

XDApp: Clasificación de radiografías por medio de una aplicación móvil

Juan Eduardo Luján García, Areli Yesareth Guerrero Estrada,
Cornelio Yáñez Márquez

Instituto Politécnico Nacional,
Centro de Investigación en Computación,
México

{jeduardolujan5, ayge.1904}@gmail.com, cyanez@cic.ipn.mx

Resumen. Existen una gran variedad de enfermedades respiratorias que pueden ser diagnosticadas por medio de estudios de imagen como lo son las radiografías de tórax. Por lo tanto, es posible analizar y clasificar distintas enfermedades con el uso de aprendizaje profundo, específicamente con la implementación de redes neuronales convolucionales. En este trabajo se presenta una aplicación móvil llamada XDApp que utiliza un modelo entrenado en un banco de datos multiclase de pacientes con COVID-19, neumonía, tuberculosis y sanos, para emitir un prediagnóstico de las radiografías. Esta aplicación permite realizar de manera accesible un prediagnóstico para ayudar a médicos especialistas y además, puede ser usada como recurso didáctico para estudiantes del área de la salud. Por último, la aplicación utiliza un modelo de TensorFlow Lite para realizar la inferencia, obteniendo así valores de AUC mayores a 95.18 % en cada clase.

Palabras clave: Aprendizaje profundo, red neuronal convolucional, radiografías, app móvil, clasificación.

XDApp: A Mobile App for Radiography Classification

Abstract. There are a wide variety of respiratory diseases that can be diagnosed through imaging studies such as chest radiographs. Therefore, it is possible to analyze and classify different diseases using deep learning, specifically with the implementation of convolutional neural networks. In this work, a mobile application is presented which uses a trained model on a multi-class dataset of patients with COVID-19, pneumonia, tuberculosis, and healthy subjects, in order to issue a pre-diagnosis of the radiographs. This application provides a pre-diagnosis accessible to help physicians and can also be used as a teaching resource for students in the health field. Finally, the application uses a TensorFlow Lite model to perform inference, obtaining AUC values greater than 95.18 % in each class.

Keywords: Deep learning, convolutional neural network, radiography, mobile app, classification.

1. Introducción

Las enfermedades respiratorias son de las más comunes en pacientes, generalmente ocasionadas por brotes estacionarios y virus altamente contagiosos. Dentro de las enfermedades respiratorias más frecuentes podemos encontrar influenza, síndrome agudo respiratorio (SARS), neumonía, tuberculosis y recientemente la enfermedad por coronavirus del año 2019 (COVID-19) ocasionada por el virus SARS-CoV-2.

La neumonía es una enfermedad infecciosa que puede ser ocasionada por virus, bacterias y hongos. Entre las bacterias más comunes que la producen está el *Streptococcus neumoniae* y la *Haemophilus influenzae*. Es la enfermedad respiratoria que causa más muertes en infantes, particularmente menores de 5 años, tan solo en 2019 ocasionó la muerte de más de 700 mil niños en todo el mundo [12, 14].

La tuberculosis es ocasionada principalmente por una bacteria llamada *Mycobacterium tuberculosis*. Esta bacteria ocasiona que el tejido infectado muera (necrosis) y puede manifestarse en varias partes del cuerpo, no necesariamente en los pulmones [13]. Es una de las principales causas de muerte en el mundo, provocando la muerte de 1.5 millones de personas en 2020 [13].

Por otra parte, el COVID-19 ha resultado ser una de las enfermedades infecciosas más mortíferas hasta la fecha. La reciente pandemia por COVID-19, que inició en el año 2019, ha provocado más de 191 millones de contagios y casi 3 millones de muertes tan solo en el continente americano [15].

Todas las enfermedades respiratorias mencionadas tienen algo en común, esto es que pueden ser diagnosticadas utilizando estudios de imagen como lo son radiografías de tórax (CXRAY) y tomografía computarizada (TC) [20].

Cada enfermedad presenta características radiológicas diferentes, por ejemplo, la neumonía comúnmente causa acumulación de líquido en los pulmones que se manifiesta como segmentos radiopacos (segmentos blanquecinos sobre fondo negro) [21] en las radiografías.

Por otro lado, el COVID-19 típicamente presenta, además de inflamación en los bronquios, patrones de vidrio deslustrado y de pavimento loco en la periferia de los lóbulos inferiores de los pulmones [22].

Estos pueden ayudar a los especialistas a diferenciarlo de la neumonía típica; por el contrario, la tuberculosis causa necrosis en el tejido, el cual se muestra como pequeñas bolitas oscuras dentro de los pulmones y otras partes del cuerpo [21]. Sin embargo, es necesario que un médico especialista se encargue de interpretar los estudios de imagen para poder proveer de un diagnóstico correcto.

El presente trabajo se encuentra estructurado de la siguiente manera: la sección 2 describe brevemente el estado del arte del aprendizaje profundo aplicado al área de la salud; en la sección 3, se describen los métodos y materiales utilizados para el desarrollo del presente trabajo.

En la sección 4, se detalla el modelo propuesto para resolver la tarea de clasificación multiclase; en la sección 5, se presentan los resultados y discusión de los mismos; finalmente, en la sección 6 se establecen las conclusiones y trabajo futuro de esta investigación.

Tabla 1. Particiones de cada banco de datos para conformar el banco multiclase.

Banco de datos	Partición	Número de imágenes
Tuberculosis	Entrenamiento	275
	Validación	38
	Prueba	81
Neumonía	Entrenamiento	828
	Validación	436
	Prueba	487
COVID-19	Entrenamiento	334
	Validación	47
	Prueba	97
Sanos	Entrenamiento	2133
	Validación	265
	Prueba	499

2. Aprendizaje profundo aplicado al área de la salud

Hoy en día, el aprendizaje profundo (DL, por sus siglas en inglés) es uno de los conjuntos de técnicas de aprendizaje automático (ML, por sus siglas en inglés), para tareas de visión por computadora más popular dentro del estado del arte. Más aún, la clasificación de imágenes médicas (incluyendo las de estudios radiológicos) se realiza principalmente con técnicas de DL con el uso de redes neuronales convolucionales (CNN, por sus siglas en inglés) [25, 5].

Al mismo tiempo, existen múltiples intentos por resolver tareas de clasificación de radiografías utilizando modelos ligeros de DL [19, 18, 16], que puedan ser más eficientes y que, incluso, puedan ser embebidos en dispositivos móviles como smartphones, tablets y tarjetas de desarrollo como Raspberry Pi, Jetson, entre otras. Asimismo, se han creado una gran variedad de aplicaciones móviles relacionados con temas de salud, bienestar y medicina.

En particular, se han desarrollado aplicaciones de asistencia médica ayudando a pacientes a mantener el control de sus enfermedades, mejorando el autocuidado y el seguimiento a pacientes que han mostrado una mejora en la calidad de vida, dolor y actividad en los pacientes [2, 23, 24]. Las aplicaciones móviles son una parte importante de las tecnologías del aprendizaje y conocimiento que facilitan el estudio de temas de alta complejidad, mejorando las competencias de los profesionales, ya que permiten una mayor interacción con escenarios virtuales.

El uso de imágenes para observar las estructuras es fundamental como complemento a las prácticas en el área de la salud [10]. También se han desarrollado aplicaciones para la creación de ambientes de aprendizaje que permitan comprender los factores que afectan la enseñanza de estudiantes de medicina [3]. De tal forma que, el uso e implementación de técnicas DL pueden ser de ayuda para el prediagnóstico de enfermedades por medio del análisis de radiografías.

Agregado a lo anterior, la disponibilidad de una aplicación móvil que ayude a realizar este tipo de prediagnósticos, serían útiles en lugares en los cuales no hay alta disponibilidad de médicos radiólogos.

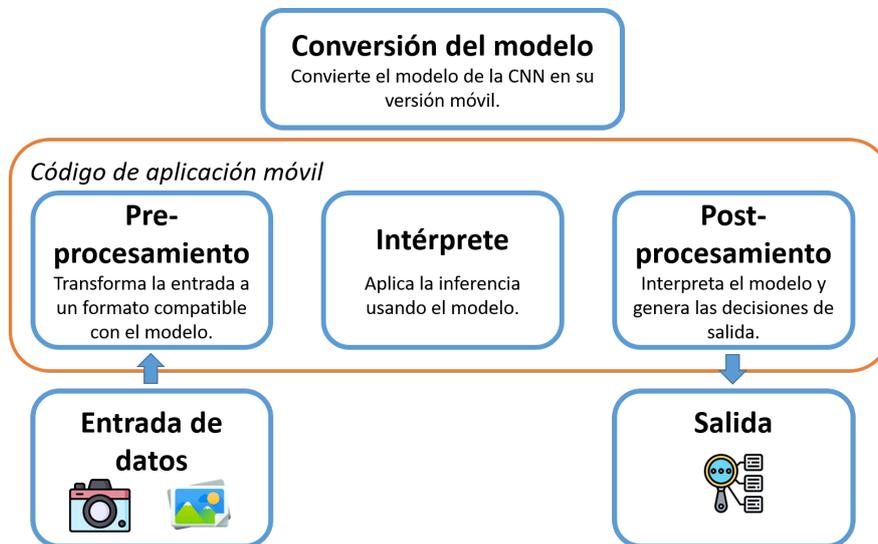


Fig. 1. Esquema de implementación de modelos de TensorFlow Lite en dispositivos móviles.

Por lo tanto, ayudaría en la práctica y enseñanza de diagnósticos que emplean imágenes radiológicas para estudiantes del área de la salud y las distintas especialidades.

3. Métodos y materiales

En esta sección, se describen los bancos de datos de imágenes radiológicas de vista postero-anterior usados para entrenar el modelo de CNN. Después, se menciona el método de validación utilizado para dividir los bancos de datos y crear el nuevo banco de datos multiclase. Finalmente, se especifican las métricas usadas para evaluar el desempeño del modelo.

3.1. Bancos de datos

Se generó un banco de datos multiclase utilizando bancos de datos de tuberculosis, COVID-19 y neumonía para obtener a los pacientes enfermos; y los bancos de tuberculosis, neumonía y neumotórax [7] para los pacientes sanos. A continuación, se describen brevemente los bancos de datos empleados para obtener las imágenes de pacientes enfermos.

Tuberculosis. Es una colección de imágenes de rayos X del tórax de dos hospitales, recopilada por el Instituto Nacional de Salud de los Estados Unidos [8]. Está formado por el conjunto del condado de Montgomery, el cual posee 138 imágenes, de las cuales 80 son casos sanos y 58 son enfermos de tuberculosis; así como el conjunto de Shenzhen, que tiene 662 radiografías frontales con 326 pacientes sanos y 336 pacientes enfermos de tuberculosis.

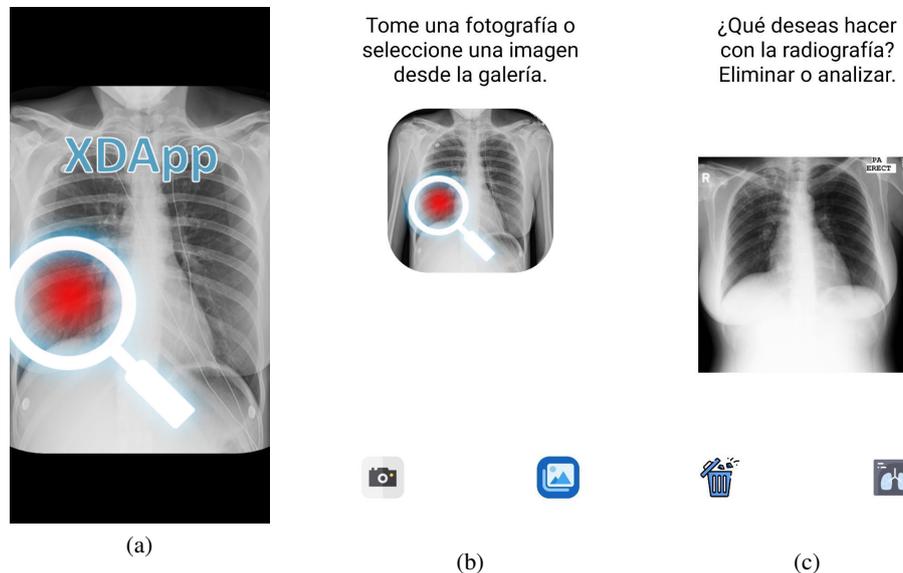


Fig. 2. Capturas de pantalla de la aplicación móvil. a) Imagen de bienvenida a la aplicación; b) Pantalla principal para captura o carga de imágenes; c) Imagen seleccionada cargada en la aplicación.

COVID-19. Comprende una colección de imágenes de rayos X de tórax de pacientes enfermos con COVID-19 recopilados por Cohen et al. [4] durante el 2020, con un total de 478 imágenes.

Neumonía. Se emplearon dos bancos de datos de neumonía, el conjunto de datos pediátrico generado por Kermany et al. [9] y el conjunto RSNA Pneumonia Detection Challenge (RSNA-PC) disponible como una competencia de la plataforma Kaggle ¹.

El conjunto publicado por Kermany et al. está formado por 5853 imágenes en el conjunto de entrenamiento, de los cuales 3883 son pacientes infectados con neumonía y 1349 son pacientes sanos; y 624 en el conjunto de prueba, dividido en 390 imágenes de pacientes enfermos y 234 de sanos.

El banco de datos RSNA-PC está formado por 3000 radiografías de tórax de adultos en el conjunto de prueba y 26684 en el conjunto de entrenamiento, de las cuales el 29 % corresponde a imágenes normales y 71 % de imágenes con áreas dañadas del pulmón causadas por neumonía. De este banco, se tomaron 478 imágenes de pacientes sanos y 478 de enfermos para balancearlo con el número de casos del banco de COVID-19.

3.2. Método de validación

Para la validación de los resultados se empleó el método Hold-out 70-10-20 para obtener el conjunto de entrenamiento, validación y prueba. Este método consiste en dividir aleatoriamente el conjunto de datos en 70 % para el conjunto de entrenamiento, 10 % para la validación y 20 % para el conjunto de prueba.

¹ kaggle.com/c/rsna-pneumonia-detection-challenge

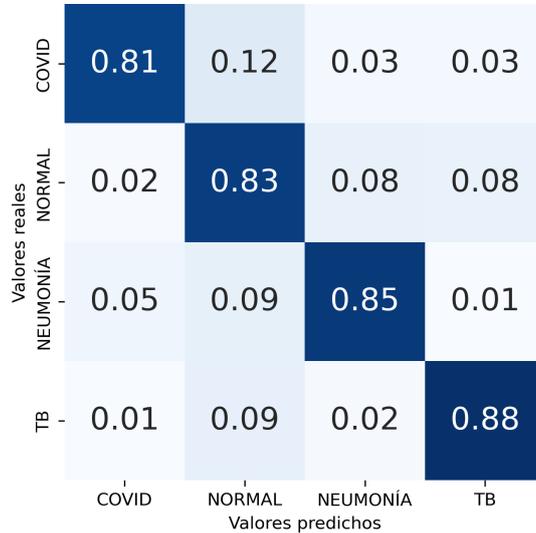


Fig. 3. Resultados de clasificación de enfermedades con NanoChest-Net.

Este método se empleó para todos los bancos de datos, excepto para el de Kermany que ya cuenta con un conjunto de prueba oficial. En este caso, el conjunto de entrenamiento se dividió en 90 % para entrenamiento y 10 % para la validación. En la tabla 1 se muestran las particiones para cada conjunto de datos.

3.3. Métricas de desempeño

Para bancos de datos desbalanceados, existen métricas útiles para evaluar el desempeño de un clasificador. Por ejemplo, la tasa de verdaderos positivos (TPR, por sus siglas en inglés), también conocida como sensibilidad (eq. (1)) evalúa la habilidad del clasificador para detectar la presencia de una condición entre el total de instancias:

$$\text{TPR/sensibilidad} = \frac{tp}{tp + fn}. \quad (1)$$

La tasa de falsos positivos (FPR, por sus siglas en inglés), indica cuando se produce una falsa alarma, es decir, la proporción de instancias predichas erróneamente como positivas por el clasificador (eq. (2)):

$$\text{FPR} = \frac{fp}{tn + fp}. \quad (2)$$

Por otro lado, el valor de predicción positiva (PPV por sus siglas en inglés) o precisión (eq. (3)), mide la proporción de instancias verdaderamente positivas entre las predichas positivas por el clasificador:

$$\text{PPV/precision} = \frac{tp}{tp + fp}. \quad (3)$$

Tabla 2. Métricas de desempeño en banco de datos multiclase.

Clase	Precisión	Sensibilidad	F1	AUC
COVID-19	0.6991	0.8144	0.7524	0.9786
NORMAL	0.8697	0.8297	0.8492	0.9518
NEUMONÍA	0.9035	0.8460	0.8738	0.9601
TB	0.5966	0.8765	0.7100	0.9829
Promedio macro	0.7673	0.8417	0.7964	0.9687

Otra medida muy utilizada con datos desbalanceados es la medida F_1 . La medida F_1 (eq. (4)), evalúa la similitud entre las instancias positivas verdaderas y las predichas por el clasificador. Esta métrica es la media armónica entre la precisión y la sensibilidad:

$$F_1 = \frac{2 \cdot tp}{2 \cdot tp + fp + tn} = 2 \cdot \frac{\text{precision} \cdot \text{sensibilidad}}{\text{precision} + \text{sensibilidad}}. \quad (4)$$

Por último, otra técnica para visualizar el desempeño de un clasificador es evaluar la relación entre TPR y FPR a diferentes umbrales, esto es conocido como curvas ROC [6]. De la misma manera, se puede calcular el área bajo la curva ROC (AUC), a mayor área, mejor desempeño por parte del clasificador.

4. Propuesta

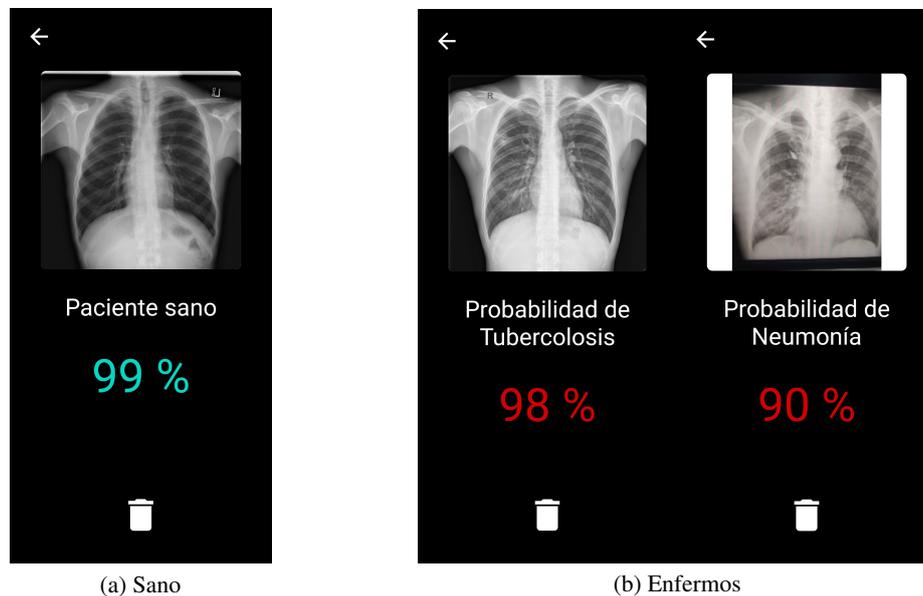
Para la clasificación de radiografías, se implementó el modelo convolucional llamado NanoChest-Net [11], que fue desarrollado exclusivamente para clasificar imágenes de estudios radiológicos de manera eficiente debido al tamaño del mismo (13.5 MB en su versión para móvil). Se entrenó dicho modelo en el banco de datos multiclase que incluye las distintas enfermedades y los pacientes sanos.

Una vez que la CNN fue entrenada, se convirtió el modelo a su versión de TensorFlow Lite para utilizarlo como modelo de inferencia dentro de la aplicación móvil XDApp (X-ray Diagnosis App).

La Figura 1 representa el esquema de implementación de TensorFlow Lite en kotlin, los datos de entrada se refieren a las imágenes que se convierten a mapa de bits, redimensionado a $1 \times 250 \times 250 \times 3$ para ser procesados por el intérprete que utiliza la CNN para generar la salida.

La salida es un tensor de tamaño 4×1 que contiene las probabilidades de que la imagen pertenezca a cada clase. Por lo tanto, se selecciona la clase con mayor probabilidad para mostrarla al usuario e indicar si el paciente tiene alguna enfermedad o está sano.

La aplicación móvil permite analizar imágenes adquiridas desde la cámara del dispositivo o cargar imágenes desde la galería. Al analizar las imágenes, la aplicación emitirá un prediagnóstico, indicando la probabilidad de que una enfermedad esté o no presente como se muestra en la Figura 2.



5. Resultados y discusión

5.1. Experimentación

Se utilizó Python 3.11 como lenguaje de programación, se empleó la librería TensorFlow 2.9.1 [1] para el procesamiento de aprendizaje profundo con Keras como API de alto nivel y la biblioteca scikit-learn [17] para obtener las métricas de desempeño.

El entrenamiento de la CNN se realizó en un equipo con las siguientes características: procesador Intel Core i7 5930K; 16 GB RAM; tarjeta de gráficos discretos Nvidia RTX 2070S. Para el diseño y programación de la aplicación móvil se empleó como lenguaje kotlin y la biblioteca TensorFlow Lite para integrar el modelo entrenado usando Android Studio como entorno de desarrollo.

Las imágenes fueron normalizadas y redimensionadas al tamaño de entrada del modelo NanoChest-Net (250x250x3), además se aplicaron técnicas de aumento de datos con el fin de que el modelo trate de generalizar al entrenar con un mayor número de ejemplos diferentes. De tal forma, se aplicaron de manera aleatoria volteo horizontal; alejamiento-acercamiento, en un rango de 0.9 a 1.2; rotación aleatoria de ± 20 grados; traslación horizontal y vertical, con un factor de 0.2; y cambio de brillo en un rango de 0.80 a 1.05.

Para la parte del entrenamiento, se utilizaron los siguientes hiperparámetros: optimizador Adam; tasa de aprendizaje de 5×10^{-4} ; 100 épocas; categorical cross-entropy como función de costo; penalización para el desbalance de las clases, calculado con la función compute class weight de scikit-learn; y tamaño de lote de 32.

5.2. Resultados de clasificación

Una vez entrenado el modelo de CNN, se obtuvieron las predicciones para el conjunto de prueba y se generó la matriz de confusión normalizada, para las 4 clases (Figura 3). De la matriz de confusión (Figura 3), se calcularon las métricas de desempeño mostradas en la Tabla 2.

En la Tabla 2, se puede observar que en la métrica de sensibilidad, el modelo es capaz de clasificar de una manera más efectiva los ejemplos de tuberculosis, con un valor de 0.8765; en segundo lugar, la neumonía, con un valor de 0.8460; seguido de los pacientes normales, con un valor de 0.8297; y finalmente, los pacientes con COVID-19 con 0.8144.

Sin embargo, al calcular TPR y FPR a diferentes umbrales, los valores de AUC son bastantes altos, con un valor de 0.9687 para tuberculosis; 0.9786 para COVID-19; 0.9601 para neumonía; y finalmente, 0.9518 para la clase normal. En la Figura 4, se puede observar un ejemplo de clasificación utilizando XDApp.

6. Conclusiones y trabajo a futuro

Se ha entrenado un modelo de red neuronal convolucional para la clasificación de radiografías de múltiples enfermedades. En concreto, se logró clasificar neumonía, tuberculosis, COVID-19 y pacientes sanos, usando el modelo NanoChest-Net con sensibilidades de 84.60 %, 87.65 %, 81.44 % y 82.97 %. A su vez, por ser un modelo con parámetros reducidos, permite utilizarlo dentro de una aplicación para dispositivos móviles que no necesariamente necesitan ser de gama alta.

La implementación de un modelo de clasificación en XDApp, permite tener un evaluador de radiografías móvil, que puede ser utilizado para consultar prediagnósticos, en situaciones donde no exista un médico radiólogo especialista. De la misma manera, XDApp puede ser utilizada como una herramienta para la enseñanza educativa en ciencias de la salud, donde el estudiante tenga dudas al observar una radiografía.

Es importante mencionar, que una de las desventajas que tiene el uso de la cámara para adquirir fotografías de radiografías se debe de hacer en un ambiente con iluminación controlada para evitar que los reflejos y efectos de luz, alteren el resultado de clasificación.

Como parte del trabajo futuro, es importante considerar ampliar el número de enfermedades que el modelo puede clasificar. Además, este tipo de aplicaciones podría ser implementado de manera remota en un servidor para ser accesible por medio de una computadora con acceso a internet e incluir envío de notificaciones con las imágenes y predicciones a los médicos encargados de realizar el diagnóstico.

Agradecimientos. Agradecemos al Instituto Politécnico Nacional por su apoyo para la realización de este trabajo; de igual manera, al apoyo del gobierno mexicano a través del Consejo Nacional de Ciencia y Tecnología (CONACYT).

Referencias

1. Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., Levenberg, J., et al.: TensorFlow: Large-scale machine learning on heterogeneous systems (2015) doi: 10.48550/ARXIV.1603.04467
2. Anderson, K., Burford, O., Emmerton, L.: Mobile health apps to facilitate self-care: A qualitative study of user experiences. *PLOS ONE*, vol. 11, no. 5, pp. e0156164 (2016) doi: 10.1371/journal.pone.0156164
3. Atkinson, R. B., Sidey-Gibbons, C., Smink, D. S., Askari, R., Pusic, A. L., Cho, N. L., Robertson, J. M., Rangel, E. L.: Real-time student feedback on the surgical learning environment: Use of a mobile application. *Journal of Surgical Education*, vol. 80, pp. 817–825 (2023) doi: 10.1016/j.jsurg.2023.02.017
4. Cohen, J. P., Morrison, P., Dao, L.: COVID-19 image data collection (2020) doi: 10.48550/ARXIV.2003.11597
5. El-Shafai, W., El-Nabi, S. A., M. El-Rabaie, E. S. M., Ali, A. M., Soliman, N. F., Algarni, A. D., El-Samie, F. E. A.: Efficient deep-learning-based autoencoder denoising approach for medical image diagnosis. *Computers, Materials & Continua*, vol. 70, no. 3, pp. 6107–6125 (2022) doi: 10.32604/cmc.2022.020698
6. Fawcett, T.: An introduction to ROC analysis. *Pattern Recognition Letters*, vol. 27, no. 8, pp. 861–874 (2006) doi: 10.1016/j.patrec.2005.10.010
7. Gavrysh, V.: Pneumothorax binary classification task (2021) <https://www.kaggle.com/datasets/volodymyrgavrysh/pneumothorax-binary-classification-task>
8. Jaeger, S., Candemir, S., Antani, S., Wáng, Y. X. J., Lu, P. X., Thoma, G.: Two public chest X-ray datasets for computer-aided screening of pulmonary diseases. *Quant Imaging in Medicine and Surgery*, vol. 4, no. 6, pp. 475–477 (2014) doi: 10.3978/j.issn.2223-4292.2014.11.20
9. Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X., Yan, F., Dong, J., Prasadha, M. K., Pei, J., Ting, M., Zhu, J., Li, C., Hewett, S., Dong, J., Ziyar, I., Shi, A., et al.: Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, vol. 172, no. 5, pp. 1122–1131.e9 (2018) doi: 10.1016/j.cell.2018.02.010
10. Lucero-Mueses, J. E., Álzate-Mejía, O. A.: Aplicaciones móviles para el estudio de la anatomía humana. *International Journal of Morphology*, vol. 38, no. 5, pp. 1365–1370 (2020) doi: 10.4067/s0717-95022020000501365
11. Luján-García, J. E., Villuendas-Rey, Y., López-Yáñez, I., Camacho-Nieto, O., Yáñez-Márquez, C.: Nanochest-net: A simple convolutional network for radiological studies classification. *Diagnostics*, vol. 11, no. 5, pp. 775 (2021) doi: 10.3390/diagnostics11050775
12. OMS: Neumonía infantil (2022) who.int/es/news-room/fact-sheets/detail/pneumonia
13. OMS: Tuberculosis (2023) who.int/es/news-room/fact-sheets/detail/tuberculosis
14. PAHO: La neumonía es la causa principal de muerte de niños (2011) paho.org/es/noticias/11-11-2011-neumonia-es-causa-principal-muerte-ninos
15. PAHO: Brote de enfermedad por el Coronavirus COVID-19 (2023) paho.org/es/temas/coronavirus/brote-enfermedad-por-coronavirus-covid-19
16. Pasa, F., Golkov, V., Pfeiffer, F., Cremers, D., Pfeiffer, D.: Efficient deep network architectures for fast chest X-Ray tuberculosis screening and visualization. *Scientific Reports*, vol. 9, no. 1, pp. 6268–6268 (2019) doi: 10.1038/s41598-019-42557-4
17. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E.: Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830 (2011) doi: 10.48550/ARXIV.1201.0490

18. Polsinelli, M., Cinque, L., Placidi, G.: A light CNN for detecting COVID-19 from CT scans of the chest. *Pattern Recognition Letters*, vol. 140, pp. 95–100 (2020) doi: 10.1016/j.patrec.2020.10.001
19. Siddiqi, R.: Efficient pediatric pneumonia diagnosis using depthwise separable convolutions. *Computer Science*, vol. 1, no. 6, pp. 343–343 (2020) doi: 10.1007/s42979-020-00361-2
20. Suetens, P.: *Fundamentals of medical imaging*. Second edition (2009)
21. Sutton, D.: *Textbook of radiology and imaging* (2003)
22. Varadarajan, V., Shabani, M., Ambale-Venkatesh, B., Lima, J. A. C.: Role of imaging in diagnosis and management of COVID-19: A multiorgan multimodality imaging review. *Frontiers in Medicine*, vol. 8 (2021) doi: 10.3389/fmed.2021.765975
23. Vialart-Vidal, M. N., Vidal-Ledo, M. J., Sarduy-Domínguez, Y., Delgado-Ramos, A., Rodríguez-Díaz, A., Fleitas-Estévez, I., Muñoz-Morejón, M., Gavilondo-Mariño, X., Pérez-Matar, R.: Aplicación de la eSalud en el contexto cubano. *Revista Panamericana de Salud Pública*, pp. 1–9 (2018) doi: 10.26633/RPSP.2018.19
24. Weigandt, W. A., Schardt, Y., Bruch, A., Herr, R., Goebeler, M., Benecke, J., Schmieder, A.: Impact of aneHealth smartphone app on quality of life and clinical outcome of patients with hand and foot eczema: Prospective randomized controlled intervention study. *Journal of Medical Internet Research mHealth and uHealth*, vol. 11, pp. e38506 (2023) doi: 10.2196/38506
25. Yacin-Sikkandar, M. Y., Sabarunisha-Begum, S., Alkathiry, A. A., Alotaibi, M. S. N., Manzar, M. D.: Automatic detection and classification of human knee osteoarthritis using convolutional neural networks. *Computers, Materials and Continua*, vol. 70, no. 3, pp. 4279–4291 (2022) doi: 10.32604/cmc.2022.020571