

Inteligencia artificial para un diagnóstico accesible en la identificación del melanoma y otras lesiones

Artificial intelligence for accessible diagnosis in the identification of melanoma and other skin lesions

Verónica Angélica Villalobos Romo^{1a} , Soledad Vianey Torres Argüelles^{1a} , José David Díaz Román^{1b}  

^{1a}{Departamento de Ingeniería Industrial y Manufactura}, ^{1b}{Departamento de Ingeniería Eléctrica y Computación}, Instituto de Ingeniería y Tecnología, Universidad Autónoma de Ciudad Juárez, Ciudad Juárez, Chihuahua, México

RESUMEN

El objetivo de este proyecto de innovación social es generalizar el acceso a herramientas de diagnóstico precisas, promoviendo la implementación de sistemas de detección temprana en entornos clínicos con recursos limitados. Desarrollar sistemas de aprendizaje profundo para mejorar la precisión de la detección temprana del melanoma que se considera una de las formas más agresivas de cáncer de piel, enfatizados en la necesidad de un diagnóstico preciso para reducir la mortalidad. A través del aprendizaje profundo y el aprendizaje por transferencia, el sistema identifica lesiones cutáneas por medio de imágenes dermatoscópicas, apoyándose en Redes Neuronales Convolucionales (RNC) entrenadas para la extracción de características de imágenes. Este enfoque permite aprovechar el conocimiento preexistente en los modelos RNC para mejorar la eficiencia y precisión de la identificación del melanoma. Además, al reducir la necesidad de procedimientos médicos invasivos y optimizar el uso de recursos en sistemas de salud con infraestructura limitada, el proyecto contribuye a la sostenibilidad del cuidado de la salud, fomentando diagnósticos más accesibles y precisos. La metodología de desarrollo es esencial y se presenta en este trabajo, con la expectativa de que la mejora en las capacidades de detección del melanoma tenga un impacto positivo en la salud pública y en la sostenibilidad a largo plazo.

PALABRAS CLAVE: cáncer; melanoma; diagnóstico; aprendizaje profundo; redes neuronales convolucionales.

ABSTRACT

The objective of this social innovation project is to generalize access to accurate diagnostic tools by promoting the implementation of early detection systems in clinical settings with limited resources. The aim is to develop deep learning systems to improve the accuracy of early melanoma detection, which is considered one of the most aggressive forms of skin cancer, emphasizing the need for precise diagnosis to reduce mortality. Through deep learning and transfer learning, the system identifies skin lesions using dermatoscopic images, leveraging pre-trained convolutional neural networks (CNNs) for feature extraction. Transfer learning is used to adapt the specific task of classifying pigmented skin lesions. This approach enables the use of pre-existing knowledge in CNN models to enhance the efficiency and accuracy of melanoma identification. Furthermore, by reducing the need for invasive medical procedures and optimizing resource use in healthcare systems with limited infrastructure, the project contributes to the sustainability of healthcare, promoting more accessible and accurate diagnoses. The development methodology is crucial and is presented in this work, with the expectation that improvements in melanoma detection capabilities will have a positive impact on public health and long-term sustainability.

KEYWORDS: cancer; melanoma; diagnosis; Deep Learning; Convolutional Neural Networks.

Correspondencia:

DESTINATARIO: José David Díaz Román

INSTITUCIÓN: Universidad Autónoma de Ciudad Juárez /
Instituto de Ingeniería y Tecnología

DIRECCIÓN: Ave. del Charro núm. 450 norte, col. Partido
Romero, C. P. 31310, Ciudad Juárez, Chihuahua, México

CORREO ELECTRÓNICO: david.roman@uacj.mx

Fecha de recepción: 9 de junio de 2025. **Fecha de aceptación:**
10 de julio de 2025. **Fecha de publicación:** 31 de agosto de
2025.



Licencia Creative Commons



I. INTRODUCCIÓN

El melanoma es el tipo más agresivo y letal de cáncer de piel. La radiación ultravioleta (UV) del sol puede causar graves efectos en la salud de la piel si se expone de manera excesiva sin protección, desde quemaduras solares hasta el aumento en el riesgo de desarrollar cáncer [1], [2]. El cáncer de piel, que involucra tipos como el carcinoma de células basales, el carcinoma de células escamosas y el melanoma, es una gran preocupación por la salud y los costos. A diferencia de otros males, este se propaga uniformemente en todo el mundo, principalmente debido a la radiación UV del sol [3].

El cáncer de piel es un problema creciente en México, que afecta a personas de todas las edades y tipos de piel, debido a la intensa luz solar en el país, la falta de conciencia sobre las medidas de protección y las limitaciones en la difusión de información sobre la importancia del cuidado de la piel. “Es un panorama amplio”, advierte el Dr. Rodrigo Roldán Marín, jefe de la Clínica de Oncología de la Facultad de Medicina de la UNAM, al explicar las diferencias de riesgo entre los diferentes tipos de cáncer y la importancia de la detección temprana. Solo de melanoma se reportan 2000 casos anuales, siendo responsable del 80 % de los decesos por cáncer de piel [4].

Las regiones con las tasas más altas de frecuencia y mortalidad por cáncer de piel en México incluyen Ciudad de México, Baja California Sur, Jalisco, Nuevo León y Colima. Tan solo tres de estos estados: Guerrero, Nuevo León y Zacatecas, presentan incrementos en la frecuencia de más del 250 %. Actualmente, el melanoma ocupa el tercer lugar en incidencia entre los tipos de cáncer en el México, con un incremento del 500 % en los casos reportados, según estadísticas del Instituto Nacional de Cancerología [4], [5].

El 23 de mayo se celebra el Día Mundial del Melanoma Cutáneo para concienciar al público sobre la importancia de esta enfermedad, su potencial de muerte, además de la necesidad de una detección temprana para su tratamiento [6].

A. FACTORES Y CAUSAS DEL CÁNCER DE PIEL

El cáncer de piel está fuertemente relacionado con varios factores de riesgo, uno de los cuales es la exposición al sol. Estar expuesto prolongada o intermitentemente a

los rayos UV se ha relacionado con un mayor índice de riesgo de este cáncer, especialmente entre las 10 a. m. y las 4 p. m. Las quemaduras solares durante la infancia son aun más dañinas, ya que incrementan de forma significativa la probabilidad de padecer cáncer de piel en la edad adulta. No tomar medidas preventivas, como el uso de protector solar o la ropa adecuada para el caso de las zonas expuestas al sol, aumenta el riesgo [7], [8].

Otro factor que juega un papel importante es el fenotipo. Las personas con piel clara, ojos claros y cabello rubio o pelirrojo corren un mayor riesgo porque tienen niveles más bajos de melanina, el pigmento que protege contra el daño de los rayos UV. Estos rasgos genéticos los hacen más susceptibles a la radiación de los rayos UV [8], [9].

Finalmente, los antecedentes familiares y ciertos factores del estilo de vida también contribuyen a un mayor riesgo de desarrollar cáncer de piel. El historial familiar de la enfermedad o la presencia de lunares displásicos (lunares anormales) son factores de advertencia importantes [10]. De manera similar, los cambios en el estilo de vida, como pasar más tiempo al aire libre, la tendencia a tomar el sol y el agotamiento de la capa de ozono, han aumentado la incidencia del cáncer de piel en las últimas décadas. Estos factores ambientales, combinados con una mayor exposición al sol, enfatizan la importancia de tomar precauciones para minimizar los riesgos [10].

B. MÉTODOS DE DIAGNÓSTICO

El diagnóstico temprano es crucial para mejorar las tasas de supervivencia, y los métodos principales incluyen técnicas no invasivas, como la inspección visual, e invasivas, como la biopsia, que ayudan a diferenciar entre lesiones benignas y malignas [11]. Entre las técnicas de exploración visual utilizadas para el diagnóstico de melanoma se encuentra la regla ABCDE, evaluando las características de tamaño, color y forma [12], además del método de siete puntos que toma en consideración cambios en las lesiones pigmentadas [13], [14], [15]. La regla de Menzies, por otro lado, se basa en la evaluación de características dermatoscópicas, dividiéndolas en criterios positivos y negativos para facilitar el diagnóstico del melanoma [16].

En lesiones sospechosas, el método más seguro es la biopsia, que es un procedimiento médico invasivo que

se basa en la toma de una muestra de la lesión cutánea para ser examinada bajo el microscopio y determinar si es benigna o maligna [13], lo que requiere equipo especializado, anestesia local y personal capacitado. Este procedimiento es especialmente necesario cuando en una lesión pigmentada se observa un cambio de color, tamaño o forma, ya que estas modificaciones pueden ser indicativos de melanoma o de otro tipo de cáncer de piel. El análisis de una biopsia puede tardar días o incluso semanas, dependiendo de la carga de trabajo del laboratorio. Este método es indispensable para confirmar el diagnóstico y proporcionar el tratamiento adecuado [14], [15].

C. DIFICULTADES EN LOS MÉTODOS DE DIAGNÓSTICO

Las dificultades en el diagnóstico del cáncer de piel, especialmente el melanoma, se deben a varios factores complejos. Uno de los principales desafíos es la variabilidad clínica de las lesiones, que pueden parecerse a otros problemas dermatológicos benignos [9]. Otro factor que afecta la precisión del diagnóstico es el nivel de experiencia y formación del especialista, pues una menor destreza y habilidad para la interpretación precisa de las lesiones puede variar el diagnóstico [16], [17]. Esto complica su identificación temprana, que es crucial para el tratamiento exitoso. Las herramientas de diagnóstico, como la dermatoscopia, mejoran la capacidad para detectar melanomas en etapas tempranas, pero al mismo tiempo han generado preocupaciones debido al sobrediagnóstico y el tratamiento excesivo de tumores clínicamente insignificantes [18].

D. TIPOS DE LESIONES DE PIEL

Existen varias lesiones pigmentadas en la piel que pueden ser benignas, pero a veces son mal diagnosticadas o confundidas con lesiones malignas debido a sus características similares. A continuación, algunos ejemplos de estas lesiones benignas y su posible confusión con cáncer de piel:

- **Nevo melanocítico (lunar común):** son acumulaciones benignas de melanocitos (células productoras de pigmento). Aunque la mayoría son inofensivos, algunos nevos displásicos o atípicos pueden parecer sospechosos debido a su forma, color o tamaño irregular, lo que puede llevar a una biopsia para descartar melanoma. Sin embargo, la mayoría de estos nevos son benignos.

- **Queratosis seborreica:** son lesiones pigmentadas que comúnmente son confundidas con cáncer de piel, pero son crecimientos benignos que aparecen en la superficie de la piel. Tienen una textura rugosa o verrugosa y a menudo se diagnostican erróneamente como melanoma debido a su apariencia oscura e irregular.
- **Melanoma:** es la forma más peligrosa de cáncer de piel. Se produce de melanocitos (células productoras de pigmentos) de origen dérmico que se encuentran en diversas partes del cuerpo.
- **Dermatofibroma:** es un nódulo benigno de la piel que puede aparecer pigmentado. Su firmeza al tacto y su coloración marrón pueden hacer que se confunda con lesiones malignas, aunque suele ser inofensivo [13], [19], como se puede observar en la [Figura 1](#).




Figura 1. Lesiones pigmentadas de la piel (HAM10000) [20].

Es crucial que cualquier lesión pigmentada sospechosa sea evaluada por un dermatólogo, quien puede recomendar una biopsia para asegurar un diagnóstico preciso y descartar la presencia de cáncer de piel, como el melanoma [15].

II. METODOLOGÍA

En esta sección se expone el procedimiento seguido para el desarrollo de un sistema de diagnóstico de cáncer de piel mediante imágenes. Inicialmente, se seleccionó el repositorio después de hacer una revisión

bibliográfica para identificar una base de imágenes que contuviera casos clínicos apropiadamente diagnosticados y categorizados por personal profesional en la materia. Posteriormente, se balancearon los datos usando técnicas de aumento de datos para incrementar la representatividad de las clases.

Se utilizó la arquitectura de la red neuronal convolucional con ajuste fino para la extracción de características y dichas arquitecturas convolucionales se tomaron de las aplicaciones de Keras [21]. Con las redes se obtienen características representativas de las imágenes seleccionadas. Luego, se aplicó la técnica de reducción de características mediante análisis de componentes principales (PCA) [22] y, finalmente, un clasificador logístico predice cada imagen a la clase correspondiente. Cabe resaltar que los pasos anteriores se muestran resumidos en la [Figura 2](#).




Figura 2. Etapas de la metodología.

A continuación se presenta un breve resumen de cada paso de la metodología descrita en la [Figura 2](#).

A. SELECCIÓN DE BASES DE DATOS: BASE DE DATOS HAM10000

Las redes neuronales artificiales en tareas de clasificación requieren una gran cantidad de datos previamente etiquetados. Cada imagen debe contar con una etiqueta que indique claramente la clase o el objeto que contiene, lo cual es fundamental para que el modelo aprenda a distinguir entre diferentes categorías. Dado lo anterior, la base de datos HAM10000 fue identificada como adecuada para la realización de este proyecto. HAM10000, cuyo nombre es un acrónimo de “Human Against Machine with 10000 training images”, es un conjunto de datos de imágenes dermatoscópicas recopilado por la Universidad de Harvard [20], [23] que contiene 10 015

imágenes de diversas enfermedades y afecciones de la piel, con todas las imágenes clasificadas previamente por dermatólogos y otros profesionales médicos para garantizar la precisión y calidad de las etiquetas. Una de las razones por las que este es un conjunto ideal es el hecho de que contiene una diversidad de lesiones cutáneas.

Las imágenes en la base de datos incluyen una amplia variedad de lesiones cutáneas, lo que permite a los modelos aprender a diferenciar entre múltiples tipos de afecciones. Además, la gran cantidad de imágenes le da al modelo suficiente generalización de ejemplos para clasificar correctamente y tener un buen desempeño en la identificación de nuevas imágenes.

En la [Figura 3](#) se muestra la cantidad de imágenes que contiene la base de datos HAM10000, abarcando siete tipos de lesiones dermatológicas, etiquetadas y validadas por expertos.




Figura 3. Clasificación y número de imágenes de lesiones contenidas en HAM10000 [20].

A continuación, se explica brevemente cada una de las lesiones:

- **Dermatofibroma (df):** con 115 imágenes, es un tumor benigno de la piel, generalmente inofensivo, causado por una reacción fibrosa del tejido conectivo. Sus características son: pequeño nódulo firme, normalmente marrón o rojizo, que puede sentirse debajo de la piel.
- **Lesiones vasculares (vasc):** con 142 imágenes, estas incluyen emangiomas, angiomas y telangiectasias, las cuales son alteraciones en los vasos sanguíneos de la piel. Sus características son: lesiones rojizas o violáceas, algunas veces elevadas, que sangran fácilmente.

- Queratosis actínica y carcinoma intraepitelial / enfermedad de Bowen (akiec): con 327 imágenes, es una lesión precancerosa que se desarrolla debido a la exposición prolongada al sol y que puede progresar a carcinoma escamoso si no se trata. Sus características: parches ásperos, escamosos o costrosos en la piel, de color rojo o marrón.
- Carcinoma de células basales (bcc): con 514 imágenes, es el tipo de cáncer de piel más común y de crecimiento lento. Rara vez hace metástasis, pero puede invadir tejidos cercanos. Sus características: lesión perlada o brillante, con vasos sanguíneos visibles; a veces tiene una úlcera central.
- Lesiones benignas similares a queratosis (bkl): con 1099 imágenes, es un grupo de lesiones benignas que incluyen la queratosis seborreica, queratosis líquen y queratosis solar. Sus características: superficie rugosa, pigmentada o con apariencia verrugosa. No representan riesgo de cáncer.
- Melanoma (mel): con 1113 imágenes, es un tipo de cáncer de piel más agresivo, con alta probabilidad de metástasis si no se detecta a tiempo. Sus características: manchas asimétricas, con bordes irregulares y colores mixtos (negro, marrón, azul, rojo). Suelen cambiar de tamaño o sangrar.
- Nevo melanocítico (nv): con 6705 imágenes, son lunares comunes y benignos formados por acumulaciones de melanocitos. Sus características: son redondos, simétricos, de color uniforme (marrón, negro o piel). En general, son inofensivos.

Como se puede observar en la [Figura 3](#), hay un problema de desbalanceo de clases significativo en la base de datos HAM10000. Por ejemplo, la clase de imágenes de nevus contiene un total de 6705 imágenes, mientras que de melanoma son 1113. Esto crea un problema considerable para los algoritmos de clasificación, ya que los resultados tienden a sesgar hacia las clases con un número mayor de ejemplos, generando un rendimiento desigual para la detección de melanoma.

B. ORGANIZACIÓN Y PROCESAMIENTO DE DATOS

La base de datos contiene las imágenes en dos archivos .zip, junto con un archivo de metadatos que incluye información detallada sobre cada imagen, como el nom-

bre del archivo, diagnóstico, método de diagnóstico, edad, sexo del individuo y la ubicación de la lesión.

Para organizar los datos, cada imagen se colocó en la carpeta correspondiente según su diagnóstico, asegurando que cada tipo de lesión estuviera correctamente categorizado.

Posteriormente, todas las imágenes fueron redimensionadas a un tamaño uniforme, garantizando que la Red Neural Convolutiva (RNC) pueda procesarlas de manera consistente.

C. BALANCEO DE DATOS

Para enfrentar este problema, que se refiere al desbalanceo entre las clases, fue necesario aplicar la técnica de aumento de datos (*data augmentation*) [24], [25], [26], dado que permiten crear nuevas variaciones de las imágenes existentes [26], [27]. De esta manera, se incrementa la cantidad de datos con la clase menos representada, como el dermatofibroma, pero a la vez ayuda a mejorar la capacidad de generalización del modelo, puesto que permitirá que este pueda reconocer patrones y características más diversificados.

En este caso, para realizar pruebas preliminares se tomaron de forma aleatoria 500 muestras de las clases con mayor cantidad de imágenes y se aplicó *data augmentation* para las clases con menor número de imágenes, con el fin de tener un conjunto de datos más equilibrado.

De esta forma, el sistema se entrenó de una manera más equilibrada y, en consecuencia, su rendimiento en la clasificación de las imágenes de melanoma se verá incrementado a pesar del desbalanceo existente de modo inicial en la base de datos.

D. SELECCIÓN DE ARQUITECTURA PREENTRENADA

El lenguaje de programación utilizado fue Python, ya que cuenta con librerías como Keras y contiene RNC, modelos preentrenados como ResNet, VGG, Inception y Xception, entre otros [28]. Estos modelos son muy populares y útiles para tareas como la clasificación de imágenes, segmentación, detección de objetos y más. Debido a que los modelos vienen preentrenados en el conjunto de datos ImageNet, que contiene millones de imágenes clasificadas en 1000 categorías. Esto permite usar los modelos para tareas de clasificación y extrac-

ción de características sin necesidad de entrenarlos desde cero. Con esto, es posible seleccionar qué parte del modelo utilizar (por ejemplo, con o sin las capas de clasificación finales), personalizando fácilmente los modelos preentrenados, ya sea agregando nuevas capas, ajustando el número de clases o aplicando ajuste (*fine-tuning*) para adaptarlo a tareas específicas. Así, se puede utilizar cualquier capa intermedia de estos modelos como extractor de características y luego aplicar un clasificador como SVM, Random Forest o capas densas adicionales [29].

E. EXTRACCIÓN DE CARACTERÍSTICAS Y APRENDIZAJE POR TRANSFERENCIA

En el aprendizaje por transferencia se utiliza un modelo preentrenado en una tarea específica (como clasificación de imágenes en ImageNet) y luego se ajusta para una tarea diferente pero relacionada [30], tal como la clasificación de lesiones en imágenes médicas [31], [32], [33]. Para extraer características utilizando una red preentrenada, proceso que se conoce como *feature extraction*, se suelen utilizar las capas anteriores a la capa de clasificación final [34], como se muestra en la Figura 4.




Figura 4. Extracción de características con arquitectura VGG16. Adaptada de [35].

Este proceso se explica a continuación:

- Seleccionar una red preentrenada: se utilizan redes como VGG16, ResNet, Inception, o EfficientNet, que ya están entrenadas en un gran conjunto de datos como ImageNet.
- Congelar las capas: usualmente, se congelan las capas convolucionales que actúan como un extractor de características genérico. Solo se hace *fine-tuning*.

- Eliminar la última capa de clasificación: esta capa está ajustada a una tarea específica, como clasificar en 1000 clases de ImageNet, por lo que no es necesaria. En las redes comunes, esta capa suele ser una capa *fully connected* o de tipo softmax. En su lugar, se utiliza la salida de una de las últimas capas convolucionales o de *pooling*.

F. REDUCCIÓN DE CARACTERÍSTICAS

Con el objetivo de reducir características, se aplicó PCA para simplificar el conjunto de datos de alta dimensionalidad [22], [36] que sale de la RNC, transformándolo en un conjunto con menos dimensiones, mientras se preserva la mayor cantidad posible de la información relevante. Específicamente, PCA busca transformar las características originales en nuevas variables llamadas componentes principales, que son combinaciones lineales de las características originales, ordenadas por la cantidad de varianza (información) que explican. De tal manera, se evita el sobreajuste en el modelo de aprendizaje automático, ya que esto significa que el modelo se ajusta demasiado bien a los datos de entrenamiento y no generaliza bien en nuevos datos. Al reducir la dimensionalidad con PCA, se eliminan las características redundantes para evitar el sobreajuste y así entrenar un clasificador.

G. ENTRENAR UN CLASIFICADOR

Cuando se entrena un clasificador utilizando las características que fueron extraídas de la RNC y reducidas con PCA se mejora el rendimiento del sistema en términos de precisión, eficiencia computacional y generalización, al simplificar los datos y enfocarse en la información relevante. Se puede utilizar diferentes clasificadores y en este caso se eligió Máquina de Soporte Vectorial (SVM) por ser efectiva en espacios de alta dimensión y funciona bien cuando hay una separación clara entre las clases [37].

Después de la reducción de características, el conjunto de características es menos ruidoso, lo que permite que el clasificador se concentre en los patrones más relevantes. A su vez, esto permite al clasificador descubrir los patrones importantes en los datos [38]. Además, al entrenar un clasificador con un número menor de características, es decir, menor dimensionalidad después de PCA, se posibilitó que el sistema se entrenara más rápido y así consumiera menos recursos computacionales comparado con usar todas las características originales.

Esto es especialmente importante al trabajar con grandes conjuntos de datos, como imágenes o datos de alta dimensión. Finalmente, menos características también significan predicciones más rápidas.

III. RESULTADOS PRELIMINARES

Como resultado de la metodología que se describió anteriormente se obtuvieron los datos, aplicando las técnicas de aprendizaje profundo y aprendizaje por transferencia a tres RNC: VGG16, VGG19 y ResNet50.

Este análisis fue el paso inicial para validar la metodología propuesta, ya que esta aún se encuentra en proceso de ajuste y optimización.

Con los resultados de la aplicación de la metodología a los modelos mencionados anteriormente para la extracción de características y aplicando el clasificador al conjunto de entrenamiento se obtuvo la [Tabla 1](#), la cual muestra la relación entre los valores predichos y los reales para así medir la exactitud, la precisión general del sistema, y sus promedios.

TABLA 1
MÉTRICAS DE LAS RNC OBTENIDAS CON LA METODOLOGÍA PROPUESTA

RNC	EXACTITUD	MACRO PROMEDIO			PROMEDIO PONDERADO		
		PRECISIÓN	SENSIBILIDAD	F1-SCORE	PRECISIÓN	SENSIBILIDAD	F1-SCORE
VGG16	0.95	0.95	0.95	0.95	0.95	0.95	0.95
VGG19	0.88	0.87	0.88	0.87	0.88	0.88	0.88
RESNET50	0.99	0.99	1.00	0.99	1.00	0.99	1.00

En la [Tabla 1](#) se muestran los resultados preliminares de las pruebas que se realizaron aplicando la metodología propuesta. La cual contiene los siguientes datos:

- Exactitud (*accuracy*): es la exactitud que obtuvo el sistema.
- Macro promedio (*macro avg*): el macro promedio calcula el promedio de cada métrica (precisión, sensibilidad y F1-score) de manera simple, sin tener en cuenta el desequilibrio de clases. Calcula cada métrica para cada clase y para luego promediar los valores.
- Promedio ponderado (*weighted avg*): es el promedio ponderado, toma en cuenta el número de muestras en cada clase. Calcula cada métrica (precisión, sensibilidad, y F1-score) para cada clase y para promediar estos valores ponderados por el número de muestras de cada clase.
- Sensibilidad (*recall*): indica el porcentaje de casos positivos que el sistema ha logrado predecir correctamente.
- El F1-score esta una métrica combina precisión (*precision*) y sensibilidad (*recall*) en un solo valor, proporcionando una medida balanceada de la precisión del modelo y determina la capacidad

para identificar correctamente los positivos y evitar los falsos positivos y falsos negativos.

IV. CONCLUSIONES

Los resultados mostrados en la sección anterior son el análisis inicial de la metodología aplicada para clasificar imágenes de lesiones. Aunque las métricas preliminares presentadas anteriormente validen la primera etapa de la técnica aplicada, también destacan la necesidad de algunos ajustes y optimizaciones en el futuro.

Con base en la extracción de características, se presentó las tres RNC previamente entrenadas. A partir de la metodología de Transfer Learning, estas redes permitieron a esta técnica capturar patrones muy complejos en las imágenes que luego se simplificaron a través de reducción de dimensionalidad, convirtiendo la mayor parte de la entrada de dimensionalidad en ruido. El clasificador SVM construido a partir de esta información distingue con mayor precisión entre los distintos tipos de lesiones.

Con estos resultados se logró identificar mejoras y próximos ajustes en el rendimiento del modelo, con la finalidad de desarrollar un sistema de diagnóstico preciso y confiable, para lograr obtener una herramienta que apoye a la sociedad en general, disminuyendo en un mediano plazo los efectos negativos de un diagnóstico tardío.

REFERENCIAS

- [1] A. C. Geller *et al.*, “Advancing Survivors Knowledge (ASK Study) of Skin Cancer Surveillance after Childhood Cancer: A Randomized Controlled Trial in the Childhood Cancer Survivor Study”, *J Clin Oncol*, vol. 41, n.º 12, pp. 2269-2280, abr. 2023, doi: [10.1200/JCO.22.00408](https://doi.org/10.1200/JCO.22.00408).
- [2] H. Sung *et al.*, “Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries”, *CA Cancer J Clin*, vol. 71, n.º 3, pp. 209-249, may. 2021, doi: [10.3322/caac.21660](https://doi.org/10.3322/caac.21660).
- [3] WHO, *The effect of occupational exposure to solar ultraviolet radiation on malignant skin melanoma and non-melanoma skin cancer: a systematic review and meta-analysis from the WHO/ILO joint estimates of the work-related burden of disease and injury*. Ginebra: World Health Organization, 2021.
- [4] J. F. Gallegos. “En verano, reforzar cuidados para reducir riesgos de cáncer de piel”. GOB.mx. Disponible: <https://www.gob.mx/imss/articulos/en-verano-reforzar-cuidados-para-reducir-riesgos-de-cancer-de-piel?idiom=es> (accedido: oct. 23, 2024).
- [5] A. Cámara-Salazar *et al.*, “Características individuales y por entidad federativa de la mortalidad por melanoma en México entre 2014 y 2018”, *Dermatol Rev Mex*, vol. 64, n.º 3, pp. 248-254, may. 2020.
- [6] J. F. Gallegos. “Día Mundial del Melanoma Cutáneo”. GOB.mx. Disponible: <https://www.gob.mx/imss/articulos/dia-mundial-del-melanoma-cutaneo?idiom=es> (accedido: oct. 23, 2024).
- [7] American Cancer Society. “Cáncer de piel tipo melanoma”. CANCER.net. <https://www.cancer.org/es/cancer/tipos/cancer-de-piel-tipo-melanoma.html> (accedido: ag. 23, 2025).
- [8] IARC, “Melanoma Awareness Month 2022”. IARC.who.int. <https://www.iarc.who.int/news-events/melanoma-awareness-month-2022/> (accedido: oct. 17, 2022).
- [9] C. Alonso-Belmonte, T. Montero-Vilchez, S. Arias-Santiago y A. Buendía-Eisman, “Situación actual de la prevención del cáncer de piel: una revisión sistemática”, *Actas Dermosifiliogr*, vol. 113, n.º 8, pp. 781-791, sept. 2022, doi: [10.1016/j.ad.2022.04.015](https://doi.org/10.1016/j.ad.2022.04.015).
- [10] Secretaría de Salud. “Falta de prevención y detección tardía ocasiona 30% de fallecimientos en pacientes con melanoma”. GOB.mx. <https://www.gob.mx/salud/prensa/196-falta-de-prevencion-y-deteccion-tardia-ocasiona-30-de-fallecimientos-en-pacientes-con-melanoma> (accedido: oct. 23, 2024).
- [11] Mayo Clinic. “Diagnóstico y tratamiento”. Cáncer de piel. <https://www.mayoclinic.org/es-es/diseases-conditions/skin-cancer/diagnosis-treatment/drc-20377608> (accedido: oct. 17, 2022).
- [12] D. N. H. Thanh, V. B. S. Prasath, L. M. Hieu y N. N. Hien, “Melanoma Skin Cancer Detection Method Based on Adaptive Principal Curvature, Colour Normalisation and Feature Extraction with the ABCD Rule”, *J Digit Imaging*, vol. 33, n.º 3, pp. 574-585, jun. 2020, doi: [10.1007/s10278-019-00316-x](https://doi.org/10.1007/s10278-019-00316-x).
- [13] P. Castañeda y J. E. Téllez, “El cáncer de piel, un problema actual”, *Rev. Fac. Med. (Méx.)*, vol. 59, n.º 2, pp. 6-14, mar./abr. 2016.
- [14] “Abordaje Diagnóstico del Melanoma Maligno”, catálogo maestro de guías de práctica clínica IMSS-547-1, Instituto Mexicano del Seguro Social, Ciudad de México, 2012. [En línea]. Disponible: <https://www.imss.gob.mx/sites/all/statics/guiasclinicas/547GRR.pdf>
- [15] I. Arellano, Saúl. *Lecciones de Dermatología*, 16.ª ed. México: McGraw Hill, 2015.
- [16] H. Kittler, H. Pehamberger, K. Wolff y M. Binder, “Diagnostic accuracy of dermoscopy”, *Lancet Oncol*, vol. 3, n.º 3, pp. 159-165, mar. 2002, doi: [10.1016/S1470-2045\(02\)00679-4](https://doi.org/10.1016/S1470-2045(02)00679-4).
- [17] P. Weber, P. Tschandl, C. Sinz y H. Kittler, “Dermatoscopy of Neoplastic Skin Lesions: Recent Advances, Updates, and Revisions”, *Curr Treat Options Oncol*, vol. 19, n.º 11, sept. 2018, doi: [10.1007/s11864-018-0573-6](https://doi.org/10.1007/s11864-018-0573-6).
- [18] N. C. F. Codella *et al.*, “Skin Lesion Analysis Toward Melanoma Detection: A Challenge at the 2017 International Symposium on Biomedical Imaging (ISBI), Hosted by the International Skin Imaging Collaboration (ISIC)”, *arXiv:1710.05006*, oct. 2017. [En línea].

Disponible: arXiv, doi: [10.48550/arXiv.1710.05006](https://arxiv.org/abs/10.48550/arXiv.1710.05006).
[Accedido: oct. 23, 2024].

- [19] S. Jinnai, N. Yamazaki, Y. Hirano, Y. Sugawara, Y. Ohe y R. Hamamoto, “The development of a skin cancer classification system for pigmented skin lesions using deep learning”, *Biomolecules*, vol. 10, n.º 8, pp. 1-13, ag. 2020, doi: [10.3390/biom10081123](https://doi.org/10.3390/biom10081123).
- [20] P. Tschandl, C. Rosendahl y H. Kittler, “Data descriptor: The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions”, *Sci Data*, vol. 5, n.º 180161, pp. 1-9, 2018, doi: [10.1038/sdata.2018.161](https://doi.org/10.1038/sdata.2018.161).
- [21] J. Bobadilla, *Machine Learning y Deep Learning: Usando Python, Scikit y Keras*. Colombia: Ediciones de la U, 2021.
- [22] H.-J. Chiu, T.-H. S. Li y P.-H. Kuo, “Breast Cancer-Detection System Using PCA, Multilayer Perceptron, Transfer Learning, and Support Vector Machine”, en *IEEE Access*, vol. 8, pp. 204309-204324, 2020, doi: [10.1109/ACCESS.2020.3036912](https://doi.org/10.1109/ACCESS.2020.3036912).
- [23] L. Hoang, S. H. Lee, E. J. Lee y K. R. Kwon, “Multiclass Skin Lesion Classification Using a Novel Lightweight Deep Learning Framework for Smart Healthcare”, *Appl. Sci.*, vol. 12, n.º 5, mar. 2022, doi: [10.3390/app12052677](https://doi.org/10.3390/app12052677).
- [24] C. Shorten y T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning”, *J Big Data*, vol. 6, n.º 60, 2019, doi: [10.1186/s40537-019-0197-0](https://doi.org/10.1186/s40537-019-0197-0).
- [25] L. Taylor y G. Nitschke, “Improving Deep Learning with Generic Data Augmentation”, *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, Bangalore, India, 2018, pp. 1542-1547, doi: [10.1109/SSCI.2018.8628742](https://doi.org/10.1109/SSCI.2018.8628742).
- [26] I. S. Ali, M. F. Mohamed y Y. B. Mahdy, “Data Augmentation for Skin Lesion using Self-Attention based Progressive Generative Adversarial Network”, *arXiv:1910.11960*, oct. 2019. [En línea]. Disponible: arXiv, doi: [10.48550/arXiv.1910.11960](https://arxiv.org/abs/10.48550/arXiv.1910.11960). [Accedido: oct. 23, 2024].
- [27] D. Bisla, A. Choromanska, R. S. Berman, J. A. Stein, D. Polsky y R. O. Perelman, “Towards Automated Melanoma Detection with Deep Learning: Data Purification and Augmentation”, *arXiv:1902.06061*, 2019. [En línea]. Disponible: arXiv, doi: [10.48550/arXiv.1902.06061](https://arxiv.org/abs/10.48550/arXiv.1902.06061). [Accedido: oct. 23, 2024].
- [28] S. Joshi, J. A. Owens, S. Shah y T. Munasinghe, “Analysis of Preprocessing Techniques, Keras Tuner, and Transfer Learning on Cloud Street image data”, *2021 IEEE International Conference on Big Data (Big Data)*, Orlando, FL, EUA, 2021, pp. 4165-4168, doi: [10.1109/BigData52589.2021.9671878](https://doi.org/10.1109/BigData52589.2021.9671878).
- [29] P. Sutradhar, P. Kumer, I. Prodan, S. Saddi y V. S. Rozario, “Multi-Modal Case Study on MRI Brain Tumor Detection Using Support Vector Machine, Random Forest, Decision Tree, K-Nearest Neighbor, Temporal Convolution & Transfer Learning”, *AIUB J. Sci. Eng.*, vol. 20, n.º 3, sept. 2021.
- [30] D. N. T. Le, H. X. Le, L. T. Ngo y H. T. Ngo, “Transfer learning with class-weighted and focal loss function for automatic skin cancer classification”, *arXiv:2009.05977*, sept. 2020. [En línea]. Disponible: arXiv, doi: [10.48550/arXiv.2009.05977](https://arxiv.org/abs/10.48550/arXiv.2009.05977).
- [31] A. Abbas, M. M. Abdelsamea y M. M. Gaber, “DeTrac: Transfer Learning of Class Decomposed Medical Images in Convolutional Neural Networks”, *IEEE Access*, vol. 8, pp. 74901-74913, 2020, doi: [10.1109/ACCESS.2020.2989273](https://doi.org/10.1109/ACCESS.2020.2989273). [Accedido: oct. 23, 2024].
- [32] L. Singh, R. R. Janghel y S. P. Sahu, “TrCSVM: a novel approach for the classification of melanoma skin cancer using transfer learning”, *Data Technol. Appl.*, vol. 55, n.º 1, pp. 64-81, en. 2021, doi: [10.1108/DTA-06-2020-0126](https://doi.org/10.1108/DTA-06-2020-0126).
- [33] H. K. Kondaveeti y P. Edupuganti, “Skin Cancer Classification using Transfer Learning”, *2020 IEEE International Conference on Advent Trends in Multidisciplinary Research and Innovation (ICATMRI)*, Buldhana, India, 2020, pp. 1-4, doi: [10.1109/ICATMRI51801.2020.9398388](https://doi.org/10.1109/ICATMRI51801.2020.9398388).
- [34] S. Jain, U. Singhanian, B. Tripathy, E. A. Nasr, M. K. Aboudaif y A. K. Kamrani, “Deep learning-based transfer learning for classification of skin cancer”, *Sensors*, vol. 21, n.º 23, dic. 2021, doi: [10.3390/s21238142](https://doi.org/10.3390/s21238142).
- [35] S. A. Althubiti, F. Alenezi, S. Shitharth, K. Sangeetha y V. S. R. Chennareddy, “Circuit Manufacturing Defect Detection Using VGG16 Convolutional Neural

Networks”, *Wirel Commun Mob Comput*, vol. 2022, n.º 1070405, 2022, doi: [10.1155/2022/1070405](https://doi.org/10.1155/2022/1070405).

- [36] M. P. Uddin, M. Al Mamun y M. A. Hossain, “PCA-based Feature Reduction for Hyperspectral Remote Sensing Image Classification”, *IETE Tech. Rev.*, vol. 38, n.º 4, pp. 377-396, 2020, doi: [10.1080/02564602.2020.1740615](https://doi.org/10.1080/02564602.2020.1740615).

- [37] R. O. Ogundokun, S. Misra, A. O. Akinrotimi y H. Ogul, “MobileNet-SVM: A Lightweight Deep Transfer Learning Model to Diagnose BCH Scans for IoMT-Based Imaging Sensors”, *Sensors* 2023, vol. 23, n.º 2, en. 2023, doi: [10.3390/S23020656](https://doi.org/10.3390/S23020656).

- [38] A. Kumar, A. Ashok y M. A. Ansari, “Brain Tumor Classification Using Hybrid Model Of PSO And SVM Classifier”, *2018 International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)*, Greater Noida, India, 2018, pp. 1022-1026, doi: [10.1109/ICACCCN.2018.8748787](https://doi.org/10.1109/ICACCCN.2018.8748787).

RECONOCIMIENTOS

La primera autora agradece a la UACJ y al CONAHCYT por el apoyo brindado a través de la beca doctoral (CVU 272489), que ha permitido la realización de este proyecto.