

## ARTÍCULO DE INVESTIGACIÓN

### USO DE REDES NEURONALES CONVOLUCIONALES EN TELÉFONOS INTELIGENTES PARA LA IDENTIFICACIÓN DE ENFERMEDADES CUTÁNEAS

Quintero, Jormany<sup>1</sup>; González, Jesús<sup>2</sup>

1 Profesor del Departamento de Sistemas de Control, Escuela de Ingeniería de Sistemas, Facultad de Ingeniería Universidad de Los Andes. Mérida-Venezuela.

2 Ingeniero de Sistemas. Universidad de Los Andes. Mérida-Venezuela

Autor de contacto: Jormany Quintero

e-mail: [profe.jormany@gmail.com](mailto:profe.jormany@gmail.com)

#### Cómo citar este artículo:

**Vancouver:** Quintero J, González J. Uso de redes neuronales convolucionales en teléfonos inteligentes para la identificación de enfermedades cutáneas. *IDEULA*. 2021; (1): 79-96.

**APA:** : Quintero, J., González, J. Uso de redes neuronales convolucionales en teléfonos inteligentes para la identificación de enfermedades cutáneas. *IDEULA*, (1), 79-96.

**Recibido:** 27/05/2020      **Aceptado:** 27/06/2020

### RESUMEN

Las enfermedades cutáneas son un grupo de afecciones de la dermis, caracterizadas por el cambio de aspecto que presentan en comparación con la piel sana, donde algunas de ellas pueden evolucionar hasta convertirse en lesiones malignas siendo un riesgo para el paciente. Con la continua evolución de la tecnología, las herramientas de diagnóstico han ido evolucionando incorporando los teléfonos inteligentes en las actividades clínicas. Las aplicaciones móviles que soportan al dermatólogo en tareas de diagnóstico son escasas y limitadas, en este sentido el propósito de este trabajo fue desarrollar un prototipo de aplicación móvil basada en Android para el reconocimiento de lesiones cutáneas en tiempo real usando redes neuronales convolucionales. La aplicación móvil desarrollada implementó la librería *TensorFlow* para la ejecución del modelo. El reconocimiento implementó el modelo *Mobilenet V2*, junto con un banco de 305 imágenes obtenidas de la internet. Las enfermedades seleccionadas para la identificación fueron: melanoma, psoriasis en placa, sarcoma de Kaposi y dermatitis atópica. Las pruebas de la aplicación se realizaron en dos equipos diferentes para evaluar el comportamiento. Las lesiones de tipo melanoma, psoriasis en placa y dermatitis atópica, presentaron un buen desempeño (>75%) para la predicción y un desempeño regular (<75%) en la predicción de enfermedades tipo sarcoma de Kaposi. La aplicación móvil desarrollada demostró un buen comportamiento a pesar de la baja cantidad de imágenes usadas en el entrenamiento.

**Palabras clave:** aprendizaje automático; enfermedades de la piel; inteligencia artificial; mSalud.

## USE OF CONVOLUTIONAL NEURAL NETWORKS IN SMARTPHONES FOR THE IDENTIFICATION OF SKIN DISEASES

### ABSTRACT

Skin diseases are a group of conditions of the dermis, characterized by the change in appearance that they present in comparison with healthy skin, where some of them can evolve into malignant lesions, being a risk for the patient. With the continuous evolution of technology, diagnostic tools have been evolving incorporating smartphones into clinical activities. The mobile applications that support the dermatologist in diagnostic tasks are scarce and limited, in this sense, the purpose of this work was to develop a prototype of an Android-based mobile application for the recognition of skin lesions in real-time using convolutional neural networks. The mobile application developed implemented the TensorFlow library for the execution of the model. For the recognition, the Mobilenet V2 model was used, together with a bank of 305 images obtained from the internet. The diseases selected for identification were melanoma, plaque psoriasis, Kaposi's sarcoma, and atopic dermatitis. The application tests were performed on two different computers to evaluate the behavior. Melanoma-type lesions, plaque psoriasis, and atopic dermatitis presented a good performance ( $> 75\%$ ) for the prediction and a regular performance ( $< 75\%$ ) for the prediction of Kaposi's sarcoma-type diseases. The mobile application developed showed good behavior despite the low amount of images used for training.

**Key words:** machine learning; skin diseases; artificial intelligence; mHealth.

## INTRODUCCIÓN

Las enfermedades cutáneas son un grupo de afecciones de la dermis, caracterizadas por el cambio de aspecto que presentan en comparación con la piel sana. La presencia de lesiones en la piel se hace cada vez más común afectando a personas sin importar su edad o género, esto se debe a la continua exposición al medio ambiente fluctuante actual<sup>1</sup>. Una temprana detección de estas lesiones se vuelve vital para la toma de decisión en cuanto al tratamiento a seguir. Durante la inspección clínica, dependiendo de la experiencia, la pericia y la precisión, el médico se vale de técnicas y herramientas que lo orientan a un diagnóstico más cercano al real<sup>1</sup>. Un mal diagnóstico se traduce en exámenes complementarios innecesarios, demora en aplicación del tratamiento correcto y propagación de la lesión<sup>2,3</sup>.

Poder diferenciar el tipo de lesión es un proceso complejo. Para diagnosticar una enfermedad en la piel se verifica la presencia/ausencia de algunos signos, tales como la morfología, distribución, color, escalamiento y disposición; si cada uno de estos elementos se analiza por separado aumenta la dificultad del proceso de reconocimiento de la enfermedad<sup>1,4-6</sup>. El uso de sistemas de apoyo computacionales para el diagnóstico de estas lesiones se ha vuelto imprescindible para el dermatólogo, pudiendo emitir diagnósticos más exactos minimizando la subjetividad que pudiera aparecer en ausencia de estas herramientas<sup>1,3,6,7</sup>.

En la actualidad, existen un gran número de programas informáticos que sirven de sistema de apoyo en medicina, entre estos se incluyen los de aprendizaje automático (ML: *Machine Learning* por su término en inglés), rama de la inteligencia artificial constituida por varias técnicas de aprendizaje<sup>6-8</sup>. Algunas de las soluciones basadas en ML incluyen predicción temprana de neuropatías diabéticas basados en presión plantar<sup>9</sup>, el diagnóstico por imagen<sup>10-13</sup>, detección de infartos con reconocimiento de pequeñas diferencias entre el miocardio normal y anormal<sup>14</sup>, diagnóstico de la enfermedad de Parkinson usando un dispositivo móvil<sup>15</sup>, angiografía de arteria coronaria<sup>14</sup>, entre otras muchas aplicaciones.

Con la continua evolución de la tecnología, las herramientas de diagnóstico han ido innovando. En este sentido, la incorporación de dispositivos móviles en las actividades de diagnóstico clínico, van en aumento y esto conlleva el uso de aplicaciones móviles<sup>3,4,16-20</sup>. Los teléfonos inteligentes o *smartphones* están siendo usados para la detección de síntomas oculares<sup>21</sup>, auscultación cardíaca<sup>22</sup>, seguimiento de lesiones cutáneas por parte de los pacientes<sup>17,23</sup>, identificación de lesiones a través de redes neuronales artificiales<sup>16,18</sup>, entre otros usos. Las aplicaciones móviles, en su mayoría se encuentran disponibles en las tiendas virtuales ya sea para uso de pacientes o para uso de profesionales de la salud<sup>16,18,19</sup>.

Las redes neuronales convolucionales (RNC) siguen siendo las pioneras en los métodos de ML usados para diagnóstico médico por destacar su tolerancia a fallos y la facilidad de inserción con la tecnología existente<sup>16,24-26</sup>. Estas redes pueden ser configuradas usando *TensorFlow*, una librería de código abierto de Google© para entrenar y desarrollar modelos de ML. La unidad base es el tensor, el cual puede verse como un arreglo de datos multidimensional que incluye información de las imágenes, el ancho, el largo en píxeles y cada canal de color<sup>8,16</sup>.

La documentación sobre sistemas informáticos que implementan métodos de ML para el reconocimiento de lesiones cutáneas es extensa, sin embargo, la mayoría de estos se basan en programas o piezas de software que necesitan de otros programas de cálculo como MATLAB, MAPLE u OCTAVE para el entrenamiento y ejecución de los modelos<sup>27-29</sup>. El uso de computadores con procesadores de alta velocidad y gran capacidad de memoria para la ejecución de los algoritmos de RNC limitan a los profesionales médicos al uso de equipos que ocupan grandes espacios en el área de consulta. Debido a ello, el desarrollo de aplicaciones móviles para *smartphones* se ha convertido en tendencia en los últimos años, encontrándose en los mercados digitales para aplicaciones un número limitado de alternativas para el dermatólogo en donde las aplicaciones pagas son mayoría<sup>4,16</sup>. En este sentido, la evidencia publicada hasta ahora sobre aplicaciones para *smartphones* que soporten al dermatólogo en las actividades de diagnóstico para múltiples lesiones es limitada y escasa, ya que los estudios publicados en esta área se enfocan prioritariamente en el reconocimiento de melanomas por las características de la enfermedad<sup>19,20</sup>.

La idea de contar con una herramienta que, a partir de una imagen en tiempo real, permita orientar a un diagnóstico certero aprovechando los recursos de hardware y softwares de los teléfonos inteligentes, resulta beneficioso para el clínico. Así como también el uso de este tipo de aplicaciones de apoyo para aquellos médicos que ejercen en poblaciones rurales en donde el acceso a un dermatólogo es difícil. En este sentido el objetivo de esta investigación fue desarrollar un prototipo de una aplicación móvil basada en Android para el reconocimiento de lesiones cutáneas en tiempo real usando redes neuronales convolucionales.

## MATERIALES Y MÉTODOS

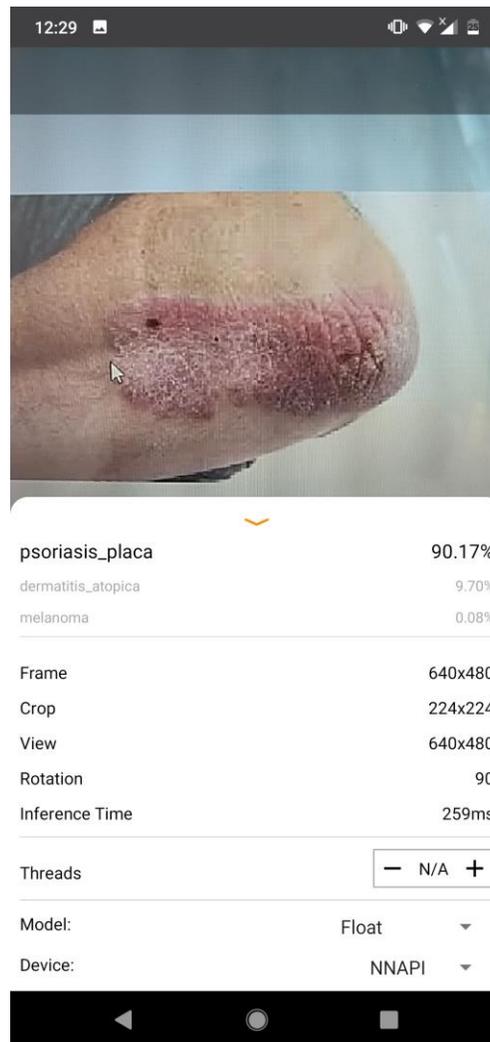
### a) Descripción de la aplicación móvil

Se desarrolló una aplicación móvil prototipo con fines de investigación llamada PICDiDIT (Procesador e Identificador Convolutacional De imágenes Dermatológicas Implementando Transferlearning), para ser usada bajo el sistema operativo Android y programada en Android Studio (Google Inc). Su propósito es identificar lesiones dermatológicas captadas por la cámara de un *smartphone* usando RNC como modelo de aprendizaje. Los permisos de ejecución están establecidos previamente para el uso de la cámara incorporada. Su funcionamiento se basa en la identificación de una imagen captada por la cámara del teléfono sin necesidad de fotografiar y almacenar. Este reconocimiento se ejecuta sin conexión a internet de forma local en tiempo real.

La aplicación móvil posee dos actividades y un servicio general. Una de las actividades corresponde a la bienvenida de la aplicación, la otra destinada al uso de la cámara, información y configuración de los parámetros para el procesamiento de las imágenes, en la Figura 1 se observa una captura de pantalla de la aplicación. El servicio de reconocimiento prepara la imagen, carga al modelo de RNC, analiza la imagen, realiza inferencias y muestra los resultados.

A nivel de hardware, PICDiDIT detecta el modelo del dispositivo donde es ejecutada y la cantidad de hilos de procesamiento disponibles para su funcionamiento óptimo. Para ejecutar la aplicación móvil es necesario un *smartphone* que posea un procesador de 1,2 GHz o superior, memoria RAM de 512 Mb o superior, cámara incorporada superior a 2 Mpx y el sistema operativo Android KitKat 4.4.2 o superior.

Las pruebas de esta aplicación fueron hechas en dos teléfonos, un Samsung Galaxy S4 mini y un Nokia 7.1.



**Figura 1.** Captura de pantalla de la aplicación PICDiDIT en funcionamiento

### b) Procesamiento de la imagen

El procesamiento de la imagen se realiza en diferentes etapas antes de ser identificada. El modelo de identificación basado en RNC debe estar entrenado previamente con imágenes y clases necesarias para ser incorporado a la aplicación móvil. La captura de la imagen es interpretada como un mapa de bits de 640x480px RGB necesario para ejecutar el proceso de inferencia y reconocimiento. El modelo de

reconocimiento transforma el mapa de bits recibido a un tensor que es entendido por la librería *TensorFlow* para ejecutar el algoritmo basado en RNC y realizar la identificación. Luego del proceso de reconocimiento se genera una lista ordenada de probabilidades correspondiente a cada clase del modelo, estos datos son mostrados en pantalla junto al tiempo de inferencia.

### c) Modelo de reconocimiento

El modelo usado para el reconocimiento fue *Mobilenet V2*, un modelo eficiente para ser ejecutado en aplicaciones móviles. El modo en punto flotante fue elegido para priorizar la precisión sobre velocidad de reconocimiento. Las capas de la red tienen en su salida una capa de normalización y un rectificador lineal a excepción de la última capa, la cual está conectada a una función exponencial normalizada que devuelve la probabilidad de inferencia. Para ahorrar en tiempo de entrenamiento y tiempo de cómputo se utilizó *transfer learning* como técnica de aprendizaje para reentrenar el modelo de RNC y el conversor integrado de la API de *TensorFlow lite* para generar el modelo compatible con aplicaciones móviles.

### d) Conjunto de Datos

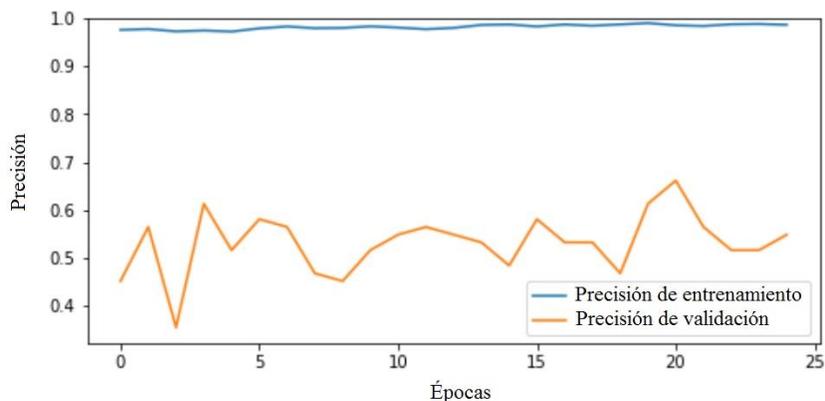
El conjunto de imágenes se obtuvo usando la técnica de *web scraping* para aquellas fotografías de acceso público y consultando bancos de imágenes como *shutterstock.com*, *geosalud.com* y *istockphoto.com*. Se seleccionaron 305 imágenes clínicas repartidas en cinco clases a identificar como se observa en la Tabla 1. Para ampliar el número de imágenes en la base de datos se realizaron transformaciones aleatorias lineales como acercamientos y rotaciones en cada una. El conjunto de datos se separó en dos, el 80% de las imágenes se usaron para el entrenamiento de la red y el 20% restante para la validación.

*Tabla 1* – Distribución de imágenes en clases de reconocimiento

Lesión	Total Imágenes	Entrenamiento	Validación
Dermatitis atópica	60	48	12
Melanoma	69	55	14
Psoriasis en placa	60	48	12
Sarcoma de Kaposi	57	46	11
Sin lesión	59	47	12
<b>Total</b>	<b>305</b>	<b>244</b>	<b>61</b>

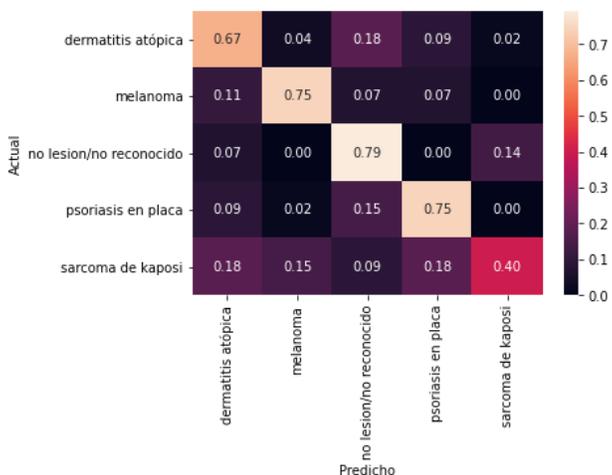
## RESULTADOS

El entrenamiento del modelo se realizó eligiendo 25 épocas de 500 pasos cada una. Para medir el rendimiento del entrenamiento se utilizó el gráfico propuesto por *TensorFlow* que mide la precisión por épocas y la tasa de sobre-entrenamiento del modelo. La Figura 2 muestra la curva de aprendizaje obtenida, en ella se aprecia que la máxima precisión obtenida ronda el 68% del conjunto de imágenes usada para la validación.



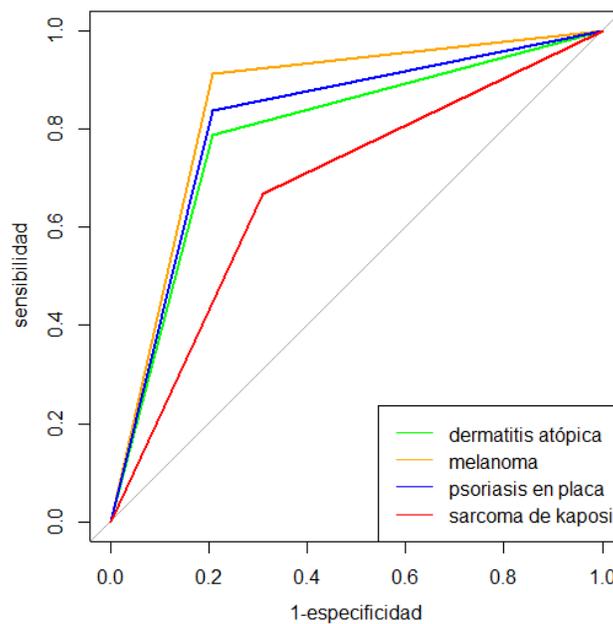
**Figura 2.** Curva de precisión del entrenamiento y la validación del modelo

Para medir la exactitud del modelo se construyó la matriz de confusión mostrada en la Figura 3. Esta matriz describe el rendimiento de la aplicación por cada clase o lesión. Para su elaboración se utilizó un conjunto de datos no balanceado. Los resultados de esta prueba develan que el 75% de las lesiones melanoma y psoriasis en placa fueron reconocidas del conjunto de imágenes de validación, el 67% de las imágenes de dermatitis atópica fue reconocido y un 40% de imágenes de lesiones de sarcoma de Kaposi fue reconocido. Las imágenes clasificadas como sin lesión o no reconocidas fueron identificadas correctamente en un 79% de los casos.



**Figura 3.** Matriz de confusión desbalanceada del modelo *MobileNet V2* para cada lesión cutánea

Para comparar los resultados de validación, se utilizó la curva de características operativas del receptor o curva ROC (*Receiver Operating Characteristic*) que se muestra en la Figura 4. Los valores del área bajo esa curva (ABC), junto con los valores de precisión y sensibilidad (*recall*) para cada clase son mostrados en la Tabla 2.



**Figura 4.** Curva ROC para cada lesión cutánea

En la curva ROC se aprecia que la lesión sarcoma de Kaposi (rojo) es la curva más pequeña en comparación con las demás, con un valor de 0,678, lo que representa una probabilidad del 67,8% de reconocer un caso aleatorio de sarcoma de Kaposi positivo frente a uno negativo. En este caso, la sensibilidad se reduce en comparación con la especificidad, lo que significa que los casos verdaderos positivos son menos reconocibles. La lesión de melanoma presenta un ABC de 0,852, psoriasis en placa un ABC de 0,814 y la dermatitis atópica tiene un ABC de 0,79, siendo el melanoma la lesión más reconocible por la aplicación móvil. Los valores de precisión y sensibilidad de la Tabla 2 muestran que el sarcoma de Kaposi es la lesión con valores mínimos.

Tabla 2. Métricas de rendimiento para cada lesión

Lesión	ABC	Precisión	Sensibilidad	Valor-F1
Dermatitis atópica	0,790	0,697	0,793	0,741
Melanoma	0,852	0,852	0,793	0,821
Psoriasis en placa	0,814	0,742	0,793	0,767
Sarcoma de Kaposi	0,678	0,689	0,689	0,689
Total	0,784	0,745	0,767	0,755

El hecho de utilizar conjuntos de datos de validación desbalanceados sugiere utilizar otra métrica para probar el rendimiento de la aplicación móvil. Para ello se usó la métrica de Valor-F1 basado en los valores de precisión y sensibilidad, los resultados de esta prueba se muestran en la Tabla 2 para cada tipo de lesión. Estos valores obtenidos son coherentes con las métricas de rendimiento anteriores. Demostrando así que esta aplicación móvil tiene un buen desempeño para el reconocimiento de lesiones tipo melanoma, psoriasis en placa y dermatitis atópica, sin embargo, presenta un desempeño regular para identificar sarcomas de Kaposi.

## DISCUSIÓN

La aplicación móvil desarrollada en este trabajo bajo tecnología Android resultó ser la mejor opción en cuanto a los costos de sistema operativo y desarrollo de software, ya que las aplicaciones similares para el diagnóstico de lesiones en piel, son en su mayoría diseñadas en iOS (Sistema Operativo de Apple), esto implica altos costos en su adquisición, programación y mantenimiento<sup>4</sup>. El modelo implementado se fundamentó en RNC para el reconocimiento de un grupo de lesiones cutáneas, usando para ello *transfer learning* como método de aprendizaje, este método es ampliamente usado por muchos sistemas de reconocimiento basados en ML<sup>1,26,27,30-34</sup>. Existen sistemas de identificación de lesiones que usan en sus

algoritmos diferentes modelos de RNC, entre estos destacan AlexNet<sup>30</sup>, VGGNet<sup>26,28</sup> y ResNet<sup>31,34-36</sup>, cuyo desempeño es similar al modelo usado para este trabajo. En cuanto al entrenamiento del modelo se ha evidenciado en diferentes investigaciones el uso *TensorFlow*<sup>1,34,37,38</sup> para aplicaciones móviles y otros programas como MATLAB<sup>27-29</sup> para soluciones en computadores de escritorio.

La naturaleza del entrenamiento de los modelos de RNC para la identificación de lesiones requiere de un banco de imágenes. En este caso el número de ítems por clases fue pequeño, alrededor de 60 imágenes por clases, lo que implicó usar el método de transformaciones lineales, acercamiento y rotaciones para ampliar la base de datos al momento del entrenamiento. La cantidad de imágenes usadas en diferentes estudios supera por mucho al usado en este trabajo<sup>25,28,30-32,35,36,38-40</sup>, es de resaltar que por esta razón estas investigaciones no hacen uso de las transformaciones aleatorias lineales. El reconocimiento de las imágenes no es directo, sino hecho en base a la probabilidad de pertenecer a una de las clases programadas en la RNC. Durante las pruebas se obtuvo que el tiempo de inferencia para el modelo no supera los 500ms, lo que resulta excelente cuando se usa como herramienta de diagnóstico. Este tiempo se considera rápido para la identificación, así como también lo es el cambio de porcentaje de certeza arrojado cuando se identifica la lesión.

Las lesiones de tipo melanoma, psoriasis en placa y dermatitis atópica, presentaron un buen desempeño al evaluar las métricas correspondientes a cada lesión. Debido a la importancia clínica y la severidad asociada, los melanomas son lesiones cutáneas frecuentemente estudiadas para la identificación por métodos de ML. En este trabajo para la lesión de melanoma se obtuvo una precisión del 85,2% al igual que otras investigaciones cuya precisión y desempeño fue similar<sup>25,26,30,35,40</sup>, otros estudios basados en RNC obtuvieron en sus resultados un desempeño regular y precisión menor al 80%<sup>3,28,42,43</sup>, sin embargo hay evidencia de investigaciones que superan el 90% en la precisión al reconocer melanomas<sup>5,24,31,33,41</sup>.

La lesión psoriasis en placa ha sido incluida dentro de otras investigaciones, en las cuales se ha obtenido con una precisión del 72,2%<sup>1</sup> y 80%<sup>37</sup>, valores próximos al 74,2% obtenido por la aplicación desarrollada en este trabajo. Las métricas para esta enfermedad se encuentran dentro del rango considerado como bueno

y las predicciones se interpretan como correctas con cierto margen de error. En cuanto al comportamiento para predecir correctamente la dermatitis atópica se obtuvo un resultado regular, menor al 70%, sin embargo, la sensibilidad para esta clase se encuentra cerca del 80% (79,3%) haciendo confiable las predicciones hechas.

La aplicación PICDiDIT ofrece un desempeño regular para lesiones tipo sarcoma de Kaposi. Con menor frecuencia se identificó esta clase, demostrado en la matriz de confusión y las métricas calculadas, mostrando una precisión (68.9%) y sensibilidad (68.9%) regular, lo que implica un aumento en el número de casos falsos positivos. Este desempeño se debe al número y calidad de imágenes usadas para el entrenamiento.

La literatura reporta un gran número de investigaciones basadas exclusivamente en métodos de ML para el reconocimiento de melanomas cutáneos. Estas piezas de software acondicionan la imagen a identificar usando una serie de filtros digitales con el fin de extraer sus características y emitir un diagnóstico<sup>3,28,29,32,33,38-41</sup>. La aplicación móvil PICDiDIT, a diferencia de estas otras, se basa en el reconocimiento clínico de varias lesiones cutáneas tomando en cuenta la observación y la visión por computadora desde un *smartphone*, tal como lo realizado por otras investigaciones que presentaron un rendimiento en la predicción mayor del 85%<sup>25,34,37,41</sup> o como la de Yang y cols. en 2018 que presentó una exactitud de 75%<sup>39</sup>.

## CONCLUSIONES

La aplicación desarrollada para el reconocimiento de enfermedades cutáneas mostró más de un 75% de precisión y más de un 77% de sensibilidad para tres de las cuatro lesiones elegidas, demostrando un buen comportamiento y desempeño a pesar de la baja cantidad de imágenes usadas para el entrenamiento. El poder efectuar el reconocimiento de forma local en tiempo real usando *smartphones* presenta una gran ventaja para el uso de esta aplicación como herramienta de diagnóstico en áreas remotas sin acceso a internet.

El incremento del número de imágenes al momento del entrenamiento de la RNC permitiría mejorar los valores de precisión y sensibilidad en esta aplicación, así como también el acondicionamiento previo de las imágenes para extraer características clínicas que permitan aportar más datos para el reconocimiento de lesiones cutáneas con métodos de ML.

## REFERENCIAS

1. Suárez-Sánchez J, Colín-Rivas L, Mejía-González A, Ambríz-Polo J, García-Mejía J. Una aproximación al diagnóstico de enfermedades de la piel por medio de aprendizaje profundo. *Aristas Investig Básica y Apl* [Internet]. 2018;6(12):13–6. Disponible en: <http://fcqi.tij.uabc.mx/usuarios/revistaaristas/numeros/N12/articulos/13-16.pdf>
2. Leguizamon Correa DN, Bareiro Paniagua LR, Vazquez Noguera JL, Pinto-Roa DP, Salgueiro Toledo LA. Computerized Diagnosis of Melanocytic Lesions Based on the ABCD Method. En: 2015 Latin American Computing Conference (CLEI) [Internet]. Arequipa, Perú: IEEE; 2015. p. 1–12. Disponible en: <https://ieeexplore.ieee.org/document/7360029/>
3. Serrano-Fernández J. Sistema de ayuda al diagnóstico para la detección temprana de melanomas [Internet]. [Madrid, Español]: Universidad Carlos III de Madrid; 2017. Disponible en: [https://e-archivo.uc3m.es/bitstream/handle/10016/28200/TFG\\_Jose\\_Serrano\\_Fernandez.pdf?sequence=1](https://e-archivo.uc3m.es/bitstream/handle/10016/28200/TFG_Jose_Serrano_Fernandez.pdf?sequence=1)
4. Hameed N, Ruskin A, Abu Hassan K, Hossain MA. A comprehensive survey on image-based computer aided diagnosis systems for skin cancer. En: 2016 10th International Conference on Software, Knowledge, Information Management & Applications (SKIMA) [Internet]. Chengdu, China: IEEE; 2016. p. 205–14. Disponible en: <https://ieeexplore.ieee.org/document/7916221/>
5. Shoieb DA, Youssef SM, Aly WM. Computer-Aided Model for Skin Diagnosis Using Deep Learning. *J Image Graph* [Internet]. 2016;4(2):122–9. Disponible en: <http://www.joig.org/index.php?m=content&c=index&a=show&catid=44&id=145>
6. González-Cruz C, Jofre MA, Podlipnik S, Combalia M, Gareau D, Gamboa M, et al. Uso del aprendizaje automático en el diagnóstico del melanoma. Limitaciones por superar. *Actas Dermosifiliogr* [Internet]. mayo de 2020;111(4):313–6. Disponible en: <https://linkinghub.elsevier.com/retrieve/pii/S0001731020300041>
7. Fernández-Blázquez P. Detección del cáncer de piel mediante técnicas de visión artificial [Internet]. [Leganés]: Universidad Carlos III de Madrid; 2017. Disponible en: [https://e-archivo.uc3m.es/bitstream/handle/10016/27843/TFG\\_Paula\\_Fernandez\\_Blazquez.pdf?sequence=1](https://e-archivo.uc3m.es/bitstream/handle/10016/27843/TFG_Paula_Fernandez_Blazquez.pdf?sequence=1)

8. Artola-Moreno A. Clasificación de imágenes usando redes neuronales convoluciones en Python [Internet]. Universidad de Sevilla; 2019. Disponible en: <https://idus.us.es/bitstream/handle/11441/89506/TFG-2402-ARTOLA.pdf?sequence=1>
9. Tincopa-Flores JP. Diseño y evaluación de un sistema de ayuda al diagnóstico para neuropatía diabética basado en la lectura de puntos de presión plantar y Machine Learning [Internet]. [Lima, Perú]: Universidad Peruana Cayetano Heredia; 2019. Disponible en: <http://190.116.48.43/handle/upch/7239>
10. de Bruijne M. Machine learning approaches in medical image analysis: From detection to diagnosis. *Med Image Anal* [Internet]. octubre de 2016;33:94–7. Disponible en: <https://linkinghub.elsevier.com/retrieve/pii/S1361841516301098>
11. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, et al. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep* [Internet]. el 7 de diciembre de 2019;9(1):3840. Disponible en: <http://www.nature.com/articles/s41598-019-40414-y>
12. Cheng C, Shueng P-W, Chang C-C, Kuo C-W. Adapting an Evidence-based Diagnostic Model for Predicting Recurrence Risk Factors of Oral Cancer. *J Univers Comput Sci* [Internet]. 2018;24(6):742–52. Disponible en: [http://jucs.org/jucs\\_24\\_6/adapting\\_an\\_evidence\\_based/jucs\\_24\\_06\\_0742\\_0752\\_cheng.pdf](http://jucs.org/jucs_24_6/adapting_an_evidence_based/jucs_24_06_0742_0752_cheng.pdf)
13. Leivi AE. Análisis de la implementación de Machine Learning en el diagnóstico por imágenes [Internet]. [Buenos Aires, Argentina]: Universidad de San Andrés; 2019. Disponible en: <http://repositorio.udes.edu.ar/jspui/bitstream/10908/16748/1/%5BP%5D%5BW%5D%5DT.%5D%5C%5DAlejo%20Ezequiel.pdf>
14. Del Río-Solá M, López Santos J, Vaquero Puerta C. La inteligencia artificial en el ámbito médico. *Rev Española Investig Quirúrgicas* [Internet]. 2018;21(3):113–6. Disponible en: <http://www.reiq.es/ING/pdf/REIQ21.3.2018.pdf#page=47>
15. Zhan A, Mohan S, Tarolli C, Schneider RB, Adams JL, Sharma S, et al. Using Smartphones and Machine Learning to Quantify Parkinson Disease Severity. *JAMA Neurol* [Internet]. el 1 de julio de 2018;75(7):876. Disponible en: <http://www.ncbi.nlm.nih.gov/pubmed/29582075>
16. González J. Diseño e implementación de una aplicación móvil inteligente en Android para reconocimiento de lesiones y enfermedades cutáneas y en la mucosa bucal. [Mérida, Venezuela]: Universidad de Los Andes; 2019.
17. Finnane A, Dallest K, Janda M, Soyer HP. Teledermatology for the Diagnosis and Management of Skin Cancer: A Systematic Review. *JAMA dermatology* [Internet]. el 1 de marzo de 2017;153(3):319–27. Disponible en:

<http://archderm.jamanetwork.com/article.aspx?doi=10.1001/jamadermatol.2016.4361>

18. Freeman K, Dinnes J, Chuchu N, Takwoingi Y, Bayliss SE, Matin RN, et al. Algorithm based smartphone apps to assess risk of skin cancer in adults: systematic review of diagnostic accuracy studies. *BMJ* [Internet]. el 10 de febrero de 2020;368:m127. Disponible en: <http://www.bmj.com/lookup/doi/10.1136/bmj.m127>
19. de Carvalho TM, Noels E, Wakkee M, Udrea A, Nijsten T. Development of Smartphone Apps for Skin Cancer Risk Assessment: Progress and Promise. *JMIR Dermatology* [Internet]. el 11 de julio de 2019;2(1):e13376. Disponible en: <http://derma.jmir.org/2019/1/e13376/>
20. Caiza Caizabuan JR, Mise-Pasuña JL, Andaluz-Espinosa DF, Reyes-Chicango R. Analysis of mobile applications that help skin care through facial recognition: A systematic analysis. *KnE Eng* [Internet]. el 8 de enero de 2020;2020:76–88. Disponible en: <https://knepublishing.com/index.php/KnE-Engineering/article/view/5922>
21. Mariakakis A, Patel S. Ocular symptom detection using smartphones. En: *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct* [Internet]. New York, NY, USA: ACM; 2016. p. 435–40. Disponible en: <https://dl.acm.org/doi/10.1145/2968219.2971354>
22. Kang SH, Joe B, Yoon Y, Cho GY, Shin I, Suh JW. Cardiac Auscultation Using Smartphones: Pilot Study. *JMIR mHealth uHealth* [Internet]. el 28 de febrero de 2018;6(2):e49. Disponible en: <http://mhealth.jmir.org/2018/2/e49/>
23. Hubiche T, Valério L, Boralevi F, Mahe E, Bodemer Skandalis C, Phan A, et al. Visualization of Patients' Skin Lesions on Their Smartphones. *JAMA Dermatology* [Internet]. el 1 de enero de 2016;152(1):95. Disponible en: <http://archderm.jamanetwork.com/article.aspx?doi=10.1001/jamadermatol.2015.2977>
24. Kanimozhi T, Murthi A. Computer aided Melanoma skin cancer detection using Artificial Neural Network classifier. *Singaporean J Sci Res* [Internet]. 2016;8(2):35–43. Disponible en: <http://www.sjsronline.com/Papers/Papers/sjsrvol8no22016-5.pdf>
25. Kawahara J, BenTaieb A, Hamarneh G. Deep features to classify skin lesions. En: *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)* [Internet]. Praga: IEEE; 2016. p. 1397–400. Disponible en: <http://ieeexplore.ieee.org/document/7493528/>
26. Romero-Lopez A, Giro-i-Nieto X, Burdick J, Marques O. Skin Lesion Classification from Dermoscopic Images Using Deep Learning Techniques. En: *Biomedical Engineering* [Internet]. Calgary, AB, Canada: ACTAPRESS; 2017. p. 49–54. Disponible en: <http://www.actapress.com/PaperInfo.aspx?paperId=456417>

27. Alcoceba-Álvarez D. Detector automático de lesiones de piel en imágenes dermoscópicas con Deep Learning [Internet]. Escuela Técnica Superior de Ingeniería y Sistemas de Telecomunicación; 2018. Disponible en:  
[http://oa.upm.es/54096/1/TFG\\_DIEGO\\_ALCOCEBA\\_ALVAREZ.pdf](http://oa.upm.es/54096/1/TFG_DIEGO_ALCOCEBA_ALVAREZ.pdf)
28. Burdick J, Marques O, Weinthal J, Furht B. Rethinking Skin Lesion Segmentation in a Convolutional Classifier. *J Digit Imaging* [Internet]. el 18 de agosto de 2018;31(4):435–40. Disponible en: <http://link.springer.com/10.1007/s10278-017-0026-y>
29. Rojas J. Aplicaciones Biomédicas de Visión Computacional: Detección Automática de Melanoma [Internet]. Universidad Central “Marta Abreu” de Las Villas; 2013. Disponible en:  
[https://dspace.uclv.edu.cu/bitstream/handle/123456789/1652/Jessica Rojas Rosales.pdf?sequence=1&isAllowed=y](https://dspace.uclv.edu.cu/bitstream/handle/123456789/1652/Jessica%20Rojas%20Rosales.pdf?sequence=1&isAllowed=y)
30. Bhattacharya A, Young A, Wong A, Stalling S, Wei M, Hadley D. Precision Diagnosis Of Melanoma And Other Skin Lesions From Digital Images. *AMIA Jt Summits Transl Sci proceedings AMIA Jt Summits Transl Sci* [Internet]. 2017;2017:220–6. Disponible en:  
<http://www.ncbi.nlm.nih.gov/pubmed/28815132>
31. Han SS, Kim MS, Lim W, Park GH, Park I, Chang SE. Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm. *J Invest Dermatol* [Internet]. 2018;138(7):1529–38. Disponible en:  
<https://linkinghub.elsevier.com/retrieve/pii/S0022202X18301118>
32. Coronado RR. Reconocimiento De Patrones En Imagenes No Dermatoscopicas Para La Detección De Enfermedades Malignas En La Piel, Utilizando Redes Neuronales Convolutivas Y Autocodificadores [Internet]. [Arequipa, Perú]: Universidad Nacional de San Agustín; 2018. Disponible en:  
<http://repositorio.unsa.edu.pe/bitstream/handle/UNSA/6520/ISMcoperr.pdf?sequence=1&isAllowed=y>
33. Salido JAA, Jr. CR. Using Deep Learning for Melanoma Detection in Dermoscopy Images. *Int J Mach Learn Comput* [Internet]. febrero de 2018;8(1):61–8. Disponible en:  
<http://www.ijmlc.org/index.php?m=content&c=index&a=show&catid=76&id=771>
34. Ziaten-Cerezo E. Clasificación de lesiones en la piel usando aprendizaje profundo [Internet]. [Málaga, España]: Universidad de Málaga; 2018. Disponible en:  
[https://riuma.uma.es/xmlui/bitstream/handle/10630/19213/Ibn Ziaten Cerezo Memoria.pdf?sequence=1&isAllowed=y](https://riuma.uma.es/xmlui/bitstream/handle/10630/19213/Ibn%20Ziaten%20Cerezo%20Memoria.pdf?sequence=1&isAllowed=y)
35. Yap J, Yolland W, Tschandl P. Multimodal skin lesion classification using deep learning. *Exp Dermatol* [Internet]. noviembre de 2018;27(11):1261–7. Disponible en:  
<http://doi.wiley.com/10.1111/exd.13777>

36. Domènech T. Clasificación de imágenes dermatoscópicas utilizando Redes Neuronales Convolucionales e información de metadatos [Internet]. [Barcelona, España]: Universidad Politécnica de Catalunya; 2019. Disponible en: [https://upcommons.upc.edu/bitstream/handle/2117/165606/Final\\_thesis\\_TDA.pdf](https://upcommons.upc.edu/bitstream/handle/2117/165606/Final_thesis_TDA.pdf)
37. Velasco J, Pascion C, Alberio JW, Apuang J, Cruz JS, Gomez MA, et al. A Smartphone-Based Skin Disease Classification Using MobileNet CNN. *Int J Adv Trends Comput Sci Eng* [Internet]. el 15 de octubre de 2019;8(5):2632–7. Disponible en: <http://www.warse.org/IJATCSE/static/pdf/file/ijatcse116952019.pdf>
38. Méndez-Hernández R. Aprendizaje profundo para la segmentación de lesiones pigmentadas de la piel [Internet]. [Sevilla, España]: Universidad de Sevilla; 2019. Disponible en: <https://idus.us.es/bitstream/handle/11441/92186/TFM-1430-MENDEZ.pdf?sequence=1>
39. Yang J, Sun X, Liang J, Rosin PL. Clinical Skin Lesion Diagnosis Using Representations Inspired by Dermatologist Criteria. En: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition [Internet]. Utah, Estados Unidos: IEEE; 2018. p. 1258–66. Disponible en: <https://ieeexplore.ieee.org/document/8578235/>
40. Pham TC, Luong CM, Visani M, Hoang VD. Deep CNN and Data Augmentation for Skin Lesion Classification. En: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* [Internet]. 2018. p. 573–82. Disponible en: [http://link.springer.com/10.1007/978-3-319-75420-8\\_54](http://link.springer.com/10.1007/978-3-319-75420-8_54)
41. Kalwa U, Legner C, Kong T, Pandey S. Skin Cancer Diagnostics with an All-Inclusive Smartphone Application. *Symmetry (Basel)* [Internet]. el 13 de junio de 2019;11(6):790. Disponible en: <https://www.mdpi.com/2073-8994/11/6/790>
42. Gal Y, Islam R, Ghahramani Z. Deep Bayesian Active Learning with Image Data. *Proc 34th Int Conf Mach Learn* [Internet]. el 8 de marzo de 2017; Disponible en: <http://arxiv.org/abs/1703.02910>
43. Sánchez-Hernández J, Hernández-Rabadán D. Comparación de métodos de clasificación aplicados al diagnóstico de melanomas malignos mediante asimetría. *Program Matemática y Softw* [Internet]. 2014;6(2):51–6. Disponible en: <http://riaa.uaem.mx/handle/20.500.12055/109>