

# Técnicas De Inteligencia Artificial Aplicadas A Pruebas Capilaroscópicas Para La Detección De Enfermedades Autoinmunes Que Comprometen La Circulación Sanguínea.

M. Alvarado<sup>1\*</sup>, A. Campos<sup>2</sup>, V. Carrizales<sup>3</sup>, C. Díaz<sup>4</sup>, S. Huacre<sup>5</sup>

<sup>1</sup>Egresada de Ingeniería Biomédica, Instituto Politécnico Nacional, Ciudad de México, México.

<sup>2</sup>Estudiante de Ingeniería Biomédica, Universidad Tecnológica del Perú, Lima, Perú.

<sup>3</sup>Egresado de Ingeniería Biomédica, Universidad Autónoma de San Luis Potosí, San Luis Potosí, México.

<sup>4</sup>Estudiante de Bioingeniería Médica, Universidad Autónoma del Estado de México, Toluca, México.

<sup>5</sup>Estudiante de Ingeniería Biomédica, Universidad Nacional Mayor de San Marcos, Lima, Perú.

\*malvaradol1500@alumno.ipn.mx

**Abstract**— The main purpose of this paper is the development of an artificial intelligence model for the automatic classification of images, in order to optimize the detection of pathologies through capillaroscopy tests of the nail fold, this technique allows obtaining images of the morphology of the capillaries in the proximal nail fold of the hands. A database consisting of 300 images of capillaries corresponding to the nail fold was used. These images were labeled as healthy or diseased subject depending on the patterns of the capillaries. The method used to classify the images into two classes was transfer learning from a MobileNet V2 base model. The results show that the network is capable of detecting the presence of pathological patterns in the capillaries obtaining an AUC value of 0.932.

**Palabras clave**— Capilaroscopia, inteligencia artificial, patologías autoinmunes, redes neuronales convolucionales residuales, transferencia de aprendizaje.

## I. INTRODUCCIÓN

Las pruebas capilaroscópicas son estudios diagnósticos del área de reumatología, de las cuales se obtiene imágenes directas in vivo que aportan una gran cantidad de información acerca de la microcirculación cutánea. Cabe señalar que, la capilaroscopia es una prueba totalmente indolora, rápida, eficiente, costeable, fácil de replicar y ayuda a diagnosticar múltiples patologías, entre ellas, las autoinmunes que comprometen la circulación sanguínea [1] [2].

Generalmente las enfermedades autoinmunes se caracterizan por ser incurables, en las que el sistema inmunitario ataca equivocadamente al cuerpo, y en consecuencia se produce una rápida disminución de la capacidad vital de los pacientes [3]. Por lo mencionado, resulta crucial detectar estas patologías a tiempo para poder garantizar una atención médica oportuna, mejorando la calidad de vida de los pacientes [1].

En Latinoamérica, las pruebas capilaroscópicas no son tan reconocidas en el ámbito médico, lo que conlleva que exista un vacío de artículos científicos [4], por ello, actualmente los ingenieros biomédicos a l conjuntar disciplinas como la programación, fisiología y fisiopatología aumentan la capacidad de solucionar una gran diversidad de problemáticas en el sector salud, siendo aptos para diseñar

softwares de apoyo en la toma de decisiones en diagnósticos clínicos [5].

A nivel mundial, gracias a los avances en inteligencia artificial y una mayor inversión en los sectores de desarrollo de tecnologías se ha aumentado la capacidad de los equipos de cómputo, por ende, se ha comprobado que contar con un software inteligente de alto alcance puede denotar una reducción de tiempo y costos [6] [7]. Por ello, en los últimos 10 años se dio pie al desarrollo de diversos softwares inteligentes que ayudaron a miles de diagnósticos en distintas especialidades como genética y reumatología [8].

La capilaroscopia se puede obtener con diferentes instrumentos como lupas estereoscópicas, microscopios ópticos, oftalmoscopios, dermatoscopios o videocapilaroscopios con sonda de contacto, siempre teniendo en cuenta las condiciones de temperatura e iluminación. Por lo general, las pruebas se realizan en los dedos de las manos, del segundo al quinto dedo, debido a que tiene como ventaja una mejor visualización de los vasos sanguíneos dentro de los capilares y al mismo tiempo el poder observar el flujo en la microcirculación, como se observa en la Fig.1 [9] [10].

Una vez realizada la prueba, se pueden observar los principales parámetros que determinarán si los pacientes están sanos o presentan algún tipo de patología [10].




Fig. 1. Pliegue ungueal proximal. A. Esquema de la disposición normal de los capilares. B. Imagen digital (32X) de la distribución normal de los capilares periungueales [1].

## A. Patrones capilaroscópicos y patologías autoinmunes

Se describen dos patrones con base en la presencia de las alteraciones detectadas en la capilaroscopia.

1) *Patrón normal*: Los capilares periungueales transcurren paralelos a la superficie cutánea del pliegue

ungueal y tienen una disposición en forma de semicírculo que acompaña a la matriz ungueal con un color rojo sobre una base más clara, lo cual se denomina polaridad conservada [10]. Por lo general, un patrón normal presenta de 7 a 17 capilares claramente visibles dispuestas en forma de U, también se observa la ausencia de capilares dilatados, gigantes, tortuosidades y hemorragias, estos patrones tienden a mantenerse constantes en el tiempo [11] [12].

2) *Patrón patológico*: Este tipo de patrón presenta múltiples alteraciones, tales como tortuosidades, aumento del diámetro de los capilares, reducción de la densidad de los capilares, neoangiogénesis, hemorragias o trombosis [10]. Estas pueden ser indicativo de más de una enfermedad, las más concurrentes son la esclerosis sistémica, dermatomiositis, enfermedad mixta del tejido conectivo, fenómeno de Raynaud, síndromes de superposición, lupus eritematoso sistémico e inclusive algunas patologías que comprometen la circulación como lo son la diabetes mellitus y la hipertensión arterial [12].

### B. La capilaroscopia e inteligencia artificial

Generalmente en el campo de la capilaroscopia, la inteligencia artificial es empleada como una herramienta de diagnóstico que ayuda al profesional de la salud a analizar, con mayor sensibilidad, la microcirculación y la arquitectura de los capilares y gracias a ello, la detección precoz de patrones potencialmente patológicos [1] [13].

Por lo mencionado, el diagnóstico médico de cualquier enfermedad requiere ser muy preciso, en consecuencia, esta investigación hace uso de una red neuronal convolucional, la cual es una de las herramientas para la clasificación de imágenes con mayor porcentaje de precisión en el ámbito de la inteligencia artificial [14]. Esta red neuronal consta de varias etapas en las que existen diversos filtros que constituyen un conjunto de parámetros entrenables. Estos pueden convolucionar las imágenes que se les proporcione a la entrada para la detección de ciertos bordes, formas y/o patrones para ayudar a identificar las principales diferencias entre ellos [15].

## II. METODOLOGÍA

### A. Base de datos

La base de datos está constituida por 300 imágenes con una resolución de 1625 x 2032 píxeles, que fueron extraídas por medio de un dermatoscopio, estas imágenes corresponden a una población de hombres y mujeres con un rango de edad entre 23 y 58 años que presentan patologías como Artritis Reumatoide, Lupus y Síndrome de Sjögren. Posteriormente, se clasificó de forma binaria y se asignó una etiqueta, sano o enfermo, dependiendo de los patrones. En la base de datos se identificó, gracias a la colaboración del médico especialista en reumatología David Rivera Navarro,

208 imágenes de pacientes enfermos (69.3%) y 92 imágenes de pacientes sanos (30.7%).

### B. Preprocesado de imágenes

Dado el método de adquisición de imágenes del examen de capilaroscopia, es innato que se capturen brillos o deslumbramientos de alta intensidad que no contienen información útil para la clasificación [15]. Por ello, resulta necesario aplicar métodos de corrección de resplandores para alimentar al modelo de clasificación con ejemplos más apropiados. Se utilizó el algoritmo de eliminación de brillos basado en el método inpaint de OpenCV en Python [16] que separa a la imagen en sus componentes de matiz, saturación y brillo, como se muestra en la Fig.2. Esto permite identificar las áreas en donde se encontraba una mayor luminosidad, y a partir de la clonación de píxeles vecinos, se reconstruyó la imagen en una aproximación de su real versión sin este tipo de elementos no deseados [17].



Fig. 2. Preprocesado de las imágenes capilaroscópicas.

### C. Arquitectura de la Red Neuronal Convolucional

Se propuso un modelo de arquitectura basado en el modelo de MobileNet V2, un tipo de red convolucional residual, al cual se le aplicó transferencia de aprendizaje, es decir, se ajustaron los parámetros y tomaron los pesos de un modelo de red neuronal preentrenado [18], en este caso ImageNet, y se adicionó una capa convolucional Global Pooling, seguida de una capa densa con regularización Dropout [19]. La Fig. 3 presenta la arquitectura de red neuronal.

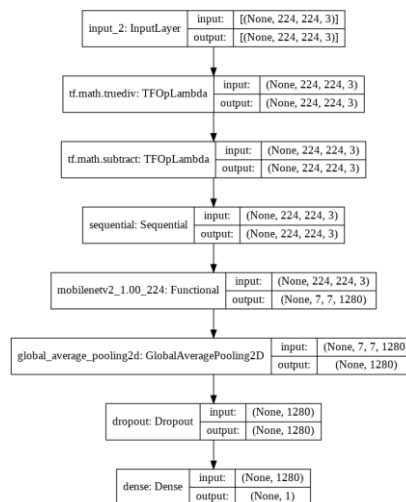


Fig. 3. Arquitectura y parametros de la red neuronal convolucional.

### D. Entrenamiento de la Red Neuronal Convolucional

La red neuronal se entrenó dentro de Google Colaboratory, el cual es un servicio cloud de Google en el

que se permite ejecutar código en lenguaje Python en el navegador, utilizando bibliotecas como Keras, Scikit-Learn, Matplotlib, Numpy y mlxtend. Google Colaboratory ofrece una GPU de acceso libre Tesla T4 usada para el entrenamiento y simulación.

Debido a la reducida cantidad de imágenes, se entrenaron 4 muestras ordenadas aleatoriamente. Primero, de un total de 2'259,265 parámetros, se entrenó 1,281 parámetros correspondientes a las capas superiores del modelo en cada una de las muestras, a una tasa de aprendizaje de 0.001 y con los pesos entrenados de la base de datos "ImageNet". Posteriormente, se descongeló 2'225,153 parámetros del modelo base MobileNetV2, con una tasa de aprendizaje muy pequeña. Las divisiones de los datos de entrenamiento y validación para las muestras fueron dos de 85%-15% y dos de 75%-25%. La Tabla I muestra los parámetros de entrenamiento por muestras.

TABLA I  
PARÁMETROS A UTILIZAR EN LAS CNN PARA EL ENTRENAMIENTO POR MUESTRAS

Muestra	TL	TANE	ET	EE	TAE	Div.	AUCV
1	8	0.001	78	48	0.00001	75-25	0.932
2	8	0.001	52	20	0.00001	85-15	0.817
3	16	0.001	63	17	0.00002	75-25	0.717
4	8	0.001	52	30	0.0001	85-15	0.733
<b>Media</b>							<b>0.7998</b>

TL = Tamaño de lote, TANE = Tasa de Aprendizaje en modelo base No Entrenable, ET = Épocas Totales, EE = Épocas en modelo Entrenable, TAE = Tasa de Aprendizaje en modelo base Entrenable, Div. = Divisiones de los datos, AUCV = Área bajo la curva ROC en la Validación.

### III. RESULTADOS.

Se tomó como principal indicador los valores de AUC de los datos de validación, porque es imperativo considerar los falsos negativos y falsos positivos obtenidos debido a la naturaleza del sistema de ayuda diagnóstica. La propuesta del modelo de la red neuronal convolucional en diferentes muestras indica que trabajando con ciertos parámetros es posible alcanzar un valor de AUC igual a 0.932 obtenida en la muestra 1. Las muestras 2, 3 y 4 indicaron valores de AUC iguales a 0.817, 0.717 y 0.733 respectivamente, observable en la Fig. 4a y 4b y Fig. 5.





Fig. 4. a) Evolución del valor AUC de los datos de entrenamiento y validación durante el entrenamiento con el modelo base entrenable (pesos descongelados). b) Curvas ROC de cada muestra.




Fig. 5 Matrices de confusión obtenidas de cada muestra para el grupo de validación. 0: Sanos, 1: Enfermos. a) Primera muestra. b) Segunda muestra. c) Tercera muestra. d) Cuarta muestra.

### IV. DISCUSIÓN.

Teniendo en cuenta que se trabaja con un sistema de diagnóstico de grado médico, se busca que el número de falsos negativos sea mínimo. De modo que, un alto porcentaje en los verdaderos positivos entre todos los casos positivos, como se muestra en la Fig. 5, aumenta la confiabilidad de dicho sistema al enfocarse en la sensibilidad, y cuanto mayor sea esta, más enfermos serán diagnosticados adecuadamente.

Uno de los mayores retos a superar en el desarrollo del proyecto fue el preprocesamiento de las imágenes, en virtud de la existencia de inconsistencias al adquirir las imágenes de los capilares, tales como imágenes descentradas y con un resplandor intenso, imposibilitando un adecuado análisis de estas. Esto fue resuelto mediante la utilización de técnicas de aumento de imágenes y eliminación de deslumbramiento.

Generalmente, en redes neuronales convolucionales se trabajan con miles o millones de patrones de entrenamiento. En el presente trabajo, el número reducido de imágenes empleadas juega un papel importante en la mejora de predicción del modelo. La autora Gil [20] menciona, que a pesar de tener buenos resultados con su red residual obteniendo un 93.63% de coincidencias en su clasificador,

es vital entrenar a las futuras redes neuronales con recortes de las imágenes para tratar de aumentar la segmentación de los detalles de los capilares. Esto sugiere que la arquitectura de la red neuronal propuesta para este tipo de imágenes segmentadas tiene que ser de tipo residual, y junto a técnicas de aumento de datos, el porcentaje de coincidencia en las predicciones aumentaría considerablemente, logrando a su vez, disminuir errores y hacer más confiable el software.

## V. CONCLUSIÓN

Este trabajo presenta el desarrollo de una red neuronal convolucional para detectar la existencia de patologías autoinmunes basados en imágenes capilaroscópicas del lecho ungueal.

Dentro del abanico de modelos de arquitectura de redes neuronales y tomando en cuenta las problemáticas desarrolladas en el proyecto, se optó por utilizar una arquitectura residual y evaluar su rendimiento a partir de los valores del área bajo la curva ROC (AUC). Es así, que se logró construir un sistema de detección con buena sensibilidad, AUC igual a 0.932, capaz de clasificar si la imagen de capilaroscopia evaluada presenta o no patrones patológicos autoinmunes. Aunque los resultados de las clasificaciones binarias son aceptables, existe un margen de mejora en la especificidad de la clasificación.

Al analizar los resultados obtenidos, un área de oportunidad observada es la reducción de brillo en las imágenes capilaroscópicas obtenidas. Una posible solución ante esta problemática es la utilización de un lente polarizado o un dermatoscopio con luz polarizada, para tener la menor cantidad de deslumbramientos posible.

Como trabajos futuros, se pretende elaborar un sistema clasificador multiclases, es decir, capaz de identificar entre diferentes patologías autoinmunes previamente mencionadas en el presente trabajo. Además, con el propósito de mejorar el desempeño de la red se propone incrementar la cantidad y calidad de la base de datos.

## REFERENCIAS

- [1] V. Garra, N. Danese, M. Rebella, and E. Cairolì, "Capilaroscopia en el diagnóstico de las enfermedades autoinmunes sistémicas," *Rev. Méd. Urug.*, vol. 28, no. 2, pp. 89–99, 2012.
- [2] S. Lambova and U. Müller-Ladner, "The role of capillaroscopy in differentiation of primary and secondary raynaud's phenomenon in rheumatic diseases: a review of the literature and two case reports," *Rev. Rheumatol. Int.*, vol. 29, sin número, pp. 1263–1271, 2009. Accessed on: June, 20th, 2021, DOI:10.1007/s00296-009-1019-z, [Online].
- [3] N. Jadueand I. González, "Inmunopatogenia de las enfermedades autoinmunes," *Rev. Med. Clin. Condes.*, vol. 23, no. 4, pp. 464–472. 2012. Accessed on: June, 20th, 2021. DOI:10.1016/S0716-8640(12)70337-1, [Online].
- [4] A. Facio, C. Velásquez, A. Zapata, L. Rodríguez, and M. Mesa, "Characteristics of nailfold videocapillaroscopy and antinuclear antibodies in a cohort of patients with systemic autoimmune disease with raynaud's phenomenon," *Revista Colombiana de Reumatología (English Edition)*, vol. 25, no. 3, pp. 169–17, 2018. Accessed on: June, 20th, 2021, DOI:10.1016/j.rcreue.2019.01.006, [Online].
- [5] J. Chacón, A. Flórez, and J. Rodríguez, "La inteligencia artificial y sus contribuciones a la física médica y la bioingeniería," *Rev.Mundo FESC.*, vol. 5, no. 9, pp. 60–63.,2015. Accessed on: June, 16th, 2021, [Online].
- [6] F. UNAM. "La evolución de la inteligencia artificial," *Rev. ¿Cómo ves?*, sin volumen, sin página. 2019. Accessed on: June, 20th, 2021, Available on: <https://www.fundacionunam.org.mx/unam-al-dia/la-evolucion-de-la-inteligencia-artificial/>, [Online].
- [7] M. d. C. Expósito and R. Ávila, "Aplicaciones de la inteligencia artificial en la medicina: perspectivas y problemas," *Rev. ACIMED.*, vol. 17, no. 5, pp. 60–63, 2008.
- [8] F. Jiang, Y. Jiang, H. Zhi, Y. Dong, H. Li, S. Ma, Y. Wang, Q. Dong, H. Shen, and Y. Wang, "Artificial intelligence in healthcare: past, present and future," *Stroke and Vascular Neurology*, vol. 2, no. 4, pp.230–243, 2017. Accessed on: June, 22th, 2021, DOI :10.1136/svn-2017-000101, [Online]-
- [9] M. Gutiérrez, C. Pineda, E. Soriano, and C. Bertolazzi, "La capilaroscopia en reumatología. Conceptos básicos de una valiosa técnica de imágenes," *Rev. Chil. Reumatol.*, vol. 31, no. 1, pp. 16–22, 2015.
- [10] J. Restrepo, M. Gutiérrez, R. De Angelis, and W. Grassi, "El papel de la capilaroscopia del lecho ungueal en reumatología," *Rev. Colomb. Reumatol.*, vol. 15, no. 3, p. 187–195, 2008.
- [11] S. Ocampo, M. Villarreal, A. Villarreal, and J. Ocampo, "Capilaroscopia: una herramienta diagnóstica valiosa," *Actas Dermosifiliogr.*, vol.100, no.5, pp.347–352,2019. Accessed on: June, 6th, 2021, DOI:10.1016/j.ad.2018.10.018, [Online].
- [12] A. Felis and M. Olesińska, "Capillaroscopy-arolein modern rheumatology, reumatologia/rheumatology," *Rev. Reumatol.*, vol.54, no. 2, pp.67–72,2016. Accessed on: June, 12th, 2021, DOI:10.5114/reum.2016.60215, [Online].
- [13] H. Fukuda, R. Ishihara, Y. Kato, T. Matsunaga, T. Nishida, T. Yamada, H. Ogiyama, M. Horie, K. Kinoshita, and T. Tada, "Comparison of performances of artificial intelligence versus expert endoscopists for real-time assisted diagnosis of esophageal squamous cell carcinoma (with video)," *Gastrointest. Endoscopy*, vol. 92, no. 4, pp. 6848–855, 2020. Accessed on: June, 13th, 2021, DOI: 10.1016/j.gie.2020.05.043, [Online].
- [14] A. Kashyap, "Artificial intelligence & medical diagnosis," *Sch. J. App. Med. Sci.*, vol. 6, no. 12, pp. 4982–4985, 2018. Accessed on: June, 6th, 2021, DOI:10.21276/sjams.2018.6.12.61, [Online].
- [15] M. Halicek, J. Little, X. Wang, A. Chen, and B. Fei, "Optical biopsy of head and neck cancer using hyperspectral imaging and convolutional neural networks," *J. Biomed. Opt.*, vol. 24, no. 3, p. 036007, 2019. Accessed on: June, 17th, 2021, DOI: 10.1117/1.JBO.24.3.036007, [Online].
- [16] Doxygen. (2020, Oct. 11). "Image Inpainting". Accessed on: [https://docs.opencv.org/4.5.0/df/d3d/tutorial\\_py\\_inpainting.html](https://docs.opencv.org/4.5.0/df/d3d/tutorial_py_inpainting.html), [Online].
- [17] H. Lange, "Automatic glare removal in reflectance imagery of the uterine cervix," *Progress in Biomedical Optics and Imaging- Proceedings of SPIE*, vol. 5747, 2005. Accessed on: June, 15th, 2021, DOI:10.1117/12.596012, [Online].
- [18] C. Ajmi, J. Zapata, S. Elferchichi, A. Zaafouri and K. Laabidi. "Deep Learning Technology for Weld Defects Classification Based on Transfer Learning and Activation Features", *Rev. Hindawi: Advances in Materials Science and Engineering*, vol. 2020, 2020. Accessed on: September, 7th, 2021, DOI:10.1155/2020/1574350, [Online].
- [19] M. Abadi and et al., "Tensorflow: A system for large-scale machine learning," in *12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16)*, 2016, pp. 265–283. Accessed on: June, 19th, 2021, Available: <https://www.usenix.org/system/files/conference/osdi16/osdi16-abadi.pdf>, [Online].
- [20] J. Gil, "Herramienta automática para el análisis y clasificación de imágenes de capilaroscopia del lecho ungueal," *Trabajo de fin de grado, Universidad de Coruña, La Coruña, España*, 2019. Accessed on: June, 15th, 2021, Available: <http://hdl.handle.net/2183/25123>, [Online].