

# Clasificador Inteligente de Imágenes de Cáncer de Mama utilizando Redes Convolucionales y Ant Lion Optimizer.

Ignacio Bosch<sup>1</sup>, Reyna Der Boghosian<sup>1</sup>

<sup>1</sup> Laboratorio de Investigación Desarrollo e Innovación  
idi@cys.com.ar

<sup>2</sup> C & S Informática S.A

**Abstract.** Las imágenes de ultrasonido son herramientas clave en el diagnóstico del cáncer de mama, ya que permiten evaluar el estado fisiopatológico del tejido mamario. No obstante, su interpretación requiere la intervención de especialistas y puede presentar desafíos en diagnósticos. En este trabajo se propone un sistema inteligente para la clasificación automática de imágenes ecográficas de mama, utilizando redes neuronales convolucionales (CNN) optimizadas mediante algoritmos metaheurísticos. Se implementaron dos arquitecturas: una CNN estándar y la red pre-entrenada ResNet50. La optimización de hiperparámetros se realizó utilizando el algoritmo metaheurístico Ant Lion Optimizer (ALO), con el objetivo de mejorar la exactitud en la clasificación. Los resultados experimentales muestran una mejora significativa en el rendimiento de ambos modelos: la CNN incrementó su exactitud del 56.57 % al 81.57 %, mientras que ResNet50 mejoró de 86.84 % a 92.00 %. Estos resultados evidencian el potencial de combinar arquitecturas de aprendizaje profundo con técnicas de optimización evolutiva para tareas de diagnóstico asistido por imágenes, especialmente en el contexto del cáncer de mama.

**Keywords:** cáncer de mama, Ant Lion Optimizer, redes neuronales, clasificador de imágenes, inteligencia artificial, metaheuristicas

## 1 Introducción

Cada año, el cáncer de mama causa cerca de medio millón de muertes en mujeres en todo el mundo, siendo una de las principales causas de mortalidad femenina (ver Sung et al., 2021). Aunque las mamografías y avances en tratamiento han logrado reducir la mortalidad en un 30% en las últimas tres décadas, el diagnóstico sigue siendo un desafío debido a la complejidad de las imágenes tumorales. Las redes neuronales convolucionales, por sus siglas en inglés) han demostrado ser herramientas efectivas al automatizar la extracción de características y análisis de datos, superando las limitaciones de los modelos tradicionales de diagnóstico asistido por computadora (ver Balasubramaniam et al., 2023). Sin embargo, el diseño y ajuste de sus hiperparámetros, como la tasa de aprendizaje, tamaño

del lote y *dropout*, sigue siendo un proceso crítico y experimental, dado que impacta directamente en la precisión y generalización del modelo (ver Gaspar et al., 2021).

La selección de estos hiperparámetros para cualquier problema es un proceso basado en prueba y error. Existen una variedad de trabajos que buscan optimizar, por ejemplo, la cantidad de filtros de las capas convolucionales (ver Rojas et al., 2022) y así obtener un diseño automatizado de una arquitectura de red neuronal convolucional. Otro ejemplo es un estudio (ver Golnoori et al., 2023) en el cual optimizan los valores de hiperparámetros como: tasa de aprendizaje, tamaño del lote, y muchos otros, con el fin de lograr un diseño adecuado de arquitectura de red neuronal para clasificación de lesiones en la piel. Por último, hay un trabajo (ver Mamindla et al., 2023) que utiliza estas metodologías aplicadas a un caso de estudio con mamografías y la metaheurística *Artificial Bee Colony* el cual se consideró como referencia para este proyecto.

Los trabajos anteriormente mencionados, hacen hincapié en la implementación de algoritmos metaheurísticos para el diseño optimizado de la arquitectura de red neuronal convolucional, pero en ningún caso se hace un relevamiento de la optimización de los algoritmos metaheurísticos utilizados.

En este trabajo, buscamos optimizar la tasa de aprendizaje mediante la metaheurística *Ant Lion Optimizer* (ver Mirjalili, 2015) para mejorar el desempeño de las redes neuronales convolucionales en la clasificación de tumores en imágenes de mama por ultrasonido. Para lo cual comparamos dos arquitecturas: una CNN (ver Ketkar et al., 2021) estándar y una arquitectura ResNet50 (ver He et al., 2016), ambas optimizadas con el algoritmo ALO.

El artículo lo estructuramos de la siguiente manera: la sección 2 incluye la descripción de la metodología propuesta, así como los algoritmos y las arquitecturas implementadas. Luego, la sección 3 presenta los resultados experimentales obtenidos. Posteriormente, en la sección 4 discutimos los resultados y en la sección 5 concluye el artículo.

## 2 Metodología

En esta sección presentamos la metodología utilizada durante el desarrollo del presente trabajo. Además, introducimos conceptos teóricos acerca del proceso de convolución y de la metaheurística *ant lion optimizer*.

### 2.1 Convolución

Las redes neuronales convolucionales combinan capas convolucionales y densas para procesar entradas tridimensionales definidas por ancho ( $W$ ), alto ( $H$ ) y profundidad ( $D$ ), como en imágenes digitales, donde  $D = 1$  para blanco y negro o  $D = 3$  para RGB. A diferencia de las capas densas, que capturan patrones globales, las convolucionales identifican patrones locales, logrando invariancia a la traslación y un aprendizaje jerárquico. Cada capa aplica múltiples filtros que generan mapas de características compartiendo pesos sinápticos dentro de un

mismo mapa, reduciendo parámetros, mientras que diferentes mapas emplean pesos únicos para mayor variabilidad.

## 2.2 Algoritmo de optimización

Los métodos de optimización son esenciales para tomar decisiones que mejoren el desempeño en cualquier tipo de proceso. Los métodos exactos (ramificación y acotación, A\*) descomponen problemas complejos garantizando soluciones óptimas, pero con altos costos computacionales. Por ello, las metaheurísticas, que son métodos de optimización inspirados en procesos, tales como: procesos biológicos, comportamiento de enjambre, procesos evolutivos y principios físicos, ofrecen soluciones cercanas al óptimo global pero con un menor costo computacional que los métodos exactos (ver Talbi, 2009).

Estas estrategias (metaheurísticas) permiten explorar y explotar eficientemente el espacio de búsqueda, abordando problemas complejos en tiempos razonables, sin garantizar la mejor solución global. Es por esto que las metaheurísticas pertenecen a los métodos aproximados (ver Talbi, 2009).

El algoritmo Ant Lion Optimizer es una metaheurística bioinspirado, debido a que se inspira en el comportamiento de caza de la hormiga león (ant lion). Las larvas de este insecto excavan trampas en forma de cono, ajustando su tamaño según el hambre y la fase lunar. Este comportamiento ha sido modelado matemáticamente para crear un algoritmo capaz de explorar y explotar eficientemente espacios de búsqueda.

## 2.3 Conjunto de datos

Para el presente proyecto empleamos datos provenientes de imágenes médicas de cáncer de mama obtenidas mediante ecografía. Este conjunto de datos se encuentra clasificado en tres categorías: imágenes correspondientes a tejido mamario normal, tumores benignos y tumores malignos. Las imágenes ecográficas han demostrado ser útiles en tareas de clasificación, detección y segmentación del cáncer de mama, particularmente cuando se integran con técnicas de aprendizaje automático (ver Al-Dhabyani et al., 2020).

El conjunto de datos fue recopilado en el año 2018 e incluye imágenes de mujeres con edades comprendidas entre los 25 y 75 años. La muestra está compuesta por 600 pacientes femeninas, y consta de un total de 780 imágenes con una resolución promedio de  $500 \times 500$  píxeles, almacenadas en formato PNG. Las imágenes se distribuyen entre las siguientes clases:

- **Normales:** 133 imágenes
- **Benignas:** 437 imágenes
- **Malignas:** 205 imágenes

En relación con la clasificación patológica, las imágenes etiquetadas como benignas corresponden, en su mayoría, a lesiones como fibroadenomas, mientras

que las imágenes malignas incluyen casos de carcinomas invasivos. Si bien el conjunto de datos no proporciona información detallada sobre el estadio clínico de los tumores ni sobre su localización anatómica específica (por ejemplo, cuadrante mamario), algunas imágenes cuentan con anotaciones visuales que delimitan la región tumoral.

La partición del conjunto de datos la realizamos mediante la técnica *Hold-Out Split*, la cual consiste en una única división del total de datos sin re-muestreo. Con esta partición asignamos el 70 % de las imágenes al conjunto de entrenamiento, el 15% al conjunto de validación y el 15% restante al conjunto de prueba.

## 2.4 Experimentos

Para alcanzar el objetivo de este trabajo propusimos dos experimentos principales utilizando arquitecturas de redes neuronales convolucionales: una red convolucional personalizada denominada CNN y una arquitectura pre-entrenada basada en ResNet50. Ambas fueron aplicadas a la tarea de clasificación de tumores de mama en imágenes de ultrasonido.

Las pruebas experimentales las llevamos a cabo siguiendo un enfoque sistemático de evaluación de hiperparámetros, con especial atención a la tasa de aprendizaje (*learning rate*), dado su impacto crítico en la convergencia y desempeño de los modelos. En particular, implementamos una estrategia de optimización de hiperparámetros mediante el uso del algoritmo metaheurístico ALO, con el objetivo de encontrar configuraciones óptimas para el entrenamiento de ambas redes.

Para evaluar la influencia de la tasa de aprendizaje y validar la robustez del algoritmo ALO, realizamos varias pruebas explorando diferentes valores en un rango definido [1e-1, 1e-4]. Asimismo, utilizamos configuraciones combinadas de cantidad de épocas de entrenamiento (*epochs*) y tamaño de la población (*population size*) durante la fase de optimización, según se detalla en la Tabla 3.

Con el propósito de establecer un punto de comparación objetivo, definimos una configuración base (*baseline*) sin optimización para CNN y ResNet50, con hiperparámetros seleccionados de forma manual. Esta configuración fue utilizada como referencia para evaluar la mejora obtenida a través del uso del algoritmo ALO.

A continuación, presentamos los detalles de la configuración de hiperparámetros y las especificaciones estructurales de las redes utilizadas en los experimentos realizados en este estudio.

**CNN** Para este experimento diseñamos una arquitectura estándar de red neuronal convolucional, inspirada en el diseño propuesto por AlexNet (ver Krizhevsky et al., 2012). La arquitectura implementada, así como los hiperparámetros asociados a cada capa, se detallan en la Tabla 1.

Utilizamos esta red CNN como modelo base (*baseline*) para establecer un punto de comparación frente a otros enfoques evaluados en este estudio. Entrenamos el modelo baseline utilizando una configuración convencional de hiperparámetros seleccionados manualmente, con una tasa de aprendizaje fija, número

de épocas determinado empíricamente y sin aplicación de algoritmos de optimización avanzados. Esta configuración permitió observar el rendimiento básico del modelo sin ajustes automáticos, funcionando como referencia para valorar los beneficios aportados por la optimización con el algoritmo ALO.

Para la validación de los modelos, empleamos una división del conjunto de datos en tres subconjuntos: entrenamiento, validación y prueba, utilizando la estrategia *Hold-Out Split* con proporciones del 70,%, 15,% y 15,% respectivamente. Durante el entrenamiento, utilizamos la estrategia de monitorización del rendimiento sobre el conjunto de validación para evitar el sobreajuste y seleccionar la mejor versión del modelo basada en la métrica de exactitud. Finalmente, la evaluación del rendimiento la realizamos sobre el conjunto de prueba, calculando métricas cuantitativas como exactitud (*accuracy*).

Esta metodología nos permitió comparar el desempeño del modelo baseline frente a las configuraciones optimizadas, tanto para la CNN como para la arquitectura ResNet50 transferida.

**Table 1.** Diseño de arquitectura y configuración de hiperparámetros.

Componente	Descripción
<b>Capas de Convolución</b>	Conv2D (5 filtros, $3 \times 3$ , ReLU) Conv2D (16 filtros, $3 \times 3$ , ReLU) Conv2D (32 filtros, $3 \times 3$ , ReLU) (3 rep)
<b>Capas de Pooling</b>	MaxPooling2D (tamaño $2 \times 2$ ) (2 rep)
<b>Capas Densas</b>	Dense (128 unidades, ReLU) Dense (128 unidades, ReLU) Dense (3 unidades, Softmax)
<b>Regularización</b>	Dropout (tasa: 0.25)
<b>Tasa de Aprendizaje</b>	ALO define este parámetro.
<b>Función de Optimización</b>	Adam
<b>Función de Pérdida</b>	CategoricalCrossentropy
<b>Métrica</b>	Accuracy
<b>Épocas de Entrenamiento</b>	10

**Modelo ResNet50** En este experimento empleamos una arquitectura convolucional profunda basada en ResNet50, la cual consta de 50 capas organizadas mediante bloques residuales. Esta arquitectura introduce conexiones de atajo o *skip connections* que permiten el aprendizaje residual, facilitando así el entrenamiento de redes muy profundas. Dichas conexiones residuales mitigan problemas comunes en redes profundas, como la desaparición del gradiente (*vanishing gradient*), y mejoran significativamente la convergencia del modelo durante el entrenamiento (ver Duta et al., 2020).

La arquitectura ResNet50 que utilizamos en este trabajo se adapta al problema de clasificación de imágenes ecográficas mamarias mediante la sustitución

de las capas finales por un clasificador denso ajustado a tres clases: normal, benigno y maligno. Esta modificación permite aprovechar el conocimiento aprendido previamente en grandes conjuntos de datos (mediante aprendizaje transferido), adaptándolo a la tarea específica. La estructura detallada de la red, incluyendo los bloques residuales y los hiperparámetros empleados, se presenta en la Tabla 2.

Evaluamos el modelo ResNet50 bajo el mismo esquema experimental que la arquitectura CNN, incluyendo tanto una configuración base (*baseline*) como una versión optimizada con el algoritmo ALO. Esto nos permitió realizar una comparación directa de los resultados y analizar el impacto de la optimización sobre una arquitectura pre-entrenada de mayor complejidad.

**Table 2.** Diseño de arquitectura y configuración de hiperparámetros.

Componente	Descripción
CNN base	ResNet 50
Capas de Pooling	GlobalAveragePooling2D
Capas Densas	Dense (128 unidades, ReLU) Dense (3 unidades, Softmax)
Regularización	Dropout (tasa: 0.25)
Tasa de Aprendizaje	ALO define este parámetro.
Función de Optimización	Adam
Función de Pérdida	CategoricalCrossentropy
Métrica	Accuracy
Épocas de Entrenamiento	10

**Table 3.** Configuración de los valores de prueba del Ant Lion Optimizer.

ALO	
Parameter	Values
Epochs	15, 30, 45
Pop-size	5, 10, 15

### 3 Resultados

En esta sección presentamos los resultados obtenidos a partir de los experimentos previamente descritos: el modelo CNN personalizado y la arquitectura ResNet50. Tal como indicamos en la sección anterior, las pruebas que realizamos son experimentales variando la cantidad de épocas de entrenamiento (*epochs*) y el tamaño de la población (*population size*) utilizados por el algoritmo de optimización ALO. Estas pruebas nos permitieron analizar el impacto de dichos parámetros en el rendimiento de ambos modelos.

En el primer experimento, correspondiente a la arquitectura CNN, los resultados que obtuvimos se ven resumidos en la Tabla 5 y para los resultados del caso base se observan en la Tabla 4. De estos se destacan los valores alcanzados de exactitud (*accuracy*) y las tasas de aprendizaje óptimas determinadas para cada configuración experimental del algoritmo ALO, en función de las combinaciones evaluadas de épocas y tamaño poblacional.

En el segundo experimento, basado en la arquitectura ResNet50, aplicamos una metodología análoga, evaluando múltiples configuraciones del optimizador. Los resultados correspondientes se presentan en la Tabla 2, donde observamos las métricas de desempeño bajo diferentes ajustes del número de épocas y tamaño de la población.

Todos los resultados los expresamos con valores decimales redondeados a cuatro cifras significativas, con el fin de garantizar precisión y uniformidad en la presentación de los datos.

**Table 4.** Resultados experimentales para el caso base.

Epoch	CNN		ResNet50	
	Accuracy	Learning Rate	Accuracy	Learning Rate
10	0.6710	0.001	0.5657	0.001
15	0.7763	0.001	0.5657	0.001
30	0.7368	0.001	0.5789	0.001
45	0.6842	0.001	0.5657	0.001

**Table 5.** Resultados en cada configuración experimental.

Epoch	Pop-size	CNN		ResNet50	
		Accuracy	Learning Rate	Accuracy	Learning Rate
15	5	0.5657	0.0746	0.8684	0.1
30	5	0.6052	0.0567	<b>0.9211</b>	0.012
45	5	0.8157	0.0007156	0.8684	0.09375
15	10	0.78947	0.0018	0.8816	0.0001
30	10	0.8026	0.00124	0.8816	0.02769
45	10	0.8157	0.00106	0.8947	0.00643
15	15	0.8026	0.0011	0.8947	0.01083
30	15	0.8026	0.00069	0.9078	0.01678
45	15	0.8157	0.00046	0.8815	0.0001


**Table 6.** Resultados comparativos de la media de la exactitud de las pruebas baseline utilizando y metaheurística ALO.

Model	Baseline	AntLion	Increase rate (%)	Best Fitness
CNN	0.7302	0.7572	+3.7%	0.8157
ResNet50	0.5723	0.8888	+54.4%	<b>0.9211</b>

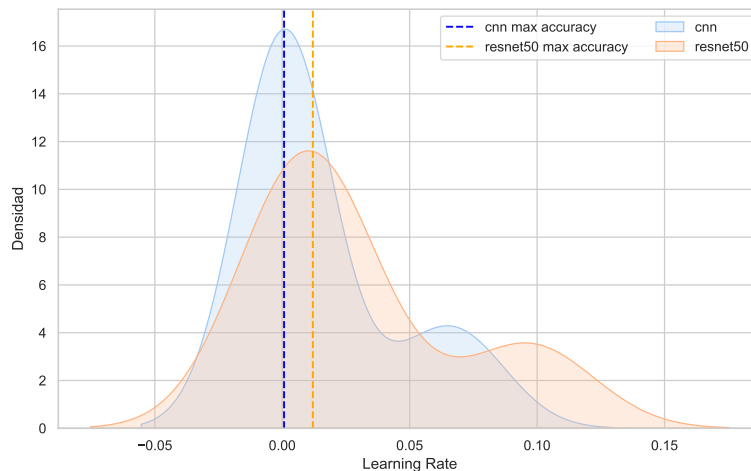
Los resultados obtenidos a partir de las pruebas experimentales los procesamos gráficamente con el fin de facilitar un análisis comparativo más detallado del desempeño de los modelos evaluados. En la Figura 1 presentamos una visualización de los valores de exactitud (*accuracy*) alcanzados en cada configuración experimental. Los datos los agrupamos según la cantidad de épocas de entrenamiento y los diferenciamos por color en función del tamaño de la población utilizado en el algoritmo ALO. La imagen ubicada a la izquierda corresponde a los resultados del modelo CNN, mientras que la imagen a la derecha muestra los resultados obtenidos por la arquitectura ResNet50 bajo las mismas condiciones experimentales.

Complementariamente, la Figura 2 muestra la distribución de los valores de tasa de aprendizaje (*learning rate*) que obtuvimos durante las pruebas para ambos modelos. Cada subgráfico representa una de las arquitecturas evaluadas (CNN y ResNet50), y las líneas punteadas indican el valor de *learning rate* asociado al mejor rendimiento alcanzado en términos de exactitud. Esta visualización nos permitió analizar la estabilidad y dispersión de dicho parámetro, así como identificar patrones que podrían estar asociados al desempeño de cada arquitectura bajo diferentes configuraciones de entrenamiento.

Los resultados que obtuvimos a partir de las pruebas experimentales fueron procesados gráficamente con el fin de facilitar un análisis comparativo más detallado del desempeño de los modelos evaluados.



**Fig. 1.** Gráfico que muestra los valores obtenidos de precisión. En la imagen de la izquierda se observan los resultados obtenidos con el experimento CNN para diversos valores de población (Ps), y a derecha se observan los resultados obtenidos en el experimento Resnet50.



**Fig. 2.** Gráfico que muestra las distribuciones de los valores de la tasa de aprendizaje obtenidos por el ALO, en cada experimento CNN y ResNet50. Las líneas punteada marcan el valor de la tasa de aprendizaje que obtuvo la mejor precisión, para cada experimento.

## 4 Discusión

De todo este trabajo podemos observar que los resultados obtenidos durante el baseline para la arquitectura CNN logramos un valor de exactitud en promedio del  $73\% \pm 0.038$  y para la arquitectura ResNet50 un valor de exactitud en promedio del  $57\% \pm 0.006$ . Estos valores los obtuvimos ejecutando las pruebas utilizando el valor del learning rate por defecto en el optimizador Adam, de la librería TensorFlow. Este valor es un estándar y podría no ser el adecuado para la problemática planteada en este trabajo.

Por otro lado los resultados que obtuvimos en ambos experimentos utilizando la metaheurística ALO, permiten concluir que el uso de una arquitectura pre-entrenada, como ResNet50, ofrece un rendimiento superior en comparación con la arquitectura CNN personalizada como se puede ver en Tabla 6. Esta mejora puede atribuirse al hecho de que utilizando una metaheurística como ALO optimiza el aprendizaje de nuevas tareas de clasificación, especialmente cuando se dispone de un número limitado de iteraciones. Este comportamiento lo observamos claramente en los valores de accuracy: con tan solo 15 épocas de entrenamiento, ResNet50 alcanzó una exactitud superior a la obtenida por la CNN incluso tras 45 épocas, independientemente del tamaño de población utilizado (ver Figura 1).

Otro aspecto destacado es que el tamaño de la población no parece ejercer una influencia determinante en el desempeño del optimizador (ver Tabla 5).

No obstante, observamos que para valores moderados del tamaño poblacional (en torno a 15), tanto en CNN como en ResNet50, el accuracy se mantuvo relativamente estable en función de las épocas evaluadas, lo cual podría indicar una zona de equilibrio entre exploración y explotación durante la búsqueda de hiperparámetros.

En este estudio, el algoritmo Ant Lion Optimizer (ALO) demostró ser eficaz para la optimización automática de hiperparámetros, permitiendo maximizar la precisión del modelo al tiempo que se minimiza el número de iteraciones necesarias. Esta eficiencia resulta consistente con lo reportado en trabajos recientes de la literatura, donde se ha validado el uso de algoritmos metaheurísticos para ajustar parámetros en modelos de aprendizaje profundo aplicados a tareas médicas (ver Abdelmaksoud et al., 2022; Mirjalili, 2015). En particular, la combinación de aprendizaje transferido y optimización evolutiva ha mostrado ventajas frente a enfoques tradicionales con hiperparámetros estáticos.

## 5 Conclusiones y Trabajo Futuro

Aunque el presente estudio se centró en la clasificación de tumores mamarios, la metodología empleada nos demuestra ser altamente transferible a otros dominios del diagnóstico médico asistido por inteligencia artificial. La combinación de una arquitectura pre-entrenada como ResNet50 con un enfoque de optimización basado en el algoritmo Ant Lion Optimizer puede implementarse a tareas similares, donde se requiera ajustar la arquitectura propuesta para un contexto específico.

Como líneas de trabajo futuro, se proponen los siguientes objetivos:

- **Expansión del conjunto de datos:** Incorporar imágenes provenientes de múltiples fuentes y modalidades, tales como ultrasonido y resonancia magnética, con el fin de mejorar la robustez del modelo y su capacidad de generalización.
- **Implementación de modelos más avanzados:** Explorar el uso de arquitecturas de vanguardia, como los *Vision Transformers* (ViT), y comparar su rendimiento frente a ResNet50 en tareas de clasificación médica.
- **Evaluación de distintos algoritmos de optimización:** Investigar otros algoritmos metaheurísticos, tales como el *Whale Optimization Algorithm* o el *Grey Wolf Optimizer*, con el objetivo de analizar su eficacia en la optimización de hiperparámetros, en consonancia con el teorema de *No Free Lunch* (ver Adam et al., 2019).
- **Validación clínica:** Establecer colaboraciones con profesionales de la salud, especialmente especialistas en oncología, para evaluar el desempeño práctico del sistema en entornos clínicos reales.
- **Extensión a otros tipos de cáncer:** Adaptar y aplicar la metodología desarrollada a la detección de cáncer en otros órganos, como pulmón, piel o próstata.

- **Métricas de evaluación:** Añadir métricas asociadas a la problemática de clasificación donde se observe la performance del modelo en conjuntos de datos desbalanceados (ej. matriz de confusión, precisión, sensibilidad, f1-score).

La generalización de esta metodología a nuevos casos de estudio requerirá ciertos ajustes, tales como la recolección de datos representativos del dominio específico, el preprocesamiento adecuado y, probablemente, una fase de reajuste fino (*fine-tuning*) del modelo de la arquitectura para asegurar un rendimiento óptimo.

Finalmente, si bien los avances en inteligencia artificial ofrecen herramientas poderosas para el apoyo diagnóstico en medicina, la participación activa del profesional de la salud sigue siendo esencial. El rol de la inteligencia artificial debe entenderse como complementario, brindando soporte y eficiencia en la práctica clínica diaria. Sin embargo, la decisión diagnóstica definitiva continuará siendo responsabilidad del especialista capacitado en el área.

## References

- Abdelmaksoud, E., Mahdy, L. N., El-Sayed, A., & El-Banby, G. M. (2022). A deep learning model for medical image classification using alo optimizer. *Multimedia Tools and Applications*, *81*, 20661–20681. <https://doi.org/10.1007/s11042-021-11669-9>
- Adam, S. P., Alexandropoulos, S.-A. N., Pardalos, P. M., & Vrahatis, M. N. (2019). No free lunch theorem: A review. *Approximation and optimization: Algorithms, complexity and applications*, 57–82.
- Al-Dhabyani, W., Gomaa, M., Khaled, H., & Fahmy, A. (2020). Dataset of breast ultrasound images. *Data in brief*, *28*, 104863.
- Balasubramaniam, S., Velmurugan, Y., Jaganathan, D., & Dhanasekaran, S. (2023). A modified lenet cnn for breast cancer diagnosis in ultrasound images. *Diagnostics*, *13*(17), 2746.
- Duta, I. C., Liu, L., Zhu, F., & Shao, L. (2020). Improved residual networks for image and video recognition [Mejoras en flujo de información y bloques, obtiene 2% de aumento en accuracy sobre ResNet-50 sin aumentar complejidad]. *arXiv preprint arXiv:2004.04989*.
- Gaspar, A., Oliva, D., Cuevas, E., Zaldívar, D., Pérez, M., & Pajares, G. (2021). Hyperparameter optimization in a convolutional neural network using metaheuristic algorithms. In *Metaheuristics in machine learning: Theory and applications* (pp. 37–59). Springer.
- Golnoori, F., Boroujeni, F. Z., & Monadjemi, A. (2023). Metaheuristic algorithm based hyper-parameters optimization for skin lesion classification. *Multimedia Tools and Applications*, *82*(17), 25677–25709.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770–778.

- Ketkar, N., Moolayil, J., Ketkar, N., & Moolayil, J. (2021). Convolutional neural networks. *Deep learning with Python: learn best practices of deep learning models with PyTorch*, 197–242.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- Mamindla, A. K., Ramadevi, D., Sedova, O. V., Alekseev, A. G., Ashraf, M., Ariffin, D., Samy, S., Fouzia, E., Nabil, E., Khalid, S., et al. (2023). Ann-abc meta-heuristic hyper parameter tuning for mammogram classification. *J. Theor. Appl. Inf. Technol*, 101.
- Mirjalili, S. (2015). The ant lion optimizer. *Advances in Engineering Software*, 83, 80–98. <https://doi.org/10.1016/j.advengsoft.2015.01.010>
- Rojas, M. G., Carballido, J. A., Olivera, A. C., & Vidal, P. J. (2022). A modified multi-swarm optimization for weights and biases of a multi-layer perceptron for medical data classification. *2022 IEEE Biennial Congress of Argentina (ARGENCON)*, 1–8.
- Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F. (2021). Global cancer statistics 2020: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 71(3), 209–249. <https://doi.org/10.3322/caac.21660>
- Talbi, E. (2009). Metaheuristics: From design to implementation. *John Wiley & Sons google schola*, 2, 268–308.