

Implementación de una Red Neuronal Convolutiva para Distinguir entre Patrones Radiológicos de COVID-19 y Neumonía en Imágenes Tomográficas de Tórax

Carlos Jesús Rivero López¹

212T0027@itsm.edu.mx

<https://orcid.org/0009-0000-0034-7723>

Tecnológico Nacional de México Campus
Instituto Tecnológico Superior de Misantla
México

José Guzmán Irahan Otoniel

iojoseg@itsm.edu.mx

<https://orcid.org/0000-0001-5336-0198>

Tecnológico Nacional de México Campus:
Instituto Tecnológico Superior de Misantla
País México

Galdino Martínez Flores

gmartinezf@itsm.edu.mx

<https://orcid.org/0000-0003-4981-8631>

Tecnológico Nacional de México Campus:
Instituto Tecnológico Superior de Misantla
México

Isaías Avendaño Cortes

iavendanoc@huatusco.tecnm.mx

<https://orcid.org/0000-0002-8873-0600>

Tecnológico Nacional de México Campus:
Instituto Tecnológico Superior de Huatusco
México

RESUMEN

En el año 2020, la Organización Mundial de la Salud (OMS) proclamó la existencia de una pandemia originada por el coronavirus (COVID-19), cuyo brote inicial tuvo lugar en Wuhan, China. Este virus ha tenido un impacto devastador, cobrando la vida de miles y afectando a millones en todo el mundo. Sus síntomas, que incluyen tos, fiebre, fatiga y disnea, se asemejan a los de una gripe común. La propagación del virus ocurre principalmente a través de partículas respiratorias emitidas por personas infectadas, las cuales pueden depositarse en los ojos, boca o nariz de otras personas. Para confirmar la infección, se utilizan dos tipos de pruebas: la prueba de reacción en cadena de la polimerasa con transcripción inversa (RT-PCR) y las pruebas de antígenos. Sin embargo, debido a sus procesamientos, estas pruebas pueden demorar en proporcionar resultados definitivos. Es en este contexto que la inteligencia artificial y las técnicas de Machine Learning (ML) se presentan como herramientas valiosas para mejorar la detección del virus en los pulmones de manera eficiente. En este trabajo, se propone la implementación de una Red Neuronal Convolutiva (CNN) para la detección temprana de pacientes con COVID-19. Se utiliza un conjunto de datos compuesto por 3616 imágenes de rayos X de tórax, empleando una red neuronal preentrenada denominada VGG16. A través del entrenamiento, se logra una precisión óptima en la clasificación de las imágenes en las categorías de COVID y Neumonía.

Palabras clave: procesamiento de imágenes; toma de decisiones; análisis multivariable

¹ Autor principal

Correspondencia: 212T0027@itsm.edu.mx

Implementation of a Convolutional Neural Network to Distinguish between Radiological Patterns of COVID-19 and Pneumonia in Chest CT Images

ABSTRACT

In 2020, the World Health Organization (WHO) proclaimed the existence of a pandemic originating from the coronavirus (COVID-19), the initial outbreak of which occurred in Wuhan, China. This virus has had a devastating impact, claiming the lives of thousands and affecting millions worldwide. Its symptoms, which include cough, fever, fatigue and dyspnea, resemble those of a common flu. Spread of the virus occurs primarily through respiratory particles emitted by infected people, which can be deposited in the eyes, mouth or nose of others. Two types of tests are used to confirm infection: reverse transcription-polymerase chain reaction (RT-PCR) and antigen testing. However, due to their processing, these tests can take time to provide definitive results. It is in this context that artificial intelligence and Machine Learning (ML) techniques are presented as valuable tools to improve virus detection in lungs in an efficient way. In this work, the implementation of a Convolutional Neural Network (CNN) for the early detection of patients with COVID-19 is proposed. A dataset composed of 3616 chest X-ray images is used, employing a pre-trained neural network named VGG16. Through training, optimal accuracy in classifying images into COVID and Pneumonia categories is achieved.

Keywords: Image processing; decision making, multivariable analysis

Artículo recibido 25 noviembre 2023

Aceptado para publicación: 30 diciembre 2023

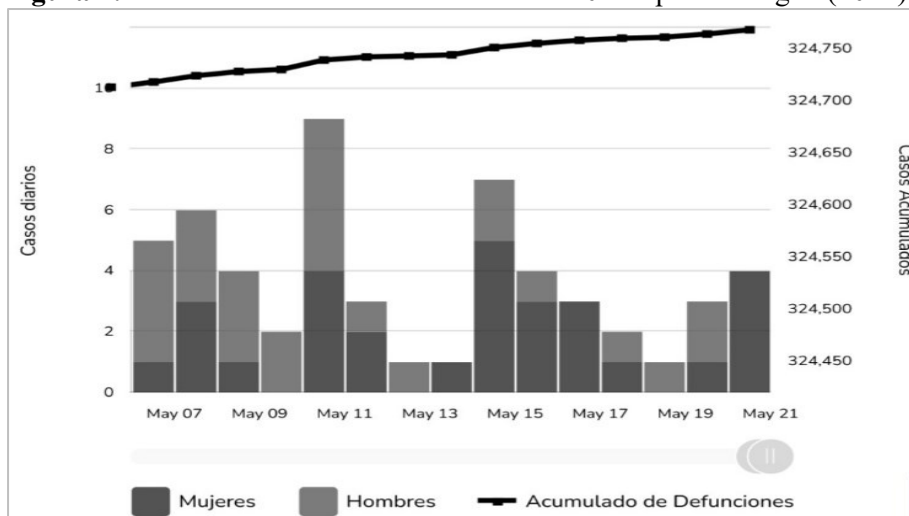
INTRODUCCIÓN

La prevalencia de la fase epidémica del actual virus presente en nuestra sociedad llamado COVID-19, hace que prácticamente cualquier opacidad pulmonar en una radiografía de tórax se pueda interpretar por una neumonía por SARS-CoV-2, sin embargo algunas características clínicas distintas entre pacientes enfermos con Covid y los que sufren de una neumonía común, han sugerido que la respuesta inmune al virus en la concavidad situada al final de los bronquios el cual es infectado, difiere de otros tipos de neumonía. Investigadores de la Northwestern Medicine University (Grant et al., 2021) recogieron muestras de líquido de lavado broncoalveolar de 88 pacientes con insuficiencia respiratoria inducida por SARS-CoV-2 y en 211 casos con sospecha neumonía de otros patógenos como lo son bacterias y hongos dentro de las 48 horas posteriores a la intubación. Los síntomas comunes de COVID-19 incluye fiebre, tos seca, dolores musculares, dolor de garganta, fatiga, anosmia e hipogeusia. A comparación de una neumonía los cuales los pacientes pueden experimentar disnea, agitación, confusión o inclusive conjuntivitis (Marín, 2021). Cuando se tiene en cuenta el amplia visión de manifestaciones clínicas y la creciente carga mundial del virus COVID-19, es importante y necesario aumentar la capacidad de diagnóstico del personal médico alrededor del mundo. Actualmente las técnicas de Inteligencia Artificial han brindado una variedad de soluciones a distintos problemas dentro de diferentes sectores de la sociedad, los cuales en los último par de años el sector medico a padecido de una pandemia originada por el virus SARS-CoV-2 que tiene múltiples secuelas o daño en los pulmones que conllevan a enfermedades tales desde un resfriado común hasta enfermedades respiratorias más graves y agudas, su primera aparición fue en Wuhan China en diciembre del 2020 (Zhu, 2020) , posteriormente se extendió por el mundo declarándola como pandemia global por la Organización Mundial de la Salud (Gorbalenya, 2020). El virus que anteriormente no se había detectado en personas, puede transmitirse a través de gotas que se expulsan mediante la tos, los estornudos o al hablar durante un tiempo prolongado, estas gotas son inhaladas o pueden caer en una superficie en la que las personas puedan tener contacto con ella y al entrar en contacto con la boca, nariz u ojos pueden contaminarse. Actualmente la gente ha sido infectada en todas las partes del mundo cobrándose muchas vidas (Figura 1)

La pandemia de coronavirus ha producido miles de víctimas y ha afectado a millones de personas en todo el mundo. Cualquier dispositivo tecnológico que permita la detección acelerada de la infección por COVID-19 con alta precisión puede ser de gran ayuda para los profesionales de la salud. Según Chowdhury et al. (2020), las imágenes de rayos X son una herramienta de fácil acceso que se utiliza para diagnosticar casos de COVID-19. Sin embargo, aunque las imágenes regulares de rayos X de tórax (XCR) pueden mejorar la detección temprana de casos sospechosos, las imágenes de varios casos virales de neumonía son similares. Por lo tanto, es difícil para los radiólogos distinguir el COVID-19 de otros casos virales de neumonía. Esta base de datos y la investigación en curso se realizan para investigar la utilidad de la inteligencia artificial (IA) en la detección rápida y precisa de COVID-19 a partir de imágenes de rayos X de tórax.

Al día de hoy, existen muchas complicaciones biomédicas de la salud (p. ej., detección de cáncer de mama, detección de tumores cerebrales, etc.) las cuales aprovechan de soluciones que tienen con base la Inteligencia Artificial (Chowdhury et al., 2019a)

Figura 1: Estadísticas de Defunción México 2022 Epidemiología (2022)



(Chowdhury et al., 2019b) (Kallianos et al., 2019). Al hacer uso de técnicas de Machine Learning (ML), se pueden detectar rasgos de la imagen que no pueden ser apreciables en imágenes originales, centrándonos en una técnica de aprendizaje supervisado como lo es una Red Neuronal Convolutiva (CNN), la cual nos permite en el sector médico poder analizar radiografías de tórax, y poder revelar aspectos de la imagen que no son visibles en las imágenes originales. Se ha demostrado que una Red Neuronal Convolutiva es beneficiosa en la extracción y en el aprendizaje de características, por lo

cual su popularidad dentro del campo de la investigación (Krizhevsky, 2012), Las técnicas de aprendizaje profundo dentro de las radiografías de tórax han sido de gran ayuda, ya que en diferentes aplicaciones los resultados de la misma han sido prometedores, dentro de la CNN desarrolla en lenguaje de programación Python ocupando la librería Keras y una red pre-entrenada cómo es el modelo VGG16, la cual nos ayuda a que sea una arquitectura fácil de entender y de implementar, entre el 96% y 97% logró obtener en la competencia de ImageNet (Russakovsky et al., 2015), ya que su arquitectura se construye de 13 capas convolucionales y 3 densas, existen redes disponibles en la librería de Keras cómo lo son; Xception, InceptionV3, ResNet50, VGG16, VGG19 y MobileNet, la actual arquitectura puede compararse con el modelo VGG19 la cual es una variante con más capas de cálculo que la VGG16, pero una de sus desventajas es que es más pesada a la hora de almacenar memoria y en cuestión de requerimientos en el procesamiento del cómputo. Al usar la arquitectura VGG16 preentrenada con la base de datos de ImageNet, nos permite que a la hora de poder extraer rasgos, codifica de una manera efectiva las relaciones que hacen a los objetos distinguibles, y poder clasificar rasgos distintivos entre las enfermedades pulmonares.

Este artículo presenta un estudio de clase de implementación de una CNN para poder identificar y posteriormente clasificar dependiendo el daño en los pulmones, en diferentes clases cómo lo son: COVID y NEUMONIA, considerando imágenes de radiografías de tórax (CXR) obtenidas de la plataforma Kaggle, el cual es un conjunto de datos de investigación abierta, que lleva por nombre COVID-19 Radiography Database, la cual cada imagen fue preprocesada para sacar el mejor conjunto de características que nos permitan identificar las enfermedades previamente mencionadas, a su vez se aplica un algoritmo de aumento de datos que permita evitar un sobre ajuste en la base de datos e incrementar con datos sintéticos el tamaño de la muestra en el entrenamiento. El presente trabajo incluye:

1. Una implementación de una arquitectura de una Red Neuronal Convolutiva para la detección de pacientes que tengan el virus COVID-19, comparando las características con neumonía, implementando un dataset de imágenes de rayos X del tórax. La cual son nuestros datos de entrada para posteriormente extraer las características más importantes con las capas de convolución, esto con la ayuda de una arquitectura VGG16 preentrenado de Keras, para finalmente clasificar en

dos clases distintas COVID y NEUMONIA.

2. Una implementación en una página web con Flask el cual es una herramienta escrita en Python, el cual es un microframework ya que no requiere librerías en particular y tampoco tiene capas de abstracción de base de datos, y puede verse de una manera sencilla y clara a la hora de cargar una imagen y ver la predicción de la CNN.
3. Opción de poder reentrenar la CNN y poder guardar nuevos modelos cada que se requiera y poder visualizarlo nuevamente en la página web.

METODOLOGÍA

El objetivo del estudio consiste en entrenar una red convolucional con imágenes de radiografías de tres tipos de pacientes: sin ninguna afección pulmonar (Normales), que presentan síntomas de COVID-19 y personas con síntomas de neumonía no relacionados con dicho virus.


Conjunto de datos de neumonía y SARS-CoV2

Actualmente los sistemas de Machine Learning y Deep Learning necesitan aprender de datos, en este caso imágenes, que reflejen lo que después tendrán que detectar automáticamente. En concreto, para el desarrollo del modelo de clasificación de radiografías, contamos con la siguiente información:

El conjunto de datos que se utilizó para el presente trabajo de investigación se obtuvieron de [6] donde un equipo de investigadores de la Universidad de Qatar, Doha y la Universidad de Dhaka, Bangladesh en colaboración de Pakistán y Malasia, junto con médicos especializados, crearon una base de datos de imágenes de Rayos X de tórax para casos positivos de SARS-CoV2, que a su vez tiene conjunto de imágenes de neumonía normal, el cual ambas se ocuparán para poder clasificar dichas enfermedades con técnicas de Machine Learning, el cual dicho dataset de imágenes estuvo dividido en etapas, en la primera, se publicaron 219 imágenes de radiografía de tórax (Figura 2) (CXR) del virus COVID-10, 1341 normales y 1345 de neumonía viral. En la segunda etapa se actualizaron los conjuntos a 1200 imágenes CXR, y por último se aumentaron para tener un total de 10192 imágenes de CXR y 6012 de opacidad pulmonar (Infección pulmonar no COVID) y 1345 de neumonía viral.

Se ocupó un aprendizaje supervisado para etiquetar, clasificar dichas imágenes y así poder entrenar una Red Neuronal Convolucional (CNN) la clasificación serán 2 etiqueta

Figura 2: SARS-Cov2, neumonía

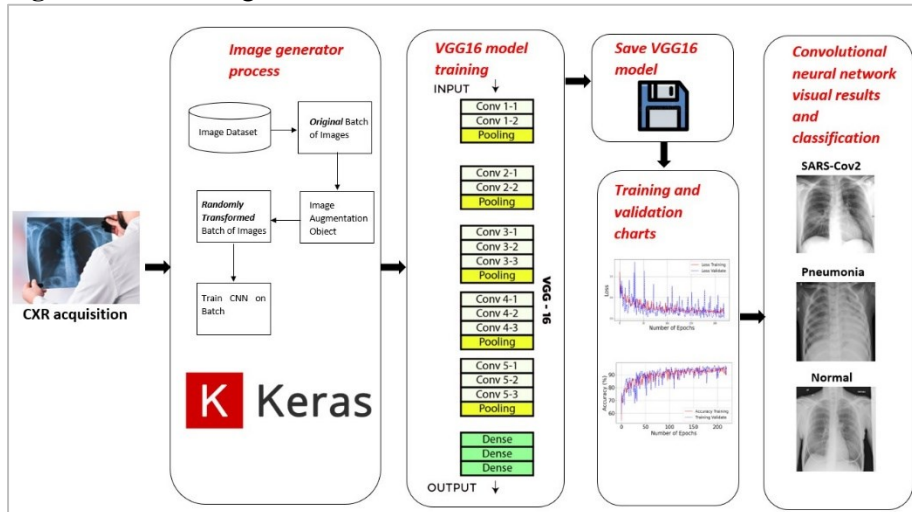


Modelo de clasificación de radiografías de COVID-19

La implementación de algoritmos de soporte de decisiones clínicas para imágenes médicas enfrenta desafíos con confiabilidad e interpretabilidad. Aquí, establecemos una herramienta de diagnóstico basada en un marco de aprendizaje profundo para la detección de pacientes con infección por el virus SARS-CoV2 y neumonía. Nuestro marco utiliza el aprendizaje por transferencia, que entrena una red neuronal convolucional con base dataset previamente mencionado. Al aplicar este enfoque a un conjunto de datos de imágenes CXR y neumonía, se demuestra un rendimiento comparable al de los expertos humanos en la clasificación de dichas enfermedades. También se proporciona un diagnóstico más transparente e interpretable al resaltar las regiones reconocidas por la red neuronal. Además, se puede demostrar la aplicabilidad general de nuestro sistema de IA para el diagnóstico mediante imágenes de rayos X de tórax. En última instancia, esta herramienta puede ayudar a acelerar el diagnóstico y la interpretación de estas afecciones tratables, lo que facilita un tratamiento más temprano y mejora los resultados clínicos.

El desarrollo de capas de redes neuronales convolucionales ha permitido avances significativos en la capacidad de clasificar imágenes y detectar objetos en una imagen [7]. Estas son múltiples capas de procesamiento a las que se aplican filtros de análisis de imágenes o convoluciones. La representación abstracta de imágenes dentro de cada capa se construye mediante la convolución sistemática de varios filtros en la imagen, lo que produce un mapa de características que se utiliza como entrada para la siguiente capa. Esta arquitectura permite procesar imágenes en forma de píxeles como entrada y dar la clasificación deseada como salida. El enfoque de imagen a clasificación en un clasificador reemplaza los múltiples pasos de los métodos de análisis de imágenes anteriores (Figura 3).

Figura 3: Metodología



Proceso de generación de imágenes

Para poder entrenar de manera eficiente nuestra Red Neuronal Convolutiva, el aumento de datos de las imágenes es una técnica que se puede utilizar para expandir artificialmente el tamaño de un conjunto de datos, imágenes, esto mediante la creación de variaciones precisamente de las imágenes a procesar. La ventaja de poder ocupar esta técnica es la obtención de modelos más eficientes y un resultado acorde a lo aprendido en las nuevas imágenes generadas.

Keras es una biblioteca orientada a las redes neuronales de aprendizaje profundo (Deep Learning) el cual nos permite ajustar modelos mediante el aumento de datos de imágenes a través del ImageDataGenerator.

Se define un método para generar imágenes para entrenamiento (Train) y para el apartado de validación (Valid) donde en dicho método se ocuparán variables específicas para el aumento de datos como lo son:

Train & Valid: Un rango de rotación que permita mover la imagen 20 grados cada iteración, al igual que un rango de zoom del 0,2 el cual se configura como si fuera una fracción donde el valor total es 1, en el cual la imagen permanece sin ese zoom, con dicha medida establecida hace un aumento del 20% a la imagen que está siendo procesada, a su vez asignaremos un rango de desplazamiento el cual en el presente trabajo de investigación pondremos valores 0.1 ya que equivale a un mismo movimiento del 10%, dentro de los atributos está la opción de hacer un efecto espejo en la imagen la cual

activaremos, caso contrario del efecto que pone de cabeza la imagen el cual permanecerá desactivado (Figura 4).

Figura 4: ImageDataGenerator.

```

train_datagen = ImageDataGenerator(
    rotation_range=20,
    zoom_range=0.2,
    width_shift_range=0.1,
    height_shift_range=0.1,
    horizontal_flip=True,
    vertical_flip=False,
    preprocessing_function=preprocess_input)
valid_datagen = ImageDataGenerator(
    rotation_range=20,
    zoom_range=0.2,
    width_shift_range=0.1,
    height_shift_range=0.1,
    horizontal_flip=True,
    vertical_flip=False,
    preprocessing_function=preprocess_input)


```

Modelo VGG16 para CNN.

Simonyan and Zisserman (2014) con el artículo que lleva por nombre Very Deep Convolutional Networks for Large-Scale Image Recognition propusieron un modelo de Red Neuronal Convolutacional, dicho modelo logra tener una precisión de prueba del 92.7% quedando entre los cinco primero en ImageNet Krizhevsky (2012), el cual es un conjunto de datos de aproximadamente 14 millones de imágenes el cual se clasifican en 1000 clases distintas. Dicho modelo fue uno de los más famosos presentados a ILSVRC-2014 Russakovsky et al. (2015) el cual se puede notar una mejora respecto a AlexNet al sustituir filtros grandes del tamaño del kernel (11 y 5 en la primera y segunda capa convolutacional) con múltiples filtros del tamaño del kernel 3x3 uno tras otro. El modelo VGG16 ocupó una GPU NVIDIA Titan Black.

Se muestra la arquitectura VGG16 (Figura 4) la cual la entrada a la primera capa de convolución es imagen de 224 x 224. Dicha figura pasa a través de un conjunto de capas convolucionales (conv), donde los filtros se ocuparon con un campo receptivo de una tamaño pequeño: 3 x 3 el cual permite capturar la noción de arriba/abajo, izquierda/derecha y el centro.

Figura 5: Arquitectura VGG16.



RESULTADOS Y DISCUSIÓN

En este trabajo de investigación se ha estudiado el modelo preentrenado de Keras que tiene por nombre VGG16, dicha arquitectura tiene como objetivo tener una clasificación óptima para poder asignar etiquetas a tomografías del virus SARS-CoV2 y neumonía, con la ayuda de una técnica de Machine Learning como lo son las Redes Neuronales Convolucionales (CNN).

Comparando un sistema automático capaz de poder analizar una imagen de rayos X de tórax de un paciente enfermo por el virus SARS-Cov2, a diferencia de la prueba tradicional PCR, dicho sistema puede tener una respuesta en cuestión de segundos, acerca de la situación en la que se pueda encontrar el paciente. Ya que al ser programado con una Red Neuronal Convolutiva, nos da la ventaja de que dichas capas tienen un orden el cual se va procesando la imagen CXR, las capas más utilizadas son: (i) capas convolucionales, los cuales tienen n filtros dedicados a generar n mapas de características. (ii) Capas de submuestreo, el cual cada mapa de características se submuestra por lo general mediante una operación de agrupación con base al valor máximo, le cual lleva por nombre Max Pooling, el cual auxilia a poder reducir progresivamente el tamaño espacial de la representación y la cantidad de parametros a entrenar. (iii) Capas densas, las cuales son capas con neuronas respectivamente conectadas. En la Figura 6 se puede mostrar cómo está compuesta la arquitectura propuesta por (Simonyan and Zisserman, 2014) la cual en la primera columna se muestra el número de capa y el tipo de operación, la segunda columna indica la cantidad de mapas de características. Por último tenemos el tamaño, que indica el número de características de salida de cada una de las capas, el propósito de usar dicho modelo es clasificar la imagen de entrada en una de varias clases según el conjunto de datos de entrenamiento.

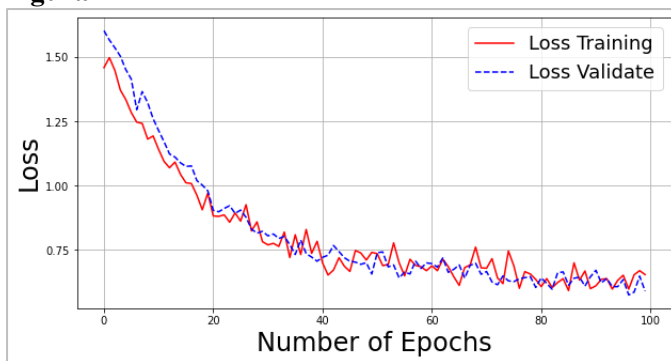
Figura 6: Modelo VGG16

Capa		Mapa de Característica	Tamaño
Entrada	Imagen	1	$224 \times 224 \times 3$
1	2 × Conv	64	$224 \times 224 \times 64$
	Agr. Max.	64	$112 \times 112 \times 64$
3	2 × Conv	128	$112 \times 112 \times 128$
	Agr. Max.	128	$56 \times 56 \times 128$
5	2 × Conv	256	$56 \times 56 \times 256$
	Agr. Max.	256	$28 \times 28 \times 256$
7	3 × Conv	512	$28 \times 28 \times 512$
	Agr. Max.	512	$14 \times 14 \times 512$
10	3 × Conv	512	$14 \times 14 \times 512$
	Agr. Max.	512	$7 \times 7 \times 512$
13	FC	-	25088
14	FC	-	4096
15	FC	-	4096
Salida	FC	-	1000

El sistema se implementó en Python, usando la librería Flask para poder visualizar los datos de una mejor manera usando un servidor web, en una computadora con un procesador Ryzen 7 serie 4000 con una memoria de 16 GB DDR4, y un sistema operativo Windows 10 Pro, con una tarjeta gráfica NVIDIA 2060 RTX.

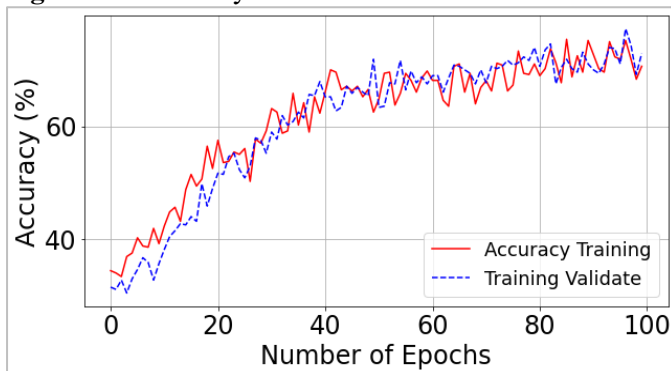
En la figura 7, se muestra una de las dos gráficas obtenidas de los resultados de entrenamiento y validación, la cual son métricas utilizadas para poder evaluar como un modelo se ajusta a los datos de entrenamiento, dicho de otra manera puede evaluar el error del modelo sobre el conjunto de entrenamiento. Se ocuparon 100 épocas para poder entrenar el modelo, esto nos informa si necesita ajustes o no, el cual al principio se puede observar como la perdida de entrenamiento (Loss Training) y la perdida de evaluación (Loss Validate) disminuyen y se empiezan a estabilizar conforme avanzan las épocas

Figura 7: Loss Plot.



En la figura 8, se puede observar la precisión que tiene el modelo y como se va ajustando conforme pasan las épocas, el cual al principio no está estabilizado pero conforme va procesando las imágenes se observa una mejora en la precisión del modelo en la época 100.

Figura 8: Accuracy Plot.



CONCLUSIONES

El sistema automático desarrollado, capaz de analizar imágenes de rayos X de tórax de pacientes afectados por el virus SARS-CoV-2, presenta la ventaja de proporcionar respuestas en cuestión de segundos, a diferencia de las pruebas PCR que pueden ser más prolongadas. La utilización de una Red Neuronal Convolutiva aprovecha la estructura ordenada de sus capas, resaltando las capas convolucionales, las capas de submuestreo mediante Max Pooling para reducir el tamaño espacial de la representación, y las capas densas con neuronas conectadas respectivamente. Estos elementos permiten un procesamiento eficiente de las imágenes CXR, contribuyendo de manera significativa a la detección rápida y precisa de la condición del paciente.

En conclusión, este enfoque representa un avance prometedor en la detección temprana de infecciones por SARS-CoV-2, al proporcionar una herramienta ágil y efectiva que tiene el potencial de mejorar significativamente la rapidez y eficiencia en el diagnóstico. Las implicaciones positivas de este enfoque se reflejan en el manejo clínico de la enfermedad, ofreciendo una contribución valiosa al contexto de la atención médica actual.

REFERENCIAS BIBLIOGRAFICAS

- Boone, J. M., Seshagiri, S., and Steiner, R. M. (1992). Recognition of chest radiograph orientation for picture archiving and communications systems display using neural networks. *Journal of Digital Imaging*, 5(3):190–193.
- Chowdhury, M. E., Alzoubi, K., Khandakar, A., Khallifa, R., Abouhasera, R., Koubaa, S., Ahmed, R., and Hasan, A. (2019a). Wearable real-time heart attack detection and warning system to reduce road accidents. *Sensors*, 19(12):2780.
- Chowdhury, M. E., Khandakar, A., Alzoubi, K., Mansoor, S., M Tahir, A., Reaz, M. B. I., and Al-Emadi, N. (2019b). Real-time smart-digital stethoscope system for heart diseases monitoring. *Sensors*, 19(12):2781.
- Epidemiologia, D. G. (2022). COVID-19 Tablero México.
- Gorbalenya, Alexander E y Baker, S. C. y. B. R. y. G. R. J. d. y. D. C. y. G. A. A. y. H. B. L. y. L. C. y. L. A. M. y. N. B. W. y. o. (2020). Coronavirus relacionado con el síndrome respiratorio agudo severo: la especie y sus virus: una declaración del grupo de estudio de coronavirus.

- Gozes, O., Frid-Adar, M., Greenspan, H., Browning, P. D., Zhang, H., Ji, W., Bernheim, A., and Siegel, E. (2020). Rapid ai development cycle for the coronavirus (covid-19) pandemic: Initial results for automated detection & patient monitoring using deep learning ct image analysis. arXiv preprint arXiv:2003.05037.
- Grant, R. A., Morales-Nebreda, L., Markov, N. S., Swaminathan, S., Querrey, M., Guzman, E. R., Abbott, D. A., Donnelly, H. K., Donayre, A., Goldberg, I. A., et al. (2021). Circuits between infected macrophages and t cells in sars-cov-2 pneumonia. *Nature*, 590(7847):635–641.
- Kallianos, K., Mongan, J., Antani, S., Henry, T., Taylor, A., Abuya, J., and Kohli, M. (2019). How far have we come? artificial intelligence for chest radiograph interpretation. *Clinical radiology*, 74(5):338–345.
- Kayalibay, B., Jensen, G., and van der Smagt, P. (2017). Cnn-based segmentation of medical imaging data. arXiv preprint arXiv:1701.03056.
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X., Yan, F., et al. (2018). Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 172(5):1122–1131.
- Krizhevsky, Alex y Sutskever, I. y. H. G. E. (2012). Clasificación de imagenet con redes neuronales convolucionales profundas. *Avances en los sistemas de procesamiento de información neuronal*, 25.
- Marín, J. E. O. (2021). Sintomatología no respiratoria de covid-19. *Alerta, Revista científica del Instituto Nacional de Salud*, 4(2):61–68.
- Rajaraman, S., Candemir, S., Kim, I., Thoma, G., and Antani, S. (2018). Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. *Applied Sciences*, 8(10):1715.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., and Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)*, 115(3):211–252.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.

Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., Yu, L., Ni, Q., Chen, Y., Su, J., et al. (2020). A deep learning system to screen novel coronavirus disease 2019 pneumonia. *Engineering*, 6(10):1122–1129.

Zhang, J., Xie, Y., Pang, G., Liao, Z., Verjans, J., Li, W., Sun, Z., He, J., Li, Y., Shen, C., et al. (2020). Viral pneumonia screening on chest x-rays using confidence-aware anomaly detection. *IEEE transactions on medical imaging*, 40(3):879–890.

Zhu, Na y Zhang, D. y. W. W. y. L. X. y. Y. B. y. S. J. y. Z. X. y. H. B. y. S. W. y. L. R. y. o. (2020). Un nuevo coronavirus de pacientes con neumonía en china, 2019. *Diario de medicina de Nueva Inglaterra*.