



PRISMA ODS

REVISTA MULTIDISCIPLINARIA SOBRE DESARROLLO SOSTENIBLE

ISSN: 3072-8452

DIAGNÓSTICO ASISTIDO POR COMPUTADORA DE NEUMONÍA INFANTIL UTILIZANDO REDES NEURONALES Y MÁQUINAS DE SOPORTE VECTORIAL

*COMPUTER ASSISTED DIAGNOSIS OF
CHILDHOOD PNEUMONIA USING
NEURAL NETWORKS AND SUPPORT
VECTOR MACHINES*

AUTORES

SAMUEL DAVID HERNÁNDEZ
CHIQUILLO

CORPORACIÓN
UNIVERSITARIA RAFAEL
NÚÑEZ
COLOMBIA

JORGE MANUEL BARRIOS
SÁNCHEZ

UNIVERSIDAD DE GUANAJUATO
- CORPORACIÓN
UNIVERSITARIA RAFAEL NÚÑEZ
COLOMBIA

ERNESTO ISAAC TLAPANCO
RÍOS

UNIVERSIDAD
DE
GUANAJUATO
MÉXICO

JORGE ENRIQUE PINO
JIMÉNEZ

CORPORACIÓN
UNIVERSITARIA RAFAEL
NÚÑEZ
COLOMBIA

Diagnóstico Asistido por Computadora de Neumonía Infantil Utilizando Redes Neuronales y Máquinas de Soporte Vectorial

Computer Assisted Diagnosis of Childhood Pneumonia Using Neural Networks
and Support Vector Machines

Samuel David Hernández Chiquillo

sfernandezc21@campusuninunez.edu.co

<https://orcid.org/0009-0008-6930-6661>

Corporación Universitaria Rafael Núñez

Cartagena – Colombia

Ernesto Isaac Tlapanco Ríos

ei.tlapanco@ugto.mx

<https://orcid.org/0000-0002-4314-5926>

Universidad de Guanajuato

Guanajuato – México

Jorge Manuel Barrios Sánchez

Jorge.barrios@campusuninunez.edu.co

<https://orcid.org/0000-0003-3528-0922>

Universidad de Guanajuato - Corporación Universitaria Rafael Núñez

Cartagena – Colombia

Jorge Enrique Pino Jimenez

jorge.pino@campusuninunez.edu.co

<https://orcid.org/0009-0006-2359-9505>

Corporación Universitaria Rafael Núñez

Cartagena – Colombia

Artículo recibido: 15/11/2025

Aceptado para publicación: 18/12/2025

Conflictos de Intereses: Ninguno que declarar

RESUMEN

El presente trabajo de investigación se enfoca en el desarrollo de clasificadores para el diagnóstico de neumonía infantil a través de imágenes de rayos X. La base de datos utilizada contiene imágenes de rayos X de tórax (anteroposterior) de cohortes retrospectivas de pacientes pediátricos. Por medio de un programa en Matlab, se extraen 10 características clave de cada imagen para determinar si el paciente presenta neumonía o si el diagnóstico es normal. Se implementan y comparan dos clasificadores: Red Neuronal Multicapa (MLP) y Maquinas de Vectores de Soporte (SVM). Los modelos lograron eficiencias del 95.03 % y 95.80 % respectivamente, demostrando su alta efectividad para esta aplicación.

Palabras clave: clasificador, neumonía, redes neuronales, SVM, diagnóstico asistido

ABSTRACT

This research focuses on the development of classifiers for the diagnosis of childhood pneumonia through X-ray images. The database used contains chest X-ray images (anteroposterior) from retrospective cohorts of pediatric patients. Using a MATLAB program, 10 key features are extracted from each image to determine whether the patient has pneumonia or whether the diagnosis is normal. Two classifiers are implemented and compared: Multilayer Perceptron (MLP) and Support Vector Machines (SVM). The models achieved efficiencies of 95.03% and 95.80% respectively, demonstrating their high effectiveness for this application.

Keywords: classifier, pneumonia, neural networks, SVM, assisted diagnosis

INTRODUCCIÓN

La neumonía es una infección aguda del parénquima pulmonar que puede ocasionar desde una inflamación hasta acumulación de líquido en los pulmones. Su etiología puede ser por la infección de virus, bacterias u hongos [1]. Afecta a pacientes no hospitalizados y hospitalizados, y representa más del 15 % de todas las muertes de niños menores de 5 años a nivel mundial [2]. Según la Organización Mundial de la Salud, la neumonía es responsable de aproximadamente 800,000 muertes anuales en niños, siendo una de las principales causas de mortalidad infantil en países en desarrollo [3]. En Estados Unidos representa más de 500,000 visitas a los departamentos de emergencia y más de 50,000 muertes según datos del 2015, lo que mantiene la dolencia en la lista de las 10 principales causas de muertes en el mundo [4].

La carga económica asociada con el tratamiento de la neumonía es significativa, con costos hospitalarios que superan los \$10 billones anuales solo en Estados Unidos [5]. El diagnóstico preciso y temprano de la neumonía es crucial para un tratamiento efectivo. Tradicionalmente, el diagnóstico se basa en la evaluación clínica y la interpretación de radiografías de tórax por radiólogos expertos [6]. Sin embargo, en muchas regiones con recursos limitados, el acceso a radiólogos especializados es escaso, lo que retrasa el diagnóstico y tratamientos adecuados [1].

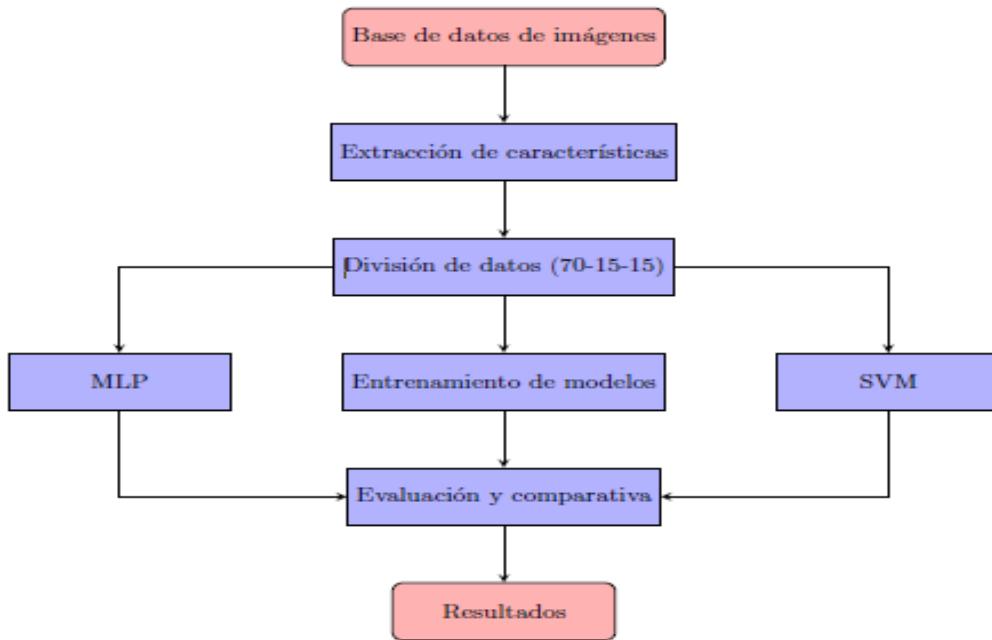
La tecnología ha logrado un significativo aporte para combatir enfermedades donde la Inteligencia Artificial (IA) es protagonista, planteando la combinación de algoritmos con el propósito de crear máquinas que presenten capacidades de apoyo al diagnóstico médico [7].

En los últimos años, el aprendizaje automático ha demostrado un potencial considerable en el análisis de imágenes médicas, incluyendo la detección de neumonía en radiografías de tórax [8, 9]. Varios estudios han explorado el uso de técnicas de aprendizaje automático para la clasificación de neumonía. Kermany et al. [10] utilizaron redes neuronales convolucionales (CNN) para clasificar imágenes de neumonía, logrando altas precisiones. Similarmente, Rajpurkar et al. [11] desarrollaron CheXNet, una CNN de 121 capas que superó a los radiólogos en la

detección de neumonía. Sin embargo, estos enfoques basados en deep learning requieren grandes conjuntos de datos y potencia computacional significativa [12]. Como alternativa, los métodos tradicionales de aprendizaje automático que utilizan características extraídas manualmente ofrecen ventajas en términos de eficiencia computacional e interpretabilidad [13]. Las Máquinas de Vectores de Soporte (SVM) han demostrado excelente rendimiento en problemas de clasificación médica [14], mientras que las Redes Neuronales Multicapa (MLP) han sido ampliamente utilizadas en diagnóstico médico debido a su capacidad para modelar relaciones no lineales complejas [15]. El objetivo principal de este artículo es desarrollar y comparar modelos de predicción basados en MLP y SVM para ayudar a los especialistas del área de la salud en el diagnóstico de la neumonía. Estos clasificadores permitirán analizar características extraídas de imágenes radiológicas para determinar con alta precisión si un paciente pediátrico tiene o no neumonía. La contribución de este trabajo radica en la evaluación comparativa de estos dos enfoques utilizando un conjunto de características cuidadosamente seleccionadas, proporcionando así una guía para la selección de métodos en entornos clínicos con diferentes El artículo comienza con una introducción, donde se presenta el problema de investigación y las estrategias usadas en el estudio. No se requiere un encabezado específico para la introducción.

METODOLOGÍA

La metodología seguida en este trabajo se ilustra en la Figura 1 y se describe a continuación:

Figura 1. Diagrama de flujo de la metodología.

Fuente: Elaboración propia.

Base de datos.

El caso de estudio para esta investigación parte de una base de datos de rayos X de tórax (anteroposterior) de cohortes retrospectivas de pacientes pediátricos de 1 a 5 años. El conjunto de datos incluye 5,856 imágenes con diagnóstico confirmado de neumonía y 1,583 imágenes normales, obtenidas de archivos hospitalarios entre 2015 y 2020. Todas las imágenes fueron preprocesadas para normalizar el tamaño (224x224 píxeles) y el contraste. El conjunto de datos fue dividido aleatoriamente en conjuntos de entrenamiento (70 %), validación (15 %) y prueba (15 %), manteniendo la proporción de clases en cada partición para evitar sesgos [13].

Extracción de características.

Se extrajeron 10 características de cada imagen mediante un programa desarrollado en MATLAB, seleccionadas por su relevancia en la discriminación de texturas pulmonares asociadas con neumonía [16, 17]:

- **Media (mean2):** Valor promedio de intensidad de los píxeles
- **Desviación estándar (std2):** Dispersión de los valores de intensidad
- **Entropía (entropy):** Medida de aleatoriedad en la textura de la imagen
- **Valor RMS (rms):** Raíz cuadrada del promedio de los cuadrados de los valores de intensidad
- **Varianza (var):** Medida de la dispersión de los valores de intensidad
- **Energía (graycoprops):** Suma de los cuadrados de los valores en la matriz de coocurrencia
- **Contraste (graycoprops):** Medida de la diferencia de intensidad entre un píxel y sus vecinos
- **Homogeneidad (graycoprops):** Medida de la uniformidad de la textura
- **Kurtosis (kurtosis):** Medida del “pico” de la distribución de intensidades
- **Asimetría (skewness):** Medida de la asimetría de la distribución de intensidades

Estas características capturan propiedades estadísticas y texturales relevantes para distinguir entre tejido pulmonar sano y afectado por neumonía [18].

Clasificadores implementados

Red Neuronal Multicapa (MLP):

Se implementó una red neuronal feed-forward con una capa oculta de 12 neuronas, determinada mediante experimentación con diferentes arquitecturas. La función de activación utilizada fue tangente sigmoide en la capa oculta y softmax en la capa de salida. Se empleó el algoritmo de entrenamiento

Levenberg-Marquardt (trainlm) por su rápida convergencia [19], con función de desempeño de entropía cruzada para problemas de clasificación binaria. El entrenamiento se detuvo cuando

la validación dejó de mejorar por 6 épocas consecutivas (early stopping) para prevenir sobreajuste.

Máquina de Vectores de Soporte (SVM).

Se implemento un clasificador SVM con kernel RBF (Radial Basis Function), seleccionado por su capacidad para manejar problemas no linealmente separables [20]. Las características fueron estandarizadas (media=0, desviación estándar=1) antes del entrenamiento. Los parámetros de regularización (C) y ancho del kernel () se optimizaron mediante validación cruzada de 5 folds, explorando un rango de $C = [0.1, 1, 10, 100]$ y $\gamma = [0.001, 0.01, 0.1, 1]$.

RESULTADOS

Resultados del clasificador MLP.

El modelo MLP alcanzó una exactitud del 95.03% en el conjunto de prueba, demostrando excelente capacidad para distinguir entre casos de neumonía y normales. La matriz de confusión y métricas detalladas se presentan en la Tabla 1 y Figuras 1-2.

Tabla 1. Métricas del clasificador MLP.

<u>Cuadro 1: Métricas del clasificador MLP</u>				
Clase	Precisión	Recall	F1-Score	Especificidad
PNEUMONÍA	96.60 %	97.26 %	96.93 %	90.05 %
NORMAL	91.88 %	90.05 %	90.96 %	97.26 %

Fuente: Elaboración propia.

El alto recall para la clase PNEUMONÍA (97.26 %) indica que el modelo es muy efectivo para identificar

casos positivos, minimizando falsos negativos, lo que es crucial en aplicaciones médicas donde los falsos negativos pueden tener consecuencias graves [13].

Resultados del clasificador MLP.

El modelo SVM demostró un rendimiento ligeramente superior con una exactitud del 95.80 % en el conjunto de prueba. Los resultados detallados se muestran en la Tabla 2.

Tabla 2. Métricas del clasificador SVM.

Cuadro 2: Métricas del clasificador SVM				
Clase	Precisión	Recall	F1-Score	Especificidad
PNEUMONÍA	98.29 %	96.15 %	97.21 %	88.56 %
NORMAL	88.56 %	94.68 %	91.52 %	98.29 %

Fuente: Elaboración propia.

La alta precisión para la clase PNEUMONÍA (98.29 %) sugiere que cuando el SVM clasifica un caso como positivo, es muy probable que sea correcto, reduciendo así los falsos positivos [14].

Análisis Comparativo.

Tabla 3. Comparativa MLP vs SVM.

Cuadro 3: Comparativa MLP vs SVM			
Métrica	MLP	SVM	Diferencia
Exactitud	95.03 %	95.80 %	+0.77 %
Precisión (PNEUMONÍA)	96.60 %	98.29 %	+1.69 %
Recall (PNEUMONÍA)	97.26 %	96.15 %	-1.11 %
F1-Score (PNEUMONÍA)	96.93 %	97.21 %	+0.28 %
Recall (NORMAL)	90.05 %	94.68 %	+4.63 %
AUC	0.9843	0.9843	0.0000

Fuente: Elaboración propia.

El análisis comparativo revela que ambos clasificadores tienen fortalezas distintas. El MLP presenta mejor sensibilidad para detectar neumonía (recall más alto), mientras que el SVM

ofrece mayor precisión en los diagnósticos positivos. Ambos modelos alcanzaron un AUC de 0.9843, indicando excelente capacidad discriminativa [21].

DISCUSIÓN

Los resultados obtenidos demuestran que ambos clasificadores son altamente efectivos para el diagnóstico de neumonía infantil a través de imágenes de rayos X, superando el 95 % de exactitud. Estos resultados son consistentes con estudios previos que han aplicado aprendizaje automático en diagnóstico médico [7, 10].

El clasificador SVM mostró un rendimiento ligeramente superior en términos de exactitud general (95.80 % vs 95.03 %), mientras que el MLP presentó mejor recall para la clase PNEUMONIA (97.26 % vs 96.15 %). Esta diferencia en el perfil de rendimiento puede atribuirse a las características fundamentales de cada algoritmo: las SVM buscan maximizar el margen entre clases [20], mientras que las MLP minimizan el error de clasificación mediante ajuste iterativo de pesos [15].

La elección entre ambos métodos dependerá de los objetivos clínicos específicos. Si se prioriza minimizar falsos negativos en neumonía (maximizar sensibilidad), el MLP sería preferible debido a su mayor recall. Esto es particularmente importante en entornos donde el costo de no tratar una neumonía es alto [1]. Por otro lado, si se busca maximizar la certeza en diagnósticos positivos (maximizar precisión), el SVM resulta más adecuado dada su mayor precisión, lo que puede ser preferible en contextos con recursos limitados para evitar tratamientos innecesarios [13]. Ambos modelos alcanzaron un AUC de 0.9843, indicando una excelente capacidad discriminatoria entre clases y superando el umbral de 0.9 considerado como excelente en aplicaciones médicas [21]. Las curvas ROC casi idénticas sugieren que ambos métodos son comparables en términos de compromiso entre sensibilidad y especificidad.

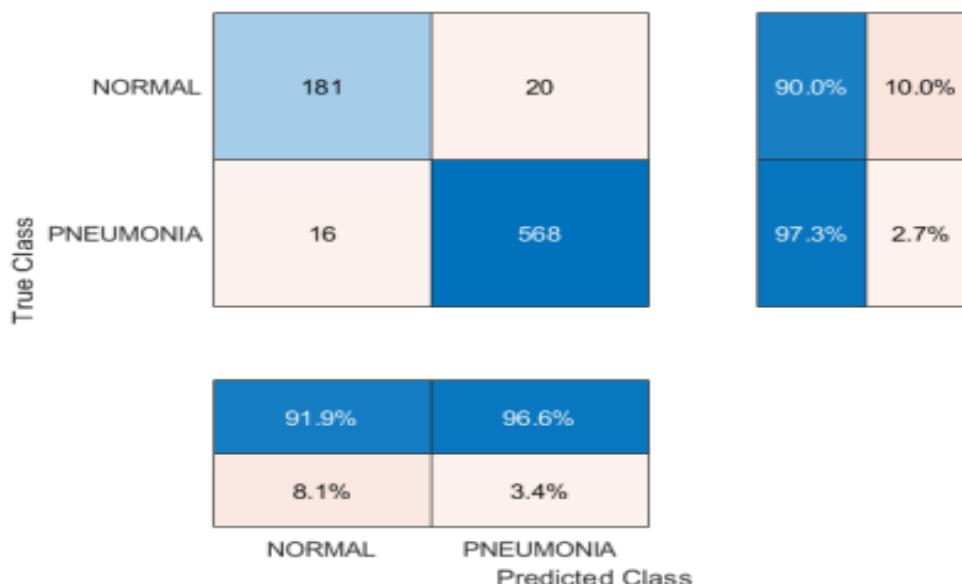
ILUSTRACIONES, TABLAS, FIGURAS.**Figura 2.** Matriz de confusión – MLP (Accuracy 95.03%).

Figura 2: Matriz de confusión - MLP (Accuracy 95.03 %)

Fuente: Elaboración propia.

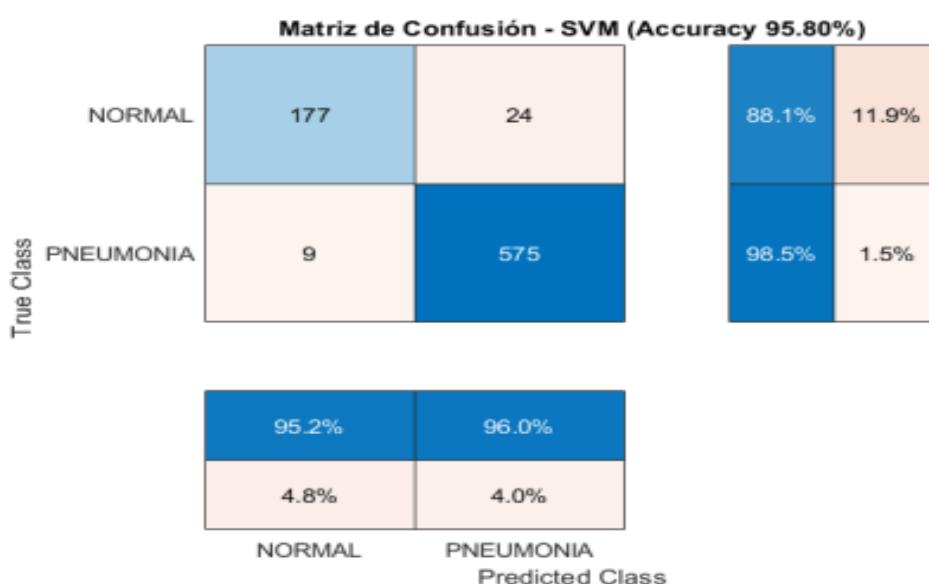
Figura 3. Matriz de confusión – SVM (Accuracy 95.80%).

Figura 3: Matriz de confusión - SVM (Accuracy 95.80 %)

Fuente: Elaboración propia.

Figura 4. Curva ROC - MLP.

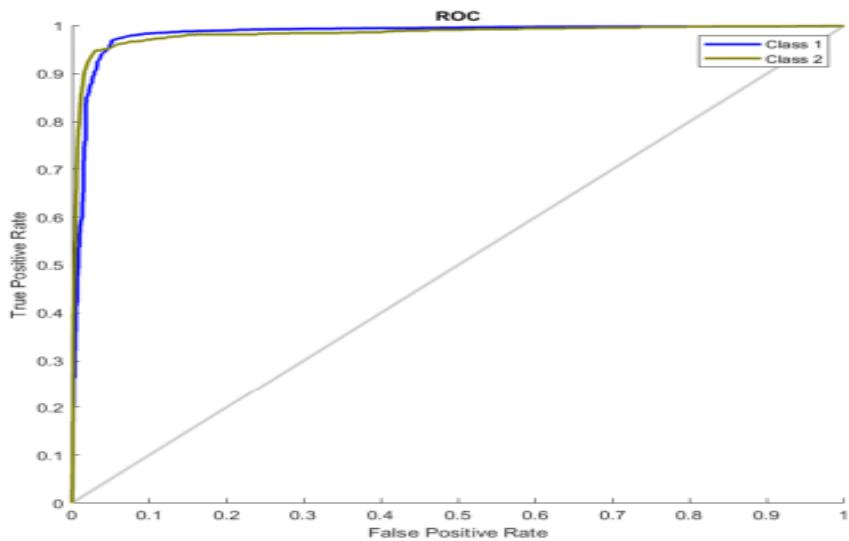


Figura 4: Curva ROC - MLP

Fuente: Elaboración propia.

Figura 5. Curva ROC – SVM (AUC = 0.9843).

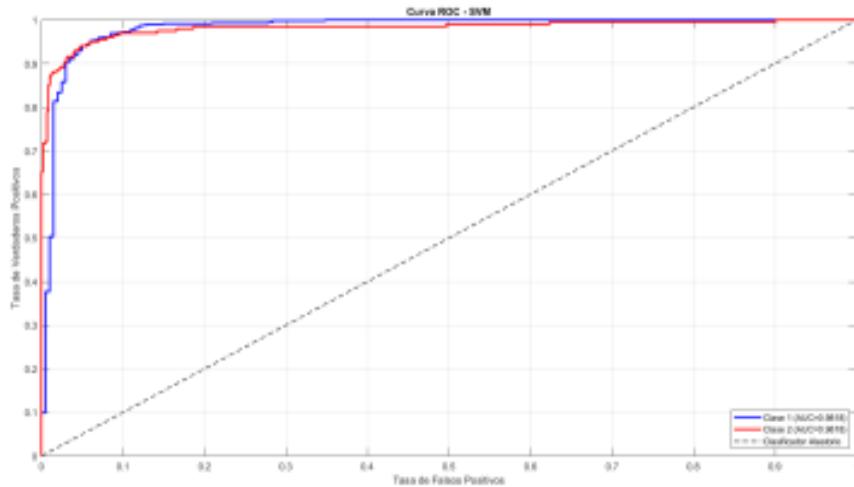


Figura 5: Curva ROC - SVM (AUC=0.9843)

Fuente: Elaboración propia.

CONCLUSIÓN

Este estudio demuestra la alta efectividad de clasificadores basados en MLP y SVM para el diagnóstico de neumonía infantil a través de imágenes de rayos X. Utilizando 10 características extraídas de las imágenes, ambos modelos lograron eficiencias superiores al 95 %, validando su aplicación como herramientas robustas y precisas para el diagnóstico asistido por computador. El rendimiento obtenido, especialmente con el clasificador SVM que alcanzó 95.80 % de exactitud, subraya el potencial de los modelos de inteligencia artificial en el campo de la medicina. El estudio proporciona herramientas prácticas para ayudar a los especialistas a realizar clasificaciones acertadas, mejorando la eficiencia en el diagnóstico. Las limitaciones de este trabajo incluyen el uso de un conjunto de datos específico de población pediátrica y la extracción de características limitadas. Para trabajos futuros, se recomienda explorar el uso de características más avanzadas y arquitecturas de deep learning, así como la validación en conjuntos de datos más grandes y diversos que incluyan diferentes grupos de edad y variaciones en la calidad de las imágenes.

REFERENCIAS

- Beletew, B., Bimerew, M., Mengesha, A., Wudu, M., & Azmeraw, M. (2020). Prevalence of pneumonia and its associated factors among under-five children in East Africa: a systematic review and meta-analysis. *BMC pediatrics*, 20(1), 254.
- Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
- Çalli, E., Sogancioglu, E., Van Ginneken, B., van Leeuwen, K. G., & Murphy, K. (2021). Deep learning for chest X-ray analysis: A survey. *Medical image analysis*, 72, 102125.
- Chen, H., Ni, D., Qin, J., et al. (2017). Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans. *Scientific Reports*, 6, 24454.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273-297.

- Esteva, A., Kuprel, B., Novoa, R. A., et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, 115-118.
- Esteva, A., Robicquet, A., Ramsundar, B., et al. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25, 24-29.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27, 861-874.
- Franquet, T. (2018). Imaging of community-acquired pneumonia. *Journal of Thoracic Imaging*, 33, 282-294.
- Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5, 989-993.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3, 610-621.
- Heron, M. (2019). Deaths: Leading causes for 2017. *National Vital Statistics Reports*, 68(6).
- Kermany, D. S., Goldbaum, M., Cai, W., et al. (2018). Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 172, 1122-1131.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436-444.
- Litjens, G., Kooi, T., Bejnordi, B. E., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Noble, W. S. (2006). What is a support vector machine? *Nature Biotechnology*, 24, 1565-1567.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225*.
- Roth, G. A., Abate, D., Abate, K. H., et al. (2018). Global, regional, and national age-sex-specific mortality for 282 causes of death in 195 countries and territories, 1980-2017: a systematic analysis for the Global Burden of Disease Study 2017. *The Lancet*, 392, 1736-1788.

- Rudan, I., Boschi-Pinto, C., Biloglav, Z., Mulholland, K., & Campbell, H. (2008). Epidemiology and etiology of childhood pneumonia. *Bulletin of the World Health Organization*, 86, 408-416.
- Sánchez, J. M. B., Villagómez, J. L., Moreno, A. L., & Jiménez, L. M. (2024). The Development of a Classifier Based on Neural Networks and K-Neighbors for Pediatric Pneumonia Diagnosis through X-Ray Images.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60.
- Tang, X. (2010). Texture information in run-length matrices. *IEEE Transactions on Image Processing*, 7, 1602-1609.
- Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998-6008.
- Watkins, K., & Sridhar, D. (2018). Pneumonia: a global cause without champions. *The Lancet*, 392(10149), 718-719.

© Los autores. Este artículo se publica en Prisma ODS bajo la Licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0). Esto permite el uso, distribución y reproducción en cualquier medio, incluidos fines comerciales, siempre que se otorgue la atribución adecuada a los autores y a la fuente original.



 : <https://doi.org/10.65011/prismaods.v4.i2.101>

Cómo citar este artículo (APA 7^a edición):

Hernández Chiquillo, S. D. ., Tlapanco Ríos, E. I. ., Barrios Sánchez, J. M. ., & Pino Jimenez, J. E. . (2025). Diagnóstico Asistido por Computadora de Neumonía Infantil Utilizando Redes Neuronales y Máquinas de Soporte Vectorial. *Prisma ODS: Revista Multidisciplinaria Sobre Desarrollo Sostenible*, 4(2), 317-331. <https://doi.org/10.65011/prismaods.v4.i2.101>