doi: <https://doi.org/10.52711/0974-360X.2022.00758>.
- [9] I. H. Sarker, "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions," *SN Comput. Sci.*, vol. 2, no. 6, ago. 2021, doi: <https://doi.org/10.1007/s42979-021-00815-1>.
- [10] A. A. Adegun y S. Viriri, "Deep learning-based system for automatic melanoma detection," *IEEE Access*, vol. 8, pp. 7160–7172, 2020, doi: <https://doi.org/10.1109/ACCESS.2019.2962812>.
- [11] C. K. Juan et al., "Deep convolutional neural network with fusion strategy for skin cancer recognition: model development and validation," *Sci. Rep.*, vol. 13, no. 1, oct. 2023, doi: <https://doi.org/10.1038/s41598-023-42693-y>.
- [12] K. Thurnhofer-Hemsi y E. Domínguez, "A Convolutional Neural Network Framework for Accurate Skin Cancer Detection," *Neural Process. Lett.*, vol. 53, no. 5, pp. 3073–3093, oct. 2021, doi: <https://doi.org/10.1007/s11063-020-10364-y>.
- [13] K. M. Hosny, M. A. Kassem, y M. M. Foad, "Skin Cancer Classification using Deep Learning and Transfer Learning," 2018 9th Cairo Int. Biomed. Eng. Conf. CIBEC 2018 - Proc., pp. 90–93, dic. 2018, doi: <https://doi.org/10.1109/CIBEC.2018.8641762>.
- [14] C. Schröer, F. Kruse, y J. M. Gómez, "A systematic literature review on applying CRISP-DM process model," *Procedia Comput. Sci.*, vol. 181, pp. 526–534, 2021, doi: <https://doi.org/10.1016/j.procs.2021.01.199>.
- [15] A. Maranhão, "Skin Lesion Analysis Dataset," Kaggle, 2020. [En línea]. Disponible en: <https://www.kaggle.com/datasets/andrewmvd/isic-2019/data>
- [16] P. Tschandl, C. Rosendahl, y H. Kittler, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions," *Sci. Data*, vol. 5, no. 1, ago. 2018, doi: <https://doi.org/10.1038/sdata.2018.161>.
- [17] C. Hernández-Pérez et al., "BCN20000: Dermoscopic Lesions in the Wild," *Sci. Data*, vol. 11, no. 1, jun. 2024, doi: <https://doi.org/10.1038/s41597-024-03387-w>.
- [18] J. Muñoz-Ordóñez, C. Cobos, M. Mendoza, E. Herrera-Viedma, F. Herrera, y S. Tabik, "Framework for the Training of Deep Neural Networks in TensorFlow Using Metaheuristics, *Lecture Notes in Computer Science*. Springer International Publishing, pp. 801-811, 2018. doi: https://doi.org/10.1007/978-3-030-03493-1_83.
- [19] V. R. Joseph, "Optimal ratio for data splitting," *Statistical Analysis*, vol. 15, no. 4, pp. 531-538, abr. 2022, doi: <https://doi.org/10.1002/sam.11583>.

- [20] M. Anour Naoui, "Transferir el enfoque de aprendizaje basado en la detección del cáncer de piel," vol. 16, no. 4, pp. 1–17, dic. 2022. Disponible en: <http://ref.scielo.org/k754wb>.
- [21] F. Farías Rivera y N. M. Loja Mora, "Entrenamiento para la detección de cáncer de piel," ago. 13, 2025, Zenodo. doi: <https://doi.org/10.5281/ZENODO.16827475>.
- [22] S. E. Cerminara et al., "Diagnostic performance of augmented intelligence with 2D and 3D total body photography and convolutional neural networks in a high-risk population for melanoma under realworld conditions: A new era of skin cancer screening?," *European Journal of Cancer*, vol. 190, p. 112954, sep. 2023, doi: <https://doi.org/10.1016/j.ejca.2023.112954>.
- [23] S. Kim, E. Gaibor, y D. Haehn, "Web-based Melanoma Detection," 2024, arXiv. doi: <https://doi.org/10.48550/ARXIV.2403.14898>.
- [24] D. Palacios-Martínez y R. A. Díaz-Alonso, "Dermatoscopia para principiantes (I): características generales," *Semergen*, vol. 43, no. 3, pp. 216–221, abr. 2017, doi: <https://doi.org/10.1016/j.semerg.2015.11.009>.
- [25] O. Attallah, "Skin cancer classification leveraging multi-directional compact convolutional neural network ensembles and gabor wavelets," *Sci. Rep.*, vol. 14, no. 1, sep. 2024, doi: <https://doi.org/10.1038/s41598-024-69954-8>.
- [26] C. V. Niño-Rondón, D. A. Castellano-Carvajal, S. A. Castro-Casadiegos, B. Medina-Delgado, y K. C. Puerto-López, "HASCC: A Hybrid Algorithm for Skin Cancer Classification," *Rev. Fac. Ing.*, vol. 33, no. 67, p. e16943, mar. 2024, doi: <https://doi.org/10.19053/upte.01211129.v33.n67.2024.16943>.
- [27] J. Guillermo Guarnizo, S. Riaño Borda, E. C. Camacho Poveda, y A. Mateus Rojas, "Automated Malignant Melanoma Classification Using Convolutional Neural Networks," *Cien. Ing. Neogranadina*, vol. 32, no. 2, pp. 171–185, dic. 2022, doi: <https://doi.org/10.18359/rcin.6270>.
- [28] W. Gouda, N. U. Sama, G. Al-Waakid, M. Humayun, y N. Z. Jhanjhi, "Detection of Skin Cancer Based on Skin Lesion Images Using Deep Learning," *Healthcare*, vol. 10, no. 7, p. 1183, jun. 2022, doi: <https://doi.org/10.3390/healthcare10071183>.
- [29] A. Bello, S. C. Ng, y M. F. Leung, "Skin Cancer Classification Using Fine-Tuned Transfer Learning of DENSENET-121," *Applied Science*, vol. 14, no. 17, p. 7707, ago. 2024, doi: <https://doi.org/10.3390/app14177707>.
- [30] O. Akinrinade y C. Du, "Skin cancer detection using deep machine learning techniques," *IntelligenceBased Medicine*, vol. 11, p. 100191, 2025, doi: <https://doi.org/10.1016/j.ibmed.2024.100191>.
- [31] A. T. Ibrahim, M. Abdullahi, A. F. Donfack Kana, M. T. Mohammed, y I. H. Hassan, "Categorical classification of skin cancer using a weighted ensemble of transfer learning with test time augmentation Aliyu," *Data Sci. Manag.*, vol. 8, no. 2, pp. 174–184, jun. 2025, doi: <https://doi.org/10.1016/j.dsm.2024.10.002>.
- [32] S. A. Alshawhi y G. F. K. Al Musawi, "Skin Cancer Image Detection and Classification by CNN based Ensemble Learning," *IJACSA*, vol. 14, no. 5, 2023, doi: <https://doi.org/10.14569/IJACSA.2023.0140575>.