

UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA DE SISTEMAS Y COMPUTACIÓN



**Revisión sistemática de la aplicación de Redes Neuronales Artificiales,
utilizando Deep Learning, en la detección temprana del cáncer de piel**

**TRABAJO DE INVESTIGACIÓN PARA OPTAR EL GRADO ACADÉMICO DE
BACHILLER EN INGENIERÍA DE SISTEMAS Y COMPUTACIÓN**

AUTOR

Jean Edinson Guevara Briones

ASESOR

Karla Cecilia Reyes Burgos

<https://orcid.org/0000-0003-3520-5076>

Chiclayo, 2020

Índice

Resumen	3
Abstract	4
Introducción	5
Referencias	17

Resumen

Las redes neuronales artificiales (RNA's) basadas en Deep Learning han tomado mayor relevancia en el área de la medicina, ayudando a los especialistas a detectar, en una fase inicial, enfermedades mortales como el cáncer de piel. Por consiguiente, este documento presenta el análisis de las diversas investigaciones que abordan la aplicación de las RNA's en la detección temprana del cáncer de piel basándose en la metodología propuesta por Kitchenham para el desarrollo óptimo de un artículo de revisión. En base a este análisis, se pudo establecer que Alemania es el país con mayor número de investigaciones basadas en el tema del presente artículo. Además, se encontró que el modelo de arquitectura de RNA, ResNet, es el más abordado en las investigaciones seleccionadas durante el proceso de búsqueda. Por último, se concluyó que un gran porcentaje de investigaciones se desarrollaron en el continente europeo y asiático, dejando un preocupante porcentaje para el sector latinoamericano, también, se pudo corroborar que las RNA's poseen una gran versatilidad por lo cual pueden ser aplicadas en cualquier rama de la medicina y de la ciencia.

Palabras clave: Aprendizaje Profundo, Cáncer de Piel, Redes Neuronales Artificiales, Detección, Lesiones Cutáneas.

Abstract

Artificial Neural Networks (ANN's) based on Deep Learning have become more relevant in the area of medicine, helping specialists to detect, at an early stage, deadly diseases such as skin cancer. Therefore, this document presents the analysis of the various investigations that address the application of ANN's in the early detection of skin cancer based on the methodology proposed by Kitchenham for the optimal development of a review article. Based on this analysis, it was established that Germany is the country with the largest number of investigations based on the subject of this article. Furthermore, it was found that the ANN architecture model, ResNet, is the most addressed in the investigations selected during the search process. Lastly, it was concluded that a large percentage of research was carried out in the European and Asian continent, leaving a worrying percentage for the Latin American sector. It was also corroborated that the ANN's have great versatility, so they can be applied in any branch of medicine and science.

Keywords: Deep Learning, Skin Cancer, Artificial Neural Networks, Detection, Skin Lesions.

Introducción

Las RNA's basadas en la Deep Learning o aprendizaje profundo están tomando un papel importante en el tratamiento de grandes números de datos gracias a sus múltiples capas de procesamiento y su capacidad para aprender, haciendo posibles actividades como el reconocimiento de imágenes, de voz, etc., estas actividades permiten que la Deep Learning sea aplicada en diversas ramas de la ciencia [1]. Una de estas ramas es la medicina, donde las RNA's están siendo utilizadas específicamente en el diagnóstico temprano de enfermedades graves como por ejemplo el cáncer (según la Organización Mundial de la Salud [OMS], la identificación temprana del cáncer aumenta la tasa de supervivencia del individuo que la porta [2]). Sin embargo, hay tipos de cáncer donde se utiliza más esta tecnología, debido a la tasa de mortalidad que se reporta anualmente [3] y a la necesidad de reducir este número, uno de estos tipos de cáncer es el de la piel, donde la RNA es retroalimentada a través de imágenes de diversas lesiones cutáneas (malignas y benignas) con la finalidad de realizar un proceso de aprendizaje y pueda clasificar las lesiones cancerígenas y las no cancerígenas [4] mucho antes de que estas se desarrollen de forma importante.

La finalidad de este artículo es ser una motivación para futuras investigaciones, específicamente en el sector latinoamericano, pues se observa una escasez de información desarrollada en esta zona del mundo. En consecuencia, esta revisión, tiene por objetivo analizar las diversas investigaciones que aborden la aplicación de las RNA's basadas en el aprendizaje profundo a la detección temprana del cáncer de piel, iniciando la revisión en el planteamiento de interrogantes que servirán de guía al desarrollo de la investigación.

Metodología

El presente artículo de revisión seguirá el esquema definido por Kitchenham para la realización de una revisión literaria, este esquema consta de los siguientes pasos:

Preguntas de Investigación.

Estas preguntas tienen la función de servir de guía para el desarrollo de la revisión sistemática.

Tabla I: Preguntas de Investigación

P1	¿En los últimos 3 años, qué países están realizando mayores investigaciones en torno a la aplicación del aprendizaje profundo, haciendo uso de RNA's, en la detección temprana de lesiones cutáneas causantes del cáncer de piel?
P2	¿Qué arquitecturas de RNA fueron utilizadas en las investigaciones seleccionadas?

Proceso de Búsqueda

El proceso de búsqueda tiene la finalidad de encontrar artículos de investigación confiables y de un gran estándar de calidad para el desarrollo óptimo de este artículo de revisión. Cabe resaltar que el proceso de búsqueda se realizó el día 24 de junio del 2020.

Fuentes de Datos y Cadena de Búsqueda

Con la finalidad de encontrar investigaciones relevantes al tema de la presente revisión se hizo uso de las siguientes fuentes de datos: Proquest (F1), ScienceDirect (F2), WorldCat (F3). Por otro lado, las cadenas de búsqueda fueron establecidas teniendo en cuenta palabras relacionadas al aprendizaje profundo, RNA's y su aplicación en la detección del cáncer de piel.

Tabla II: Cadenas de Búsqueda

Cadena de Búsqueda – ScienceDirect y WorldCat	“deep learning” and “neural network” and “skin cáncer”
Cadena de Búsqueda -	"deep learning" and "neural network" and "skin cancer" and

Criterios de Inclusión y Exclusión

Los criterios de inclusión establecidos son los siguientes:

- Artículos de acceso libre completos.
- Artículos de investigación publicados en revistas científicas.
- Artículos publicados entre 01/06/2017 y 01/06/2020
- Publicaciones en inglés o español
- Artículos de más de 7 páginas.

Mientras que los criterios de exclusión son los siguientes:

- Tipos de documento como por ejemplo resúmenes de conferencias, encuestas y artículos de revisión.
- Artículos que aplicando Deep Learning no investiguen sobre cáncer de piel.
- Artículos que aborden la detección temprana del cáncer de piel, pero no aplicando Deep Learning.
- Artículos que aborden una comparación de efectividad de detección de cáncer de piel entre un software con Deep learning y uno o varios dermatólogos.
- Artículos duplicados.

Investigaciones Primarias

Al ejecutar la cadena de búsqueda en las fuentes de datos se obtuvieron el siguiente número de investigaciones primarias:

Tabla III: N° Artículos – Investigaciones Primarias

Fuentes de Datos	Nª Artículos
F1	148
F2	322
F3	1994

En la tabla IV se muestran el número de artículos que se obtuvieron al aplicar el primer criterio de inclusión (artículos de acceso libre completos) mediante filtros establecidos en la misma fuente de datos.

Tabla IV: N° Artículos – Primer Filtro

Fuentes de Datos	N° Artículos	N° Artículos - Inclusión
F1	148	115
F2	322	58
F3	1994	19

En la tabla V se muestran el número de artículos que se obtuvieron al aplicar el segundo criterio de inclusión (artículos de investigación publicados en revistas científicas). En la base de datos WorldCat (F3) se tuvo que realizar el criterio revisando cada artículo debido a que no existía un filtro propio de la página. No obstante, en Proquest (F1) y ScienceDirect (F2) si existió un filtro correspondiente al tipo de documento.

Tabla V: N° Artículos – Segundo Filtro

Fuentes de Datos	N° Artículos	N° Artículos - Inclusión
F1	115	76
F2	58	39
F3	19	14

En la tabla VI se muestran el número de artículos que se obtuvieron al aplicar el tercer criterio de inclusión (artículos publicados entre 01/06/2017 y 01/06/2020). Se tuvo que verificar artículo por artículo en las fuentes de datos ScienceDirect (F2) y WorldCat (F3) con el fin de que no sobrepasen el rango de fecha establecido en el criterio de inclusión, esto debido a que no existía un filtro que permitiera establecer un rango de tiempo por fechas.

Tabla VI: N° Artículos – Tercer Filtro

Fuentes de Datos	Artículos de Investigación	N° Artículos - Inclusión
F1	76	69
F2	39	39
F3	14	14

En la tabla VII se muestran el número de artículos que se obtuvieron al aplicar el primer criterio de exclusión (tipos de documento como por ejemplo resúmenes de conferencias, encuestas y artículos de revisión). Este criterio fue aplicado manualmente en todas las fuentes de datos.

Tabla VII: N° Artículos – Cuarto Filtro

Fuentes de Datos	Artículos de Investigación	N° Artículos - Exclusión
F1	69	63
F2	39	39
F3	14	14

En la tabla VIII se muestran el número de artículos que se obtuvieron al aplicar el segundo, tercer y cuarto criterio de exclusión (artículos que aplicando Deep learning no investiguen sobre cáncer de piel, artículos que aborden la detección temprana del cáncer de piel, pero no aplicando Deep Learning y artículos que aborden una comparación sobre la efectividad de detección de cáncer de piel entre un software con Deep learning y uno o varios dermatólogos). Al igual que el anterior filtro, estos criterios tuvieron que ser aplicados revisando artículo por artículo.

Tabla VIII: N° Artículos – Quinto Filtro

Fuentes de Datos	Artículos de Investigación	N° Artículos - Exclusión
F1	63	17
F2	39	8
F3	14	7

En la tabla IX se muestra el número de artículos que se obtuvieron al aplicar el cuarto criterio de exclusión (artículos duplicados). La única fuente en la que se encontró artículos duplicados fue en WorldCat (F3) donde un artículo se duplico dos veces en la misma fuente y dos artículos obtenidos en Proquest (F1) se duplicaron en WorldCat (F3).

Tabla IX: N° Artículos – Sexto Filtro

Fuentes de Datos	de Artículos de Investigación	de N° Artículos - Exclusión
F1	17	17
F2	8	8
F3	7	3

En este punto de la metodología se pudo dar respuesta a la primera pregunta de investigación (P1), que busca identificar qué países desarrollan mayores investigaciones en torno al tema del presente artículo de revisión en los últimos tres años sin excepción de idiomas. No obstante, para aquellas investigaciones cuyo desarrollo se produjo de manera colaborativa entre dos o más países se optó por establecer como país de desarrollo el lugar de la publicación. Los resultados fueron los siguientes:

Tabla X: N° Artículos por País

País	Investigación	Numero
Alemania	[5], [6], [7], [8], [9], [10]	6
China	[11], [12], [13], [14]	4
Corea del Sur	[15], [16]	2
India	[17] , [18]	2
Suiza	[19] [20]	2
Rumania	[21]	1
Holanda	[22]	1
Estados Unidos	[23]	1
Turquía	[24]	1
Brasil	[25]	1
México	[26]	1
Reino Unido	[27]	1
Noruega	[28]	1
Israel	[29]	1
Hungría	[30]	1

Irán	[31]	1
Indonesia	[32]	1

Una vez resuelta la primera interrogante de investigación, se prosiguió a aplicar el cuarto y quinto criterio de inclusión (artículos en inglés o español y artículos de más de siete páginas) obteniendo los resultados que se muestran en la tabla XI. Cabe resaltar que para poder aplicar estos criterios se tuvo que revisar artículo por artículo en todas las fuentes de datos.

Tabla XI: N° Artículos – Sexto Filtro

Fuentes de Datos	Artículos de Investigación	Nª Artículos - Inclusión
F1	17	16
F2	8	4
F3	3	0

Evaluación de Calidad

Como último paso del proceso de búsqueda se procedió a establecer criterios de calidad con el fin de contar con investigaciones confiables para el óptimo desarrollo del presente artículo de revisión. Estos criterios son los siguientes:

- Numero citas del articulo
- Factor de impacto de la revista en tiempo real

Se vio necesario contar con artículos que hayan sido citados en dos o más ocasiones, esto se verifico buscando artículo por artículo en Google Scholar e identificando el número de veces que fue citada la investigación. Además, la revista donde se ha publicado cada artículo debe poseer un factor de impacto (promedio de citas por artículo que se publique en una determinada revista) o journal impact mayor a 1.500 en el periodo 2019/2020, para facilitar la aplicación de este criterio se hizo uso de una página web especializada (<https://academic-accelerator.com>). Si un artículo no cumple con uno de los criterios de calidad, este será descartado. Cabe resaltar que esta evaluación se realizó el 5 de julio del 2020 obteniendo los resultados que se muestran en la tabla XII.

Tabla XII: N° Artículos – Evaluación de Calidad

Fuentes de Datos	Artículos de Investigación	Calidad
F1	16	11
F2	4	3
F3	0	0

Tabla XIII: Artículos Descartados

Artículo	Revista	Factor de Impacto 2019 - 2020
[6]	Open Medicine	1.340
[11]	Computer Assisted Surgery	0.700

Tabla XIV: Artículos Descartados 2

Articulo	Numero de Citas
[19]	0
[12]	1
[20]	1
[17]	0

Al finalizar el proceso de búsqueda y la evaluación de la calidad se obtuvieron un total de catorce investigaciones, las cuales se muestran en la tabla XV.

Tabla XV: Artículos Seleccionados

País	Investigación	Numero
Alemania	[5] , [7]	2
China	[13], [14]	2
Corea del Sur	[15], [16]	2
Rumania	[21]	1
Holanda	[22]	1
Turquía	[24]	1
Brasil	[25]	1
México	[26]	1
Reino Unido	[27]	1
Noruega	[28]	1
Hungría	[30]	1

Resultados y discusión

Una vez seleccionadas y analizadas las investigaciones con las que desarrollar la presente revisión sistemática se procedió a responder las preguntas de investigación planteadas al inicio de la metodología.

¿En los últimos 3 años, qué países están realizando mayores investigaciones en torno a la aplicación del aprendizaje profundo, haciendo uso de RNA's, en la detección temprana de lesiones cutáneas causantes del cáncer de piel?

De acuerdo a la Tabla X se pudo establecer que Alemania, en los últimos tres años, es el país que ha centrado mayores esfuerzos en el desarrollo de investigaciones, acerca de los distintos tipos de RNA's basados en Deep Learning que pueden ser aplicados para la detección temprana de lesiones cutáneas cancerígenas, con un numero de seis artículos de investigación, le sigue China con dos artículos menos; Corea del Sur, la India y Suiza con dos investigaciones en su haber y con un solo artículo: Rumania, Holanda, Estados Unidos,

Turquía, Brasil, México, Reino Unido, Noruega, Israel, Hungría, Irán e Indonesia. Además, se pudo identificar que Alemania fue el único país que tuvo presencia, con al menos un artículo, en las tres fuentes de datos utilizadas en esta revisión, les sigue China y Corea del Sur con presencia en dos fuentes de datos.

¿Qué arquitecturas de RNA fueron utilizadas en las investigaciones seleccionadas?

La arquitectura de una red neuronal viene a ser la forma en la que se estructura las conexiones de los diferentes nodos (neuronas) que la conforman, esta forma determina el comportamiento de una RNA y también establece los diferentes flujos que recorre las variables de entrada al momento de hacer uso de la red. Por lo general una RNA está compuesta por grupos de neuronas que cumplen una determinada función, estos grupos se denominan capas de procesamiento [33].

Existen modelos de arquitecturas de RNA's ya establecidas para determinadas actividades, no obstante, en este caso nos interesa aquellas arquitecturas que se desempeñan para la clasificación de imágenes. Algunos de estos modelos, de los diversos que existen, son utilizados en las investigaciones seleccionadas en este artículo de revisión y se muestran en la tabla XVI, respondiendo así la segunda pregunta de investigación (P2).

Tabla XVI: Arquitecturas e Investigaciones que las abordan

Arquitectura	Investigaciones	Numero
GoogleNet	[21], [25], [27], [30]	4
ResNet	[21], [5], [25], [26], [30], [14], [16], [24]	7
NasNet-Large	[21]	1
VGGNet	[25], [26], [30]	3
MobileNet	[25], [26]	2
AlexNet	[15], [28], [30], [24]	4
Inception v3	[26]	1
Xception	[26]	1
DenseNet-201	[26]	1
FCRN-88	[13]	1
Modelo creado o	[7], [22]	2

no especificado

Se puede observar en la tabla XVI que la arquitectura que más predomina en las diversas investigaciones es la ResNet, siendo utilizada en siete artículos, seguida de GoogleNet y AlexNet, ambas utilizadas en cuatro artículos respectivamente. Estos modelos son explicados brevemente a continuación.

ResNet

Es una de las arquitecturas que maneja un mayor número de capas de procesamiento, pudiendo llegar a las 152 capas según la versión del modelo que se escoja (50,101,152), gracias a esto se puede extraer hasta 2048 características de cualquier imagen procesada por una red con este modelo de arquitectura [25].

GoogleNet

Esta arquitectura, a diferencia de los demás, trabaja con 9 módulos de inicio que ayudan a optimizar el tiempo de entrenamiento de la RNA abarcando cada parámetro ingresado de manera más conveniente. Estos módulos están incluidos en las 22 capas de procesamiento que maneja, permitiéndole obtener hasta 1024 características de una imagen [25].

AlexNet

Esta arquitectura consta de 5 capas de procesamiento, de las cuales, las 2 primeras se encargan de filtrar las imágenes de entrada y las 3 últimas, de identificar las características parametrizadas durante el entrenamiento de la RNA. En total, este modelo trabaja con 4096 neuronas [30].

Conclusiones

Las RNA's están siendo una gran alternativa, en el sector médico, para la detección temprana del cáncer de piel y la reducción de la tasa de mortalidad de esta enfermedad, esto se logra debido a que las RNA's utilizan modelos de procesamiento y clasificación de imágenes previamente entrenadas con millones de imágenes de diferentes tipos de lesiones cutáneas benignas y malignas.

Sin embargo, en este artículo se pudo concluir lastimosamente que en Latinoamérica este tema no se está abordando lo suficiente, centrándose más en el continente europeo (Alemania)

y asiático (China), lo cual genera preocupación debido a que el continente americano se caracteriza por tener climas muy cambiantes y esto puede causar estragos importantes en la piel. No cabe duda que las RNA's tomarían un papel fundamental en esta zona del mundo.

Además, se pudo identificar, en la tabla XVI, que las arquitecturas ResNet, GoogleNet y AlexNet son las más utilizadas en lo que viene a ser clasificadores de imágenes por sus múltiples capas de procesamiento y el número de características que puede identificar de una imagen.

Por último, las RNA's se pueden aplicar en la detección de diversas enfermedades ya que pueden ser utilizadas para analizar no solo imágenes de lesiones cutáneas sino también tomografías, rayos x, etc. dejando constancia de lo cuan versátiles pueden llegar a ser.

Agradecimientos.

Este trabajo se pudo llevar a cabo, gracias a la Ing. Reyes Burgos Karla Cecilia y sus recomendaciones impartidas en cada asesoría, a mi casa de estudios, que me facilitó el acceso a las fuentes de datos utilizadas en el proceso de búsqueda y en especial al apoyo brindado por mi familia durante la realización del presente artículo..

Referencias

- [1] Y. LeCun, Y. Bengio y G. Hinton, «Deep learning,» *nature*, vol. 521, n° 7553, pp. 436-444, 2015.
- [2] O. M. d. I. Salud, «Organizacion Mundial de la Salud,» 3 Febrero 2017. [En línea]. Available: <https://www.who.int/es/news-room/detail/03-02-2017-early-cancer-diagnosis-saves-lives-cuts-treatment-costs>.
- [3] O. M. d. I. Salud, «Cancer,» Organizacion Mundial de la Salud, 12 Septiembre 2018. [En línea]. Available: <https://www.who.int/es/news-room/fact-sheets/detail/cancer>.
- [4] A. Esteva, B. Kuprel, R. A. Novoa, J. Ko, S. M. Swetter, H. M. Blau y S. Thrun, «Dermatologist-level classification of skin cancer with deep neural networks,» *Nature*, n° 542, pp. 115-118, 2017.
- [5] T. J. Brinker, A. Hekler, A. H. Enk y C. von Kalle, «Enhanced classifier training to improve precision of a convolutional neural network to identify images of skin lesions,» *PLoS One*, vol. 14, n° 6, 2019.
- [6] H. J. Gao, L. Zhang, J. Zhang y B. Badami, «Optimization of the Convolutional Neural Networks for Automatic Detection of Skin Cancer,» *Open Medicine*, vol. 15, n° 1, pp. 27-27, 2019.
- [7] S. Nasiri, J. Helsper, M. Jung y M. Fathi, «DePicT Melanoma Deep-CLASS: a deep convolutional neural networks approach to classify skin lesion images,» *BMC Bioinformatics*, vol. 21, pp. 1-13, 2020.
- [8] A. Hekler, J. Sven Utikal, A. H. Enk, C. Berking, J. Klode, D. Schadendorf, P. Jansen, C. Franklin, T. Holland-Letz, D. Krahl, C. von Kalle, S. Fröhling y T. J. Brinker, «Pathologist-level classification of histopathological melanoma images with deep neural networks,» *European Journal of Cancer*, vol. 115, pp. 79-83, 2019.
- [9] W. Sondermann, J. Sven Utikal, A. H. Enk, D. Schadendorf, J. Klode, A. Hauschild, M. Weichenthal, L. E. French, C. Berking, B. Schilling, S. Haferkamp, S. Fröhling, C. Kalle y T. J. Brinker, «Prediction of melanoma evolution in melanocytic nevi via artificial intelligence: A call for prospective data,» *European Journal of Cancer*, vol. 119, pp. 30-34, 2019.
- [10] A. Hekler, N. K. Jakob, E. Kriehoff-Henning y J. S. Utikal, «Effects of Label Noise on Deep Learning-Based Skin Cancer Classification,» *Frontiers in Medicine*, 2020.
- [11] X. Zhang, «Melanoma segmentation based on deep learning,» *Computer Assisted Surgery*, vol. 22, n° sup1, 2017.
- [12] A. Feng-Ping, «Medical Image Classification Algorithm Based on Weight Initialization-Sliding Window Fusion Convolutional Neural Network,» *Complexity*, vol. 2019, 2019.
- [13] Y. Li y L. Shen, «Skin Lesion Analysis towards Melanoma Detection Using Deep Learning Network,» *Sensors*, vol. 18, n° 2, p. 556, 2018.
- [14] S. Guo y Z. Yang, «Multi-Channel-ResNet: An integration framework towards skin lesion analysis,» *Informatics in Medicine Unlocked*, vol. 12, pp. 67-74, 2018.
- [15] D. Ulzii-Orshikh, K.-K. Lee, J.-Y. Choi y M. Lee, «The skin cancer classification using deep convolutional neural network,» *Multimedia Tools and Applications*, vol. 77, n° 8, pp. 9909-9924, 2018.
- [16] S. Seog Han, M. Shin Kim, W. Lim, G. Hun Park, I. Park y S. Eun Chang,

- «Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm,» *Journal of Investigative Dermatology*, vol. 138, n° 7, pp. 1529-1538, 2018.
- [17] V. Srividhya, K. Sujatha, R. Ponmagal, G. Durgadevi y L. Madheshwaran, «Vision based Detection and Categorization of Skin lesions using Deep Learning Neural networks,» *Procedia Computer Science*, vol. 171, pp. 1726-1735, 2020.
- [18] M. Ali Kadampu y S. Al Riyaaee, «Skin cancer detection: Applying a deep learning based model driven architecture in the cloud for classifying dermal cell images,» *Informatics in Medicine Unlocked*, vol. 18, 2020.
- [19] K. Zafar, S. O. Gilani, A. Waris, A. Ahmed, M. Jamil, M. Nasir Khan y A. Sohail Kashif, «Skin Lesion Segmentation from Dermoscopic Images Using Convolutional Neural Network,» *Sensors*, vol. 20, n° 6, p. 1601, 2020.
- [20] M. Naseer Bajwa, K. Muta, M. I. Malik, S. Ahmed Siddiqui, S. A. Braun, B. Homey, A. Dengel y S. Ahmed, «Computer-Aided Diagnosis of Skin Diseases Using Deep Neural Networks,» *Applied Sciences*, vol. 10, n° 7, p. 2488, 2020.
- [21] H. El-Khatib, D. Popescu y L. Ichim, «Deep Learning–Based Methods for Automatic Diagnosis of Skin Lesions,» *Sensors*, vol. 20, n° 6, p. 1753, 2020.
- [22] Q. Abbas y M. E. Celebi, «DermaDeep-A classification of melanoma-nevus skin lesions using multi-feature fusion of visual features and deep neural network,» *Multimedia Tools and Applications*, pp. 1-22, 2019.
- [23] P. M. Burlina, N. J. Joshi, E. Ng, S. D. Billings, A. W. Rebman y J. Aucott, «Automated detection of erythema migrans and other confounding skin lesions via deep learning,» *Computers in Biology and Medicine*, vol. 105, pp. 151-156, 2019.
- [24] S. Serte y H. Demirel, «Gabor wavelet-based deep learning for skin lesion classification,» *Computers in Biology and Medicine*, vol. 113, 2019.
- [25] A. G. Pacheco y R. A. Krohling, «The impact of patient clinical information on automated skin cancer detection,» *Computers in Biology and Medicine*, vol. 116, 2020.
- [26] J.-A. Almaraz-Damian, V. Ponomaryov, S. Sadovnychiy y H. Castillejos-Fernandez, «Melanoma and Nevus Skin Lesion Classification Using Handcraft and Deep Learning Feature Fusion via Mutual Information Measures,» *Entropy*, vol. 22, n° 4, p. 484, 2020.
- [27] X. Zhang, S. Wang, J. Liu y T. Cui, «Towards improving diagnosis of skin diseases by combining deep neural network and human knowledge,» *BMC Medical Informatics and Decision Making*, vol. 18, n° Suppl 2, 2018.
- [28] T. Majtner, S. Yildirim-Yayilgan y J. Y. Hardeberg, «Optimised deep learning features for improved melanoma detection,» *Multimedia Tools and Applications*, vol. 78, n° 9, pp. 11883-11903, 2019.
- [29] D. A. y D. E.O., «Skin cancer detection by deep learning and sound analysis algorithms: A prospective clinical study of an elementary dermoscope,» *EBioMedicine*, vol. 43, pp. 107-113, 2019.
- [30] B. Harangi, «Skin lesion classification with ensembles of deep convolutional neural networks,» *Journal of Biomedical Informatics*, vol. 86, pp. 25-32, 2018.
- [31] S. Fooladi, H. Farsi y S. Mohamadzadeh, «Detection and Classification of Skin Cancer Using Deep Learning,» *Journal of Birjand University of Medical Sciences*, vol. 26, n° 1, pp. 44-53, 2019.
- [32] T. R. Savera, W. H. Suryawan y A. Wahyu Setiawan, «Deteksi Dini Kanker Kulit menggunakan K-NN dan Convolutional Neural Network,» *Jurnal Teknologi Informasi*

dan Ilmu Komputer, vol. 7, nº 2, pp. 373-378, 2020.

- [33] P. Larrañaga, I. Inza y A. Moujahid, «Tema 8. redes neuronales,» de *Redes Neuronales*, Pais Vasco, 1997, p. 17.