

ARTÍCULO DE INVESTIGACIÓN / RESEARCH ARTICLE

<https://dx.doi.org/10.14482/inde.39.2.621.367>

Apoyo al diagnóstico de neumonía y detección de opacidades pulmonares usando segmentación de instancias semánticas en imágenes de rayos X de tórax

Support for the Diagnosis of Pneumonia and Detection of Pulmonary Opacities Using Semantic Instance Segmentation in Chest X-ray Images

VÍCTOR MANUEL ASTUDILLO DELGADO *
DAVID ARMANDO REVELO LUNA **

*Corporación Universitaria Comfacaucá (Unicomfacaucá),
Departamento de Ingeniería Mecatrónica, Popayán, Cauca. Estudiante.
Orcid: <https://orcid.org/0000-0001-7459-8023>. victorastudillo@unicomfacaucá.edu.co.

** Corporación Universitaria Comfacaucá (Unicomfacaucá),
Departamento de Ingeniería Mecatrónica, Popayán, Cauca. Profesor.
Orcid: <https://orcid.org/0000-0002-3845-8522>. drevelo@unicomfacaucá.edu.co.

Correspondencia: Víctor Manuel Astudillo Delgado.
Cra 48B n.º 56B-12 Cali, Valle del Cauca. Teléfono: 3108293703



Resumen

La neumonía es una enfermedad que ha causado gran cantidad de muertes a nivel mundial. Los métodos de detección de neumonía: pruebas de sangre, prueba de esputo, tomografía computarizada y las radiografías (RX) de tórax en general requieren de un médico especialista y tiempo para su análisis. El objetivo de esta investigación fue generar un modelo basado en instancias semánticas y aprendizaje profundo (Mask-RCNN) que permita el apoyo en el diagnóstico de opacidades pulmonares y neumonía. Usando 12 024 imágenes de radiografías de rayos X de tórax se realizaron 3 experimentos, en los que se variaron las condiciones de las imágenes del dataset (exp1: imágenes RX pacientes con neumonía, exp2: imágenes RX pacientes sanos y con neumonía, exp3: imágenes RX pacientes sanos y con neumonía, más *data augmentation*). Para los 3 experimentos se realizó un preprocesamiento de ecualización de histograma. Para evaluar el desempeño de los modelos de identificación de opacidades y clasificación de pacientes con neumonía, se utilizaron los parámetros *intersección sobre la unión, precisión, recall, F1score y accuracy*. Se encontró que la métrica de mejor desempeño fue recall para el experimento 1 tanto para la detección de opacidades como de neumonía.

Palabras clave: aumento de datos, intersección sobre la unión, redes neuronales convolucionales, Resnet50, Sociedad Radiológica de Norteamérica.

Abstract

Pneumonia is a disease that has caused many deaths worldwide. Pneumonia detection methods: blood tests, sputum test, CT scan, and chest X-rays, generally require a specialist doctor for analysis. The objective of this research was to generate a model, based on semantic instances and deep learning (Mask-RCNN), that allows for support in the diagnosis of pulmonary opacities and pneumonia, using 12 024 images of chest X-ray radiographs. 3 experiments were carried out, where the conditions of the dataset images were varied (exp1: patients with pneumonia, exp2: healthy, and, also, pneumonia patients, exp3: healthy, and, also, pneumonia patients, plus data augmentation). For all 3 experiments, a histogram equalization pre-processing technique was performed. In order to evaluate the performance of the models, the parameters Intersection on the Union, Precision, Recall, F1 score, and Accuracy were used. In the identification of pulmonary opacities in the images, and for the classification of patients with pneumonia from healthy ones, Recall was found to be the best performing metric for experiment 1, for both opacity and pneumonia detection.

Keywords: convolutional neural networks, data augmentation, junctional intersection, radiological society of North America, ResNet50.

INTRODUCCIÓN

La neumonía es un tipo de infección respiratoria aguda (IRA) que afecta los pulmones. Estos están formados por pequeños sacos llamados alvéolos; que en pacientes sanos se llenan de aire al respirar y en personas enfermas con neumonía están llenos de pus y líquido, lo cual genera dolor al respirar y limita el oxígeno que entra a los pulmones [1]. La neumonía puede ser causada por diversos agentes infecciosos, como virus, bacterias y hongos [2]. En cuanto al diagnóstico de la neumonía, las radiografías de tórax son un importante método en todo el mundo, ya que permiten observar la presencia de líquido en los pulmones, la acumulación de aire en el espacio alrededor de ellos o si existen opacidades pulmonares asociadas [3]. Sin embargo, se requiere un médico especialista para interpretar las imágenes de rayos X de manera correcta. Las limitaciones están asociadas a incertidumbres en el diagnóstico, ya que otras enfermedades también pueden mostrar opacidades similares en las imágenes [4]. Por este motivo, se requiere precisión en la lectura de las imágenes.

La inteligencia artificial (IA) se ha venido integrando con la medicina y se han desarrollado nuevos algoritmos que han permitido dar apoyo al diagnóstico y tratamiento de enfermedades [5]; de esta manera se han desarrollado modelos de identificación para encontrar evidencias de neumonía en imágenes clínicas.

Diversos estudios han presentado exitosamente sistemas de redes neuronales convolucionales (CNN) para clasificar imágenes de RX de pacientes sanos y enfermos de neumonía. En [6] utilizaron 5840 imágenes de radiografías de tórax para entrenamiento y test, en los modelos VGG16 y VGG19, con un *accuracy* mayor que 85 ; así mismo el modelo ResNet50 obtuvo un *accuracy* del 77 % y un *recall* del 97 %, mientras que en los otros modelos fue menor que 95%. En [7] se utilizó el mismo número de imágenes para el entrenamiento y validación, en los modelos XceptionNet, AlexNet, ResNet101, y se obtuvo un *accuracy* mayor que 81 %. Por el contrario, en [8] utilizaron un mayor número de imágenes para el entrenamiento y validación (26 684 imágenes) con los modelos AlexNet, LeNet, GoogleNet, y VGGNet, obtuvieron una precisión del 95 y 97 %. El *recall* mayor fue del 98 % para los modelos GoogleNet y VGGNet.

Otros estudios se han enfocado en la detección de opacidades en imágenes RX. Es decir, más allá de clasificarlas en una categoría (paciente con neumonía o paciente sano), se ha evaluado el desempeño de las CNN para identificar si existen opacidades localizadas en las imágenes que sugieran que el paciente padece neumonía. Los estudios [9] - [10] - [11] usaron el conjunto de datos de “ChestX-ray14”, que contiene 112 120 imágenes de rayos X con catorce etiquetas de enfermedades comunes pulmonares. Con respecto a la métrica AUROC (Área bajo la curva), el resultado de mejor desempeño fue el presentado en [10] con 77,6 %. En [12] se utilizaron 29 684 imágenes para entrenamiento y test, en los modelos ResNet50 y DenseNet121, y se obtuvo una precisión mayor que 85%. Ade-

más, en el mismo estudio se propuso unir en un solo modelo la técnica de instancias semánticas (Mask-RCNN) y el modelo de detección RetinaNet y se obtuvo una precisión inferior a los anteriores modelos del estudio, pero se logró un *recall* mayor a 79 %. En las investigaciones [13] - [14] - [15], se utilizó el mismo dataset de imágenes y se obtuvo un *recall* mayor que 90 %. En [13] se presentó el valor más alto de *recall*, 97 %.

En este trabajo se presenta la técnica de Instanciación Semántica (Mask-RCNN) para detección de opacidades pulmonares diseñando tres experimentos con diferentes configuraciones en el dataset. La finalidad de la investigación consiste en utilizar el modelo Mask-RCNN para identificar opacidades pulmonares y para la clasificación de imágenes de pacientes enfermos y sanos.

En las secciones siguientes se presenta la metodología implementada para el desarrollo y validación del modelo, detallando el dataset y anotación de los datos, el procesamiento previo de las imágenes, arquitectura de la red y las métricas de desempeño utilizadas. Finalmente, se presentan los resultados más relevantes de la investigación.

METODOLOGÍA

Dataset

El conjunto de datos utilizado se obtuvo desde la plataforma Kaggle con el nombre publicado por la RSNA (Sociedad Radiológica de Norteamérica) en 2018, trabajaron en conjunto con la Sociedad de Radiología Torácica y MD.ai, que apoyó en el etiquetado de las imágenes [16]. Este conjunto de datos contiene 26 636 imágenes en formato (.dcm), de las cuales 20 672 son de imágenes de pacientes sanos y 6012 de pacientes con neumonía se encuentran etiquetadas en la página de MD.ai [17], dichas anotaciones se encuentran en formato XML. Se escogieron para esta investigación las 6012 imágenes de pacientes con neumonía y la misma proporción de imágenes de pacientes sanos convertidas a formato PNG (en total 12 024 imágenes). Para las imágenes con opacidades pulmonares se realizaron anotaciones manualmente para obtener las etiquetas en formato JSON, basándose en las etiquetas reales que se encuentran en la página de MD.ai. El dataset se dividió 75 % para entrenamiento, 20 % para validación de la red y 5 % de imágenes para test. El etiquetado de las imágenes de entrenamiento, validación y test se realizó usando el *software* VGG Image Annotator versión 1.

Procesamiento de datos

En este apartado se realizaron los tratamientos previos a las imágenes antes del entrenamiento de los modelos. Como primera instancia se dimensionaron todas las imágenes a una sola resolución, debido a que el tamaño de las imágenes de dataset no era homogéneo; para este caso se utilizó 1024x1024 píxeles, como lo indica la in-

investigación [18], luego se realizó una ecualización de histograma como etapa de pre-procesamiento [19], ecuación 1.

$$T(r_k) = \sum_{j=1}^k p_r(r_j) = \sum_{j=1}^k \frac{n_j}{n} \quad (1)$$

Donde k es el número de niveles de gris, p_r probabilidad de un cierto nivel de gris, r_j un nivel de gris “ j ” específico, n_j es un número de píxeles con nivel “ j ”, n el total de píxeles. Con la ecuación 1 se busca una distribución uniforme en los valores de intensidad en el histograma mejorando el brillo y contraste de la imagen.

Además, se aplicó la técnica de *data augmentation* al dataset [20], con el fin de aumentar el tamaño del conjunto de datos, usando las transformaciones *flipping*, *scale*, *translation*, *rotate* y *shear*, utilizando la librería *imgaug augmenters*.

Arquitectura CNN

Para esta investigación se utilizó la red neuronal convolucional basada en el modelo de instancias semánticas Mask-RCNN [21], con la finalidad de identificar opacidades pulmonares y clasificar imágenes de radiografías de tórax de pacientes con neumonía (ver figura 1). Usando este modelo de red neuronal se plantearon 3 experimentos con la arquitectura ResNet50 de base, en los que se variaron las características del dataset de entrada. Los detalles de los experimentos se presentan en la tabla 1.

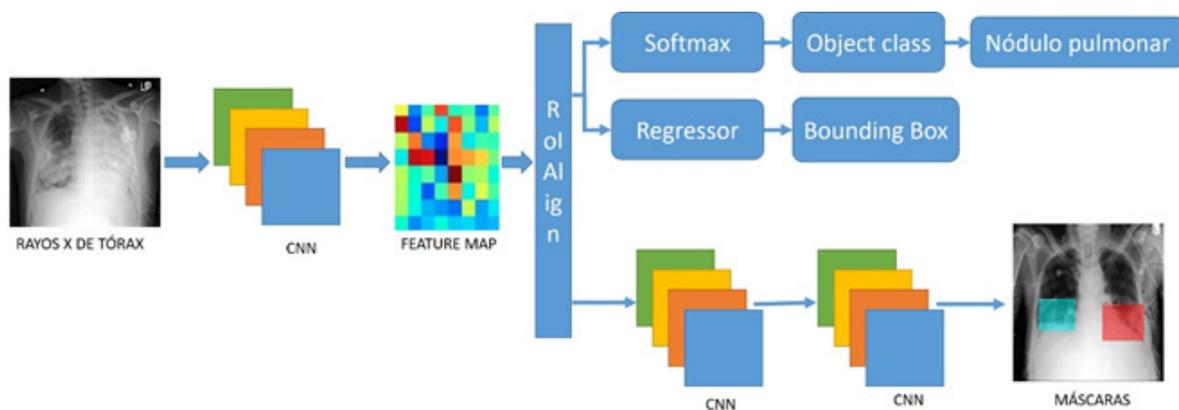


FIGURA 1. MODELO BASADO EN MASK-RCNN PARA IDENTIFICACIÓN DE OPACIDAD PULMONARES

TABLA 1. PARÁMETROS DE ENTRENAMIENTO DE LA RED MASK-RCNN

	Experimento 1	Experimento 2	Experimento 3
Tamaño imagen	[1024 1024 3]	[1024 1024 3]	[1024 1024 3]
Arquitectura base	Resnet50		
Batch Size	8	12	12
Datos Entrenamiento	Solo imágenes con neumonía (6.010)	Imágenes pacientes con neumonía y sanos, dataset balanceado (12.020)	Imágenes pacientes con neumonía y sanos, dataset balanceado, más <i>data augmentation</i> .
Learning Rate	0,001	0,001	0,001
Épocas	160	60	60
Steps	740	1000	1200
Tiempo Entrenamiento	18H	18H	18H

Métricas de desempeño

Se utilizó la media de la medida de intersección sobre la unión (IoU) para cuantificar el porcentaje de superposición entre la máscara real y la salida del modelo. La métrica IoU (ecuación 2) mide el número de píxeles comunes entre el objetivo y las máscaras de predicción dividido por el número total de píxeles presentes en ambas máscaras.

La intersección está compuesta por los píxeles que se encuentran tanto en la máscara de predicción ($B_{predicted}$) como en la máscara real ($B_{ground-truth}$), mientras que la unión se compone de todos los píxeles que se encuentran en la predicción y máscara real.

$$IoU_{region}(B_{predicted}, B_{ground-truth}) = \frac{B_{predicted} \cap B_{ground-truth}}{B_{predicted} \cup B_{ground-truth}} \quad (2)$$

Se calculó la métrica IoU para cada una de las imágenes en el conjunto de datos de test, y luego se tomó su promedio (ecuación 3). Además, se calculó la desviación estándar (ecuación 5) que permite ver la dispersión de los datos respecto a la media.

$$\bar{x}(IoU) = \frac{\sum_i^{image} IoU_I}{image} \quad (3)$$

$$\bar{x}(IoU)_{image} = \frac{\sum_i^{\# opacidades} IoU_I}{\# opacidades} \quad (4)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \bar{x}(IoU))^2} \quad (5)$$

Adicionalmente, se utilizaron las métricas *precisión*, *recall*, *F1score* y *accuracy*, calculadas según las siguientes ecuaciones:

$$Precision = \frac{Ntp}{Ntp + Nfp} \quad (6)$$

$$Recall = \frac{Ntp}{Ntp + Nfn} \quad (7)$$

$$F1Score = 2 \frac{precision \times recall}{precision + recall} \quad (8)$$

$$Accuracy = \frac{Ntp + Ntn}{Ntp + Nfp + Ntn + Nfn} \quad (9)$$

Donde *Ntp* representan los verdaderos positivos, *Nfp* falsos positivos, *Nfn* falsos negativos y *Ntn* verdaderos negativos.

Para el umbral mínimo de selección se usó el valor de $IoU > 0,45$ tomando como referencia diversas investigaciones [12] - [22], que establecieron valores aceptables, cerca del 0,5, para la métrica *IoU*.

Para identificar el desempeño del sistema en la detección de opacidades, se consideraron como verdaderos positivos todas las opacidades detectadas con un valor de *IoU* mayor que 0,45. Se consideraron falsos negativos aquellas opacidades que existen en las imágenes RX y que el sistema no detecta, o detecta con un *IoU* menor que 0,45.

Se consideraron como falsos positivos todas aquellas detecciones del sistema que no existían en las imágenes RX (ver figura 3).

Para identificar el desempeño del sistema en la clasificación de pacientes con neumonía y pacientes sanos, se utilizó la media $\bar{x}(IoU)$ por cada imagen del dataset de test (ecuación 4). El dataset se dividió en dos partes: pacientes enfermos y pacientes sanos. En los pacientes enfermos, todas las imágenes con $\bar{x}(IoU)$ mayores que 0,45, verdaderos positivos y las imágenes con $\bar{x}(IoU)$ menor a 0,45 se consideraron falsos negativos. Aquellas detecciones del modelo en imágenes RX de pacientes sanos se consideraron como falsos positivos. Las imágenes RX de pacientes sanos, en las que el sistema no detectó opacidades, se consideraron verdaderos negativos (ver figura 2).

Finalmente, para los dos casos se utilizaron *precisión* (ecuación 6), *recall* (ecuación 7) y *F1score* (ecuación 8). *Accuracy* (ecuación 9) solo para la clasificación entre pacientes con neumonía y pacientes sanos.

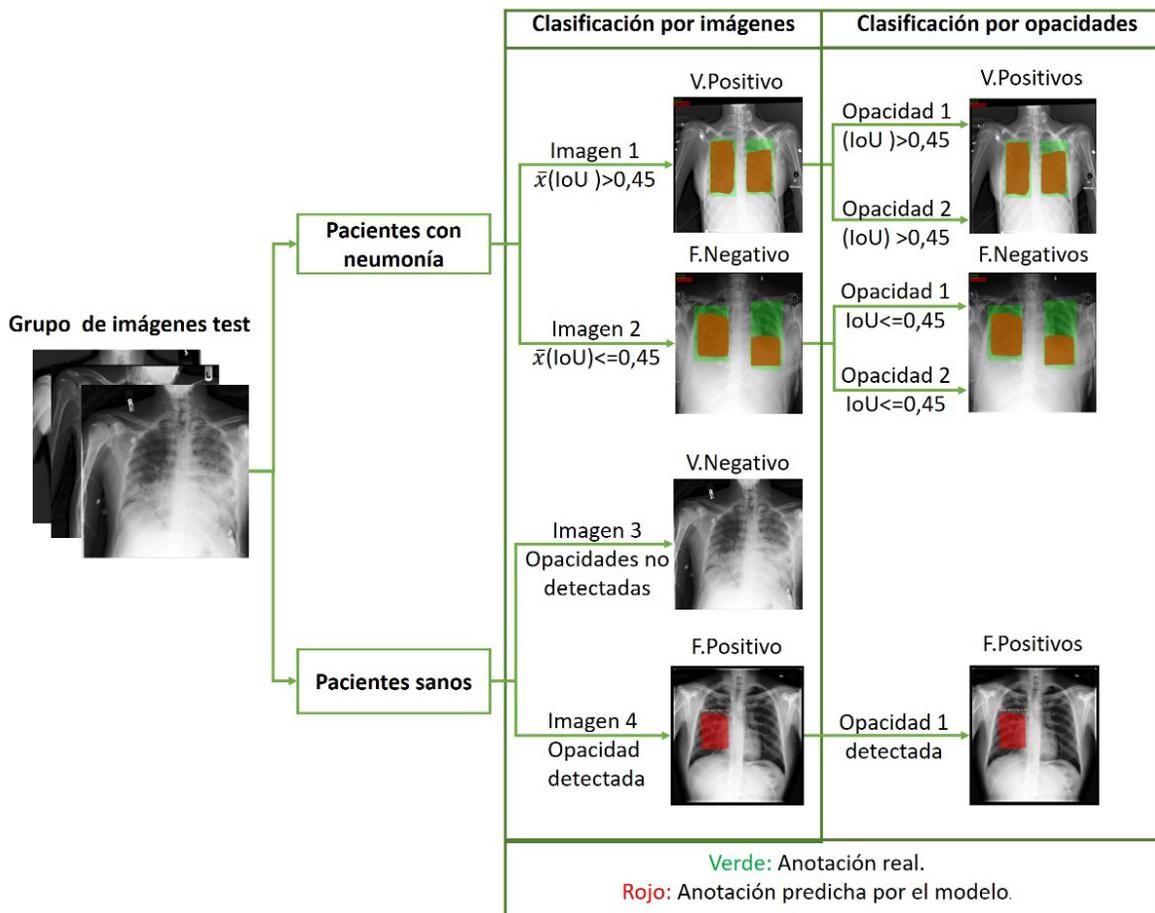


FIGURA 2. DIAGRAMA DE SELECCIÓN DE UMBRALES PARA LAS MÉTRICAS DE DESEMPEÑO

RESULTADOS Y DISCUSIÓN

Pre-procesamiento de imágenes RX

Como preprocesamiento se realizó ecualización de histograma a las imágenes del dataset. El efecto de la ecualización mostró mejoras en el brillo y contraste de las imágenes RX, resaltando los detalles como bordes o variaciones en la iluminación (ver figura 3).

a. Imagen original

b. Imagen con ecualización de histograma



FIGURA 3. APLICACIÓN DE ECUALIZACIÓN DE HISTOGRAMA AL DATASET: A. IMAGEN ORIGINAL, B. IMAGEN CON ECUALIZACIÓN DE HISTOGRAMA

Detección de opacidades Mask-RCNN

Se evaluaron los modelos obtenidos en el proceso de entrenamiento correspondiente a los 3 experimentos antes descritos; cada uno de ellos se evaluó usando las métricas presentadas en la sección anterior. Se estimó el IoU para cada imagen de test usando los tres modelos obtenidos. En la figura 4.A se muestran las etiquetas que se asignaron manualmente, en la 4.B se muestran las máscaras predichas por el modelo Mask-RCNN, y en la 4.C se observa la unión (color verde) y la intersección (color rojo) de las etiquetas reales y las predichas por el modelo.



FIGURA 4. APLICACIÓN DE LA MÉTRICA IOU INDIVIDUAL: A. ANOTACIÓN MÁSCARA, B. RESULTADO MÁSCARA, C. UNIÓN E INTERSECCIÓN

En la figura 5.A se presenta la distribución de valores de IoU de los tres experimentos utilizando el mismo grupo de imágenes de test y en la figura 5.B se observa la dispersión y la simetría de los datos. Se calculó además la media total de las IoU y la desviación estándar de los datos, para cada modelo. Para el experimento 1 $\bar{x}(IoU)$: 0,6207 y σ : 0,1336; el experimento 2 $\bar{x}(IoU)$: 0,5882 y σ : 0,1523, y para el experimento 3 $\bar{x}(IoU)$: 0,5777 y σ : 0,1953. Con base en los gráficos y la desviación estándar se concluye que las IoU obtenidas de los tres experimentos se centran en unos valores cercanos en el rango de 0,6 y 0,7, lo cual significa que los 3 experimentos obtuvieron un comportamiento similar en la identificación de verdaderos positivos, ya que el valor central es mayor que el umbral establecido (>0.45).

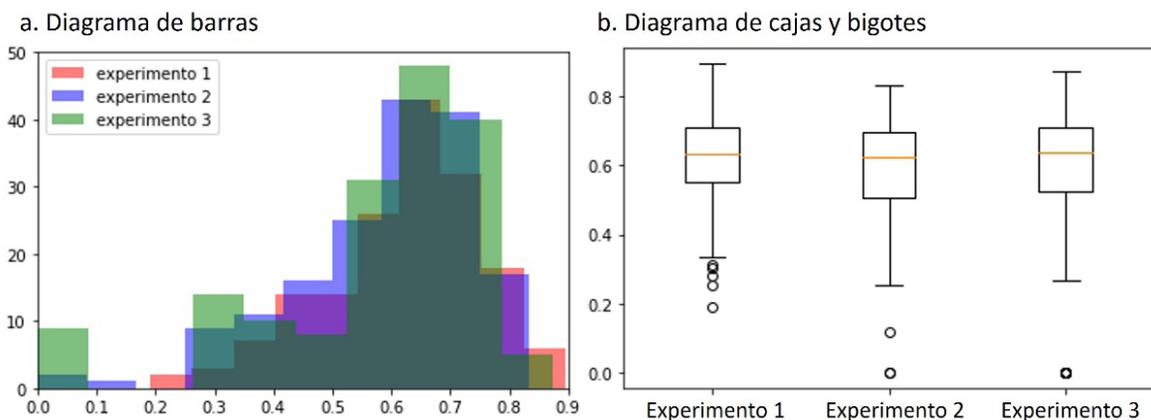


FIGURA 5. DIAGRAMAS DE DESEMPEÑO DE LA MÉTRICA IOU GLOBAL DE GRUPO DE IMÁGENES TEST

Desempeño de los modelos en la detección de opacidades

En la tabla 2 se muestran las métricas de desempeño que se obtuvieron de los experimentos para predecir opacidades pulmonares. El experimento 3 fue el de mayor precisión. Además, fue la configuración que utilizó el grupo de entrenamiento de imágenes balanceado más *data augmentation*. La métrica recall es una medida relevante en modelos que involucran aplicaciones médicas, ya que es importante que el modelo no clasifique pacientes enfermos como sanos. El experimento 1 fue el del mayor recall; dicho experimento solo se entrenó con imágenes de pacientes con neumonía; este modelo tuvo un mejor desempeño para identificar opacidades pulmonares en los pacientes enfermos, disminuyendo los falsos negativos, pero aumentando los posibles falsos positivos en las imágenes.

TABLA 2. MÉTRICAS DE DESEMPEÑO DE LOS MODELOS PARA IDENTIFICAR OPACIDADES PULMONARES

Mask-RCNN	Precisión	Recall	F1Score
Experimento 1	0,7627	0,9513	0,8466
Experimento 2	0,7164	0,8801	0,7899
Experimento 3	0,8075	0,8801	0,8422

Desempeño de los modelos en la detección de neumonía

Se estimaron las métricas para la clasificación de imágenes con neumonía utilizando el mismo grupo de imágenes test. En la figura 6 se observa la matriz de confusión para cada experimento. En las matrices de confusión se identificó que el experimento 1 y 2 lograron identificar un mayor número de aciertos de verdaderos positivos. Por el contrario, el experimento 3 obtuvo un menor número de aciertos en verdaderos positivos, pero mejoró en disminuir los falsos positivos, y además obtuvo el mayor número de aciertos en verdaderos negativos, lo cual significa que logró identificar un mayor número de pacientes sanos en comparación con los otros experimentos. Por último, el experimento 1 obtuvo el menor valor en falsos negativos, parámetro importante en aplicaciones médicas que buscan no clasificar pacientes enfermos como pacientes sanos.

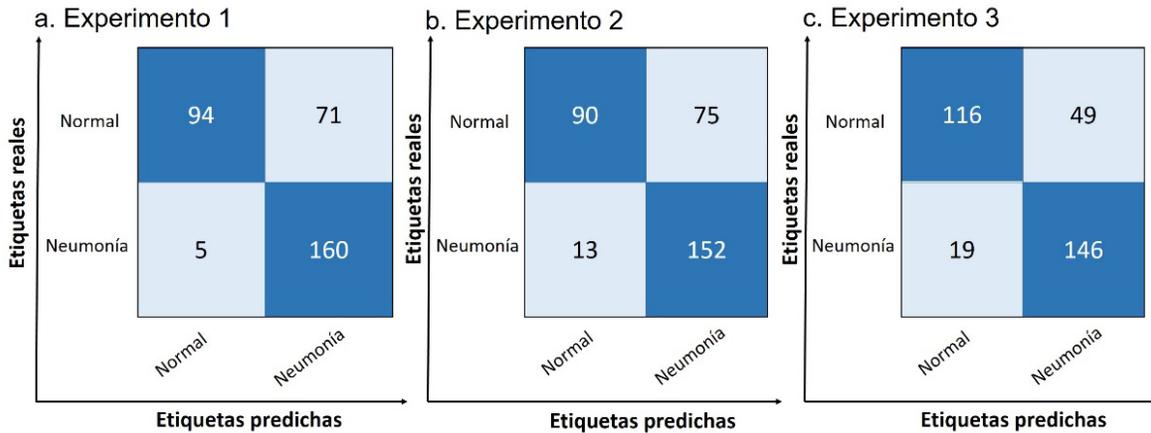


FIGURA 6. MATRIZ DE CONFUSIÓN DE LOS EXPERIMENTOS: A. EXPERIMENTO 1, B. EXPERIMENTO 2, C. EXPERIMENTO 3

En la tabla 3 se presentan las métricas de desempeño que tuvieron los modelos para clasificar imágenes de pacientes con neumonía y pacientes sanos. El modelo del experimento 3 presentó el mayor *accuracy* en comparación con los modelos obtenidos de los experimentos 1 y 2, en consecuencia, éste identificará en mayor proporción pacientes enfermos y sanos correctamente. Además, el experimento 1 obtuvo el *recall* más alto, lo cual significa que identificará en menor proporción falsos negativos.

TABLA 3. MÉTRICAS DE DESEMPEÑO DE LOS MODELOS PARA CLASIFICAR IMÁGENES DE PACIENTES CON NEUMONÍA

Mask-RCNN	Precisión	Recall	F1 Score	Accuracy
Experimento 1	0,7026	0,9696	0,8080	0,7696
Experimento 2	0,6696	0,9212	0,7755	0,7333
Experimento 3	0,7487	0,8848	0,8111	0,7939

El tamaño y la configuración del dataset de entrenamiento han mostrado que influyen en el desempeño del modelo. Existen varios estudios en los que usaron el dataset de RSNA (26 684 imágenes) para la detección de opacidades pulmonares y neumonía, con diferentes resultados. En [8] se redimensionó el dataset a 1024x1024 y se realizó *data augmentation* utilizando las técnicas *rotation*, *horizontal flipping* y *scale*. Los resultados mostraron una precisión del 89% utilizando ResNet50. Así mismo en [12] redimensionaron las imágenes a 512x512, entrenaron Mask-RCNN solo con

imágenes de neumonía, y usaron RetinaNet con el dataset completo. Integrando los dos modelos obtuvieron una precisión del 76%. En [23] utilizaron el dataset “ChestX-ray14”, que contiene 112 120 imágenes, que consta de 6643 con neumonía y 60 412 de pacientes sanos, obtuvieron una precisión del 89 %. En comparación con los resultados obtenidos en este estudio, el modelo obtenido en el exp1, con la configuración del dataset de solo imágenes con neumonía, fue superior en *recall* a los referentes consultados, con un valor de 96 %.

En [6] se utilizó un dataset de 5840 imágenes con dimensiones de 64x64, además se empleó la técnica dropout para reducir el sobre-ajuste del modelo ResNet50, y se obtuvo un *accuracy* del 77,56 % y *recall* del 97 %. En comparación con el modelo obtenido del exp3 aquí presentado, con la configuración del dataset balanceado más *data augmentation*, los referentes mostraron un *accuracy* menor, dado que el resultado obtenido en esta investigación fue del 79 %.

CONCLUSIONES

En esta investigación se presentó el modelo Mask-RCNN para la identificación de opacidades pulmonares y para la clasificación de pacientes con neumonía, usando imágenes RX. Se desarrollaron 3 experimentos con diferentes configuraciones en el dataset. El modelo que obtuvo mayor precisión (80 % y 74 %), para la detección de opacidades y neumonía, respectivamente, fue el modelo asociado al experimento 3, en el que se usó un dataset balanceado y con *data agumentation*.

Considerando la importancia de la minimización de falsos negativos en los sistemas de detección y clasificación en aplicaciones médicas, se prioriza el modelo con mayor *recall* sobre los demás. El mejor modelo bajo esa perspectiva con *recall* (95 % y 96 %), para la detección de opacidades y neumonía, fue el modelo asociado al experimento 1 donde se usó solamente imágenes RX de pacientes con neumonía.

Para trabajos futuros se sugiere considerar el uso de metainformación, como sexo, edad y antecedentes del paciente, que son características adicionales útiles que pueden ayudar al apoyo del diagnóstico de neumonía. Además, se propone el uso de otras arquitecturas de redes neuronales convolucionales, o modelos de instancias semánticas, que puedan proporcionar herramientas adicionales para el apoyo del diagnóstico de neumonía.

Estos resultados sugieren que las técnicas de instancias semánticas pueden ser útiles en el apoyo al equipo médico para el diagnóstico de la neumonía, agilizando los procesos clínicos de tratamiento.

REFERENCIAS

- [1] Organización Mundial de la Salud, “Organización Mundial de la Salud”, OMS, abril 2019. [En línea]. Disponible en: <https://www.who.int/es/news-room/fact-sheets/detail/pneumonia>. [Último acceso: 7 - abr. - 2021].
- [2] Biblioteca Nacional de Medicina de EE. UU, “MedlinePlus”, Biblioteca Nacional de Medicina de EE. UU., marzo 2020. [En línea]. Disponible en: <https://medlineplus.gov/spanish/ency/article/000145.htm#:~:text=Las%20formas%20como%20se%20puede,microbios%20directamente%20hacia%20los%20pulmones>. [Último acceso: 7 - abr.-2021].
- [3] Mayo Clinic, “Mayo Clinic”, 2 mayo 2020. [En línea]. Disponible en: <https://www.mayoclinic.org/es-es/tests-procedures/chest-x-rays/about/pac-20393494> [Último acceso: 7 - abr.-2021].
- [4] M. I. Neuman, E. Y. Lee, . S. Bixby, S. Diperna, . J. Hellinger, R. Markowitz, S. Servaes, M. C. Monuteaux y S. S. Shah, “Variability in the interpretation of chest radiographs for the diagnosis of pneumonia in children”, *Journal of hospital medicine*, vol. 7, n.º 4, pp. 294-298, 2012. <https://doi.org/10.1002/jhm.955>.
- [5] M. d. C. Expósito Gallardo y R. Ávila Ávila, “Aplicaciones de la inteligencia artificial en la Medicina: perspectivas y problemas”, *ACIMED*, vol. 17, n.º 5, 2008.
- [6] R. Jain, P. Nagrath, G. Kataria, S. Kaushik y D. J. Hemanth, “Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning”, *Measurement*, vol. 165, p. 10, mayo 2019. <https://doi.org/10.1016/j.measurement.2020.108046>.
- [7] X. Yu, S. HuaWang y Y. DongZhang, “CGNet: A graph-knowledge embedded convolutional neural network for detection of pneumonia”, *Information Processing & Management*, vol. 58, n.º 1, p. 25, 2021. <https://doi.org/10.1016/j.ipm.2020.102411>.
- [8] S. Militante y B. Sibbaluca, “Pneumonia Detection Using Convolutional Neural Networks”, *Revista Internacional de Investigación Científica y Tecnológica*, vol. 9, n.º 04, pp. 1332-1337, 2020. <https://doi.org/10.46501/ijmtsto70117>.
- [9] P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, C. Langlotz, K. Shpanskaya, L. Matthew y A. Ng, “CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning”, *ArXiv*, vol. 1711.05225, 2017. (favor, aclarar si este número corresponde a número de la edición o a las páginas)
- [10] Q. Guan, Y. Huang, Z. Zhong, Z. Zheng, L. Zheng y Y. Yang, “Diagnose like a Radiologist: Attention Guided Convolutional Neural Network for Thorax Disease Classification”, *ArXiv*, vol. 1801.09927, 2018. (favor, aclarar si este número corresponde a número de la edición o a las páginas)

- [11] L. Yao, E. Poblens, D. Dagunts, B. Covington, D. Bernard y K. Lyman, “Learning to diagnose from scratch by exploiting dependencies among labels”, *ArXiv*, vol. 1710.10501, 2018. (favor, aclarar si este número corresponde a número de la edición o a las páginas)
- [12] I. Sirazitdinov, M. Kholiavchenko, T. Mustafaev, Y. Yixuan, R. Kuleev y B. Ibragimov, “Deep neural network ensemble for pneumonia localization from a large-scale chest x-ray database”, *Computers and Electrical Engineering*, vol. 78, pp. 388-399, 2019. <https://doi.org/10.1016/j.compeleceng.2019.08.004>.
- [13] S. Chen, Y. Han, J. Lin, X. Zhao y P. Kong, “Pulmonary nodule detection on chest radiographs using balanced convolutional neural network and classic candidate detection”, *Artificial Intelligence in Medicine*, vol. 107, n.º (Debe agregarse las páginas) 101881, julio 2020. <https://doi.org/10.1016/j.artmed.2020.101881>.
- [14] C. Li, G. Zhu, X. Wu y Y. Wang, “False-Positive Reduction on Lung Nodules Detection in Chest Radiographs by Ensemble of Convolutional Neural Networks”, *IEEE Access*, vol. 6, pp. 16060-16067, 2018. <https://doi.org/10.1109/ACCESS.2018.2817023>.
- [15] X. Li, L. Shen y S. Luo, “A Solitary Feature-Based Lung Nodule Detection Approach for Chest X-Ray Radiographs”, *IEEE Journal of Biomedical and Health Informatics*, vol. 22, n.º 2, pp. 516-524, 2018. <https://doi.org/10.1109/JBHI.2017.2661805>.
- [16] Radiological Society of North America, “Kaggle”, oct. 2018. [En línea]. Disponible en: <https://www.kaggle.com/c/rsna-pneumonia-detection-challenge>. [Último acceso: 21-mayo-2021].
- [17] MD.ai, “Public MD.ai”, 2018. [En línea]. Available: <https://public.md.ai/annotator/project/LxR6zdR2/workspace>. [Último acceso: 25 - ago- 2021].
- [18] S. Militante y B. Sibbaluca, “Pneumonia Detection Using Convolutional Neural Networks”, *Revista Internacional de Investigación Científica y Tecnológica*, vol. 9, n.º 04, pp. 1332-1337, 2020.
- [19] F. Luis, D. Daniel y D. Roberto, “Optimización de la ecualización del histograma en el procesamiento de imágenes digitales”, en *VII Workshop de Investigadores en Ciencias de la Computación*, Florencio Varela, 2005.(favor, aclarar a qué corresponde este nombre)
- [20] L. Taylor y G. Nitschke, “Improving Deep Learning using Generic Data Augmentation”, en *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, Bangalore, India, 2018. <https://doi.org/10.1109/SSCI.2018.8628742>.
- [21] K. He, G. Gkioxari, P. Dollar y R. Girshick, “Mask R-CNN”, en *2017 Proceedings of the IEEE international conference on computer vision*, 2017. <https://doi.org/10.1109/ICCV.2017.322>.
- [22] A. K. Jaiswal, P. Tiwari, S. Kumar, D. Gupta, A. Khanna y J. Rodrigues, “Identifying pneumonia in chest X-rays: A deep learning approach”, *Measurement*, vol. 145, pp. 511-518, 2019. <https://doi.org/10.1016/j.measurement.2019.05.076>.

- [23] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri y R. Summers, “ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases”, en *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/CVPR.2017.369>.

