

Clasificación de Imágenes de Neumonía a causa de Covid-19 utilizando Transfer-Learning basado en Redes Convolucionales

Classification of Images of Pneumonia Due to Covid-19 Using Transfer Learning, Based on Convolutional Networks

| | |
|--|---------------------|
| Adiel Joshua Preciado Rodríguez ^{(1) *} | 0000-0002-7570-5537 |
| Flor Mayerli Flores Guillen ⁽¹⁾ | 0000-0002-6454-4467 |
| Aldo Emanuel Soraluz Soraluz ⁽¹⁾ | 0000-0001-5285-8496 |
| Jonathan Gerhard Ríos Jara ⁽¹⁾ | 0000-0002-8407-0297 |

⁽¹⁾ Universidad Peruana Unión

* Autor para la correspondencia: adielpreciado@upeu.edu.pe

RESUMEN

La Inteligencia Artificial ha ayudado a lidiar diferentes problemas relacionados con los datos masivos y a su vez con su tratamiento, diagnóstico y detección de enfermedades como la que actualmente nos preocupa, la Covid-19. El objetivo de esta investigación ha sido analizar y desarrollar la clasificación de imágenes de neumonía a causa de covid-19 para un diagnóstico efectivo y óptimo. Se ha usado Transfer-Learning aplicando ResNet, DenseNet, Poling y Dense layer para la elaboración de los modelos de red propios Covid-UPeU y Covid-UPeU-TL, utilizando las plataformas Kaggle y Google colab, donde se realizaron 4 experimentos. El resultado con una mejor clasificación de imágenes se obtuvo en el experimento 4 prueba N°2 con el modelo Covid-UPeU-TL donde Acc.Train: 0.9664 y Acc.Test: 0.9851. Los modelos implementados han sido desarrollados con el propósito de tener una visión holística de los factores para la optimización en la clasificación de imágenes de neumonía a causa de COVID-19.

Palabras clave: covid-19; transfer-learning; reconocimiento; inteligencia artificial; pandemia; rayos x; clasificación de imágenes; pulmones; redes convolucionales.

ABSTRACT

Artificial Intelligence has helped to deal with different problems related to massive data in turn to the treatment, diagnosis and detection of diseases such as the one that currently



has us in concern, Covid-19. The objective of this research has been to analyze and develop the classification of images of pneumonia due to covid-19 for an effective and optimal diagnosis. Transfer-Learning has been used applying ResNet, DenseNet, Poling and Dense layer for the elaboration of the own network models Covid-Upeu and Covid-UpeU-TL, using Kaggle and Google colab platforms, where 4 experiments have been carried out. The result with a better classification of images was obtained in experiment 4 test N ° 2 with the Covid-UPeU-TL model where Acc.Train: 0.9664 and Acc.Test: 0.9851. The implemented models have been developed with the purpose of having a holistic view of the factors for optimization in the classification of COVID-19 images.

Keywords: COVID-19; Transfer-Learnig; Recognition; Artificial intelligence; Pandemic; X-rays; Image classification; Lungs; convolucional networks.

Recibido: 2/05/2021

Aprobado: 17/01/2022

Introducción

El 31 de diciembre de 2019 se presentaron en la ciudad de Wuhan (China) 27 casos de neumonía con causa desconocida, los cuales fueron informados a la Organización Mundial de la salud ^{(1),(2)}. El 3 de enero de 2020 China notificó a la OMS haber encontrado 44 casos de esta neumonía, de los cuales 11 personas se encontraban en gravedad y otras 33 se encontraban en una situación estable. El 12 de febrero el director general de la OMS ⁽³⁾ dio alerta de la existencia de la nueva enfermedad.

La inteligencia artificial ha mejorado los avances del desarrollo tecnológico mundial, en los últimos años ha ido evolucionando como una disciplina dedicada a la construcción de herramientas tecnológicas capaces de apoyar en el desarrollo de soluciones para casos de la medicina humana, el diagnóstico o la predicción de enfermedades, como la que actualmente nos preocupa, la pandemia mundial Covid-19, afirman Weiss ⁽⁴⁾ y Ahuja ⁽⁵⁾.

Las tareas constituyen la clave para llegar a los métodos o técnicas de la inteligencia artificial (Lógica difusa, Redes Neuronales Artificiales, Naive Bayes, Arboles de Decisión, etc), ya que la correcta codificación y resolución de problemas son de primera instancia para la toma adecuada de decisiones ^{(6),(7)}.

Asimismo según Cortés⁽⁸⁾, las técnicas de Transfer Learnig (TL) vienen avanzando con éxito en el procesamiento de imágenes, su extracción, reconocimiento y clasificación. Una de las técnicas de TL utilizadas para el análisis de imágenes es la de Redes



Neuronales Convolucionales Profundas (DCNN por sus siglas en inglés: Deep Convolutional Neural Networks), que desde mediados del siglo XX hasta el 2020 han demostrado su capacidad para resolver problemas de clasificación en imágenes, proporcionando resultados satisfactorios en una amplia gama de aplicaciones ⁽⁹⁾.

La pandemia ocasionada por la Covid-19 ha ido desencadenando efectos devastadores tanto en la economía como en la salud y en la población mundial ⁽¹⁾. El uso de la inteligencia artificial, ha permitido analizar datos masivos representados en Datasets, ayudando a la comunidad científica en la detección temprana de Covid-19, como lo afirman ^{(10), (11)}.

En esta investigación se ha desarrollado y analizado la clasificación de imágenes de neumonía para un diagnostico efectivo y óptimo entre un pulmón normal y uno con Covid-19, a través de modelos propios entrenados, haciendo uso de Transfer-Learnig e inteligencia artificial como parte de una innovación tecnológica sanitaria.

Método

Para el reconocimiento de imágenes se ha hecho uso de DCNN: un modelo de neuronas que corresponden a campos receptivos, de una manera muy similar a las neuronas de la corteza visual primaria de un cerebro biológico, mencionan Zhou ⁽¹²⁾ y Curioso ⁽¹³⁾.

Las unidades de procesamiento se han organizado en capas; una capa de entrada que representa los campos de entrada de una o varias capas ocultas; y una capa de salida, con una unidad o unidades que representa el campo o los campos de destino ⁽¹⁴⁾.

Asimismo, la función de la capa convolucional ha sido el de procesar la salida de las neuronas conectadas ⁽¹⁵⁾, las cuales han extraído características de las imágenes pulmonares, a través de un conjunto de filtros entrenables cuyos valores han sido aprendidos al encontrar ciertas características.

Se ha hecho uso de Pooling, un algoritmo utilizado para la reducción de dimensiones, con el objetivo de minimizar los tiempos de procesamiento y preservar información importante, evitando el sobreajuste y robusteciendo el modelo.

La capa totalmente conectada (Dense Layer) ha cumplido la función de clasificador, ya que ha realizado la clasificación de imágenes basada en características, las cuales han sido extraídas por las capas de convolución y la capa de agrupación (Pooling). La capa totalmente conectada es la capa de salida y representa las probabilidades de las clases o categorías en la tarea de clasificación, según Quintero ⁽¹⁵⁾.



Para el funcionamiento de este modelo se ha cumplido con las siguientes funciones de una red Convolutiva:

- Inicializar todos los pesos con valores.
- Utilizar las imágenes de entrenamiento en el modelo.
- Calcular el error total de las probabilidades resultantes.
- Propagar hacia atrás para calcular el error de la gradiente de acuerdo a los pesos obtenidos en la red.
- Utilizar la gradiente descendiente para actualizar los pesos con valores y minimizar el error de salida.

Asimismo se han recopilado imágenes de Rayos X pulmonar obtenidos de Kaggle, una plataforma web de aprendizaje automático, donde se han extraído los Dataset de “Chest X-Ray Imágenes Pneumonia”⁽¹⁶⁾ y “CoronaHack-Chest X-Ray-Dataset”⁽¹⁷⁾.

Las imágenes recopiladas han sido convertidas al formato JPEG, en un tamaño inferior a 300 píxeles, para luego ser almacenadas y separadas en carpetas de Train y Test en Google Drive; el conjunto ha estado conformado por un total de 4000 imágenes, con la finalidad de obtener un modelo óptimo y efectivo, asimismo estas imágenes han sido procesadas en Google Colab donde se encontraba alojado el modelo de red neuronal para el proceso experimental a través de entrenamientos reiterados.

Goole Colab es un entorno de máquinas virtuales en la nube basado en Jupyter Notebooks, Colab ha ido difundiendo la educación y la investigación en el aprendizaje automático afirma Boderó ⁽¹⁸⁾. Por otro lado, otorga un acceso gratuito a una GPU robusta, se ha utilizado la interfaz de administración del sistema NVIDIA (nvidia-smi) y los Megabytes de espacio y uso de GPU asignados.

Se realizaron 4 experimentos: los experimentos 1, 2 y 3 se llevaron a cabo con el modelo propio Covid-Upeu y el experimento 4 con el modelo propio Covid-UpeU-TL orientado en Densenet y Resnet; aplicando los modelos mencionados se buscó obtener la mejor clasificación de imágenes de pulmones sanos y pulmones con Covid-19.

La importancia de una correcta normalización y organización del Dataset radica en su composición ⁽¹⁹⁾, ya que ha sido la base fundamental para el análisis, detección y desarrollo del modelo de red neuronal para una correcta clasificación.



Cada autor de esta investigación ha hecho uso de computadoras portátiles para una mejor experiencia personal y una mejor comparación grupal de los resultados obtenidos.

Modelos propios

Modelo 1, Covid-UPeU fue el primer modelo en realizarse y a la vez el primero en obtener resultados basados en redes neuronales, tal como se muestra en la Figura 1.

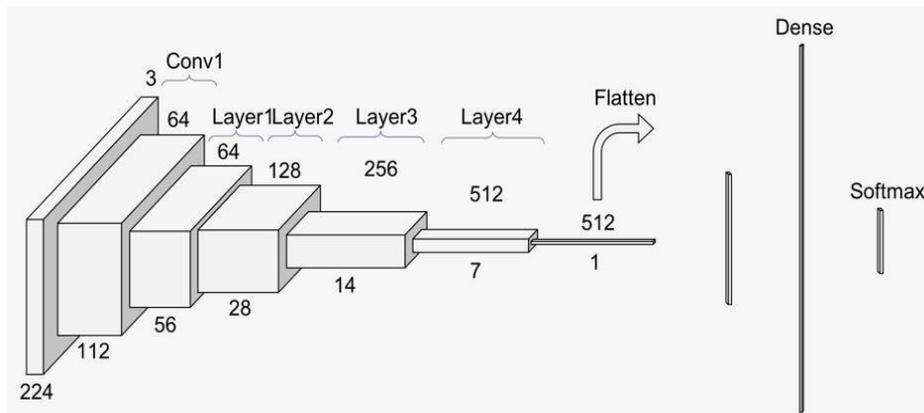


Fig.1- Modelo Covid-UPeU.

Modelo 2, Covid-UPeU-TL fue el segundo modelo en llevarse a cabo, hace uso de Transfer Learning introduciendo RESNET y DENSENET para los datos de doble o triple capa; centrado en el almacenamiento de conocimiento adquirido mientras se resuelve un problema, tal como se muestra en la Figura 2 y 3.

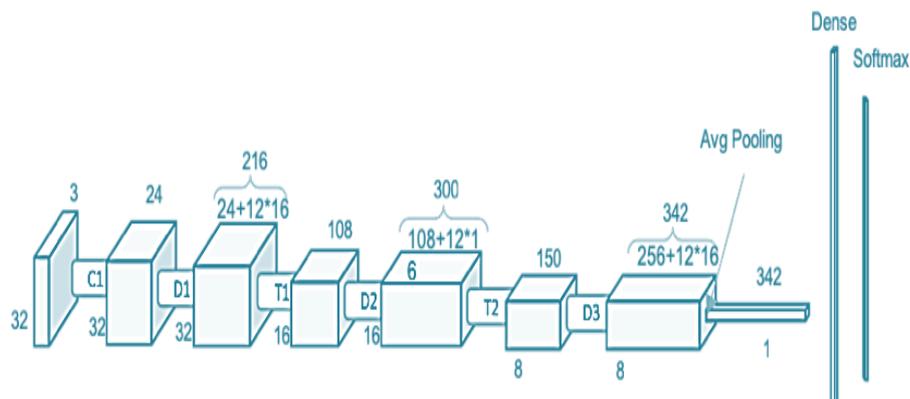


Fig.2- Modelo Covid-UPeU-TL – DENSENET



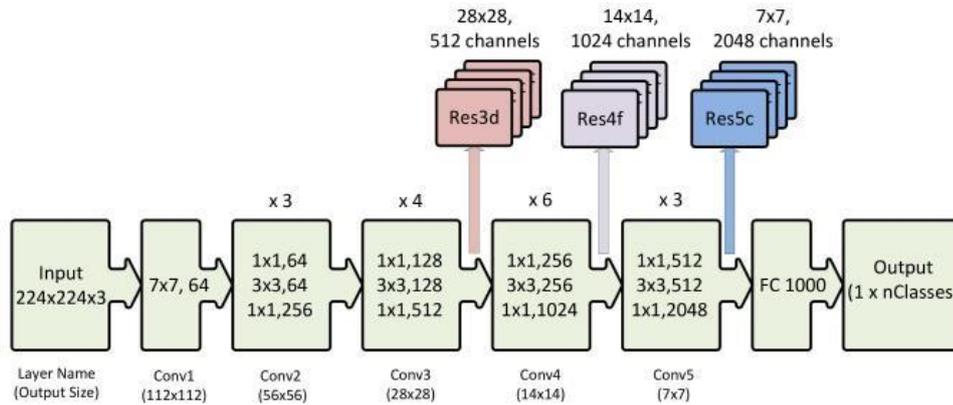


Fig.3- Modelo Covid-UPeU-TL – RESNET

Weiss⁽⁴⁾ menciona que el conocimiento adquirido ha sido útil cuando no se poseen datos suficientes para un nuevo dominio que se desea manejar a través de una red neuronal.

Resultados

Para la obtención de los resultados se decidió realizar 4 experimentos, lo cuales han estado basados en Dataset utilizados como inputs y han pasado por el proceso de normalización de transformaciones en PyTorch donde el tamaño ha sido de 224 x 224 para dar un aumento de datos, luego han pasado por la transformación de tensores y la función de transformación normalizada con valores del promedio y el estándar del conjunto de datos, dando un mejor tratamiento de los datos, asimismo se aplicaron los modelos propios Covid-UPeU y Covid-UPeU-TL (Densenet y Resnet).

Por otro lado, la selección del mejor resultado de cada experimento estuvo basado en Acc.Train y Acc.Test, donde el resultado del Acc.Train han sido imágenes que el modelo no vio y el Acc.Test han sido imágenes que el modelo clasificó, asimismo si el resultado de Acc.Train es mayor al resultado del Acc.Test el margen de error es mayor al resultado de la clasificación de imágenes por la tanto no es un resultado óptimo, sin embargo al obtener un mayor resultado en Acc.Test el entrenamiento de clasificación está dando mejores resultados, cumpliendo con el objetivo de la investigación.

En el experimento 1 se aplicó el modelo Covid-Upeu, donde se hizo uso de un total de 162 imágenes máximo y un mínimo de 148, a su vez se han clasificado las imágenes de Rayos X de pulmones sanos y pulmones con Covid-19, las cuales han sido extraídas del Dataset y ordenadas en carpetas de Google Drive para luego ser vinculadas con Google



Colab, donde la correcta ruta de ubicación ha sido esencial para no tener problemas en la compilación de la red neuronal.

Asimismo, se realizaron 4 pruebas con diferentes cantidades de imágenes y épocas las cuales nos ayudan a verificar cual es el mejor resultado en la clasificación. En la prueba N°4 se obtuvo un mejor resultado con un total de 168 imágenes y 77 épocas, con Acc.Train: 0.9198 y Acc.Test: 0.9500, tal como se muestra en la tabla 1 y figura 4.

Tabla 1- Resultados del Experimento 1.

| N° prueba | Imágenes | Épocas | Tiempo | Acc.Train | Acc. Test |
|-----------|----------|--------|--------|-----------|-----------|
| 1 | 148 | 300 | 32 min | 0.9392 | 0.9000 |
| 2 | 148 | 20 | 3 min | 0.9257 | 0.9250 |
| 3 | 148 | 250 | 25 min | 0.9392 | 0.9250 |
| 4 | 168 | 77 | 15 min | 0.9198 | 0.9500 |

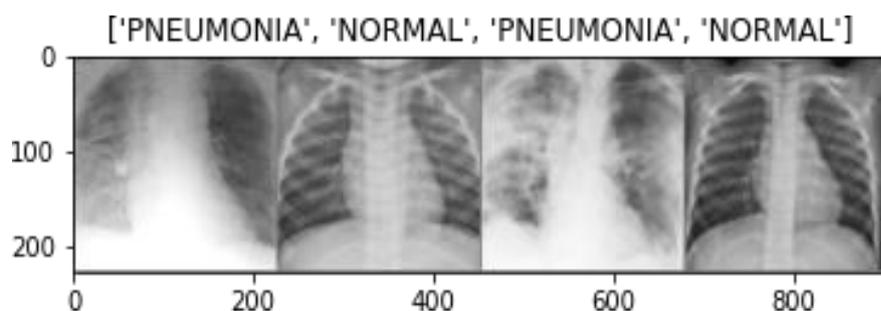


Fig.4- Experimento 1-Clasificación de un pulmón normal y uno con covid-19 a un Acc.Train de 0.9198 y Acc.Test de 0.9500, aplicando el modelo Covid-UPeU.

En el experimento 2 se aplicó el modelo Covid-UPeU, donde se optó por aumentar las imágenes a un máximo de 1636 y un mínimo de 805 lo cual dio un resultado favorable pero no el esperado, asimismo se realizaron 4 pruebas para verificar la variación del resultado en épocas e imágenes, además se utilizó el método de normalización el cual ha doblado las imágenes de su versión normal. Por lo tanto, el mejor resultado se ha obtenido en la prueba N°3 donde Acc.Train: 0.8270 y Acc.Test: 0.8702, tal como se muestra en la tabla 2 y figura 5.



Tabla 2- Resultado del Experimento 2.

| N° prueba | Imágenes | Épocas | Tiempo | Acc Train | Acc Test |
|-----------|----------|--------|----------|-----------|----------|
| 1 | 805 | 50 | 28min | 0.9578 | 0.9250 |
| 2 | 1636 | 20 | 1h 43min | 0.8784 | 0.7250 |
| 3 | 1636 | 100 | 25min | 0.8270 | 0.8702 |
| 4 | 930 | 55 | 31min | 0.8559 | 0.9155 |

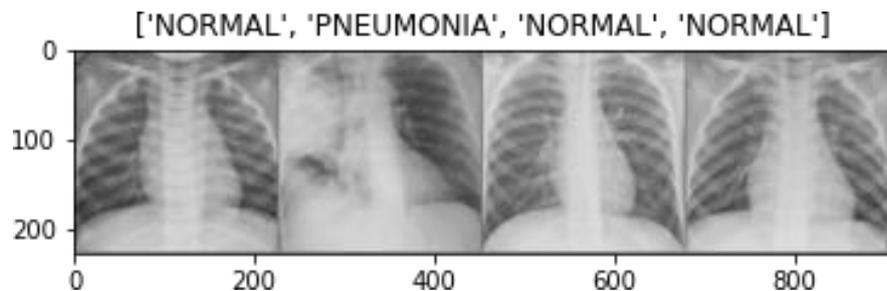


Fig.5- Experimento 2 Clasificación de un pulmón normal y uno con covid-19 usando el método de Normalización a un Acc.train de 0.8270 y Acc.test de 0.8702, aplicando el modelo Covid-UPeU.

En el experimento 3 fue aplicado el modelo Covid-UPeU, donde se optó por obtener la media y la varianza del conjunto de imágenes, para luego ser estandarizado en la fase de normalización del modelo de red. Por otro lado, en la prueba N°2 se optó por cambiar los datos de normalización de 3 a sólo 1, el cual era la media; se obtuvo un resultado bastante óptimo en la prueba N°3, donde Train: 0.8796, Accuracy: 0.9119 tal como se muestra en la tabla 3 y en la figura 6.

Tabla 3- Resultado del Experimento 3.

| N° prueba | Imágenes | Épocas | Tiempo | Acc Train | Acc Test |
|-----------|----------|--------|----------|-----------|----------|
| 1 | 2,645 | 100 | 1h 49min | 0.8881 | 0.9098 |
| 2 | 2,948 | 100 | 2h 36min | 0.8803 | 0.3750 |
| 3 | 1,770 | 79 | 53min | 0.8796 | 0.9119 |
| 4 | 1,640 | 75 | 1h 4min | 0.8735 | 0.6250 |



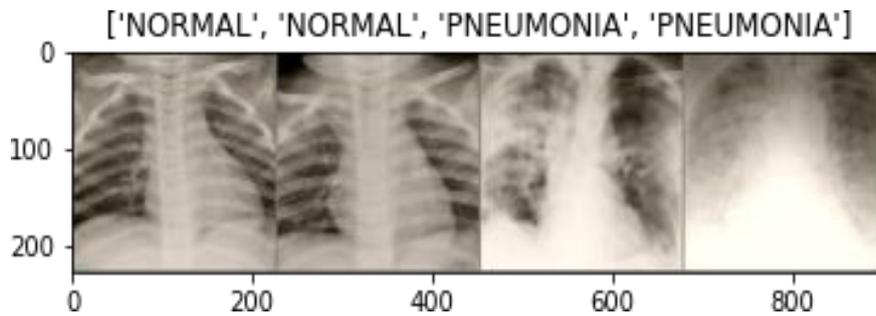


Fig.6- Experimento 3 Clasificación de un pulmón normal y uno con covid-19 usando el método de normalización con Media y Varianza a un Acc.Train de 0.8796 y un Acc.Test de 0.9119, aplicando el modelo Covid-UPeU.

En el experimento 4 se aplicó el modelo Covid-UPeU-TL, donde se adicionó una línea de código diferente para cada entrenamiento o N° de prueba, es decir se han aplicado DenseNet y ResNet los cuales fueron entrenados de forma individual ya que ambos modelos han sido pre-entrenados de la base de datos de ImageNet, esta prueba ha permitido la optimización de los pesos y como mejor resultado en la prueba N°2 se ha obtenido un Acc.Train: 0.9664 y un Acc.Test de 0.9851. Asimismo, el máximo de imágenes utilizadas ha sido de 3000 y un mínimo de 1600. Se muestra en la tabla 4 y la figura 7.

Tabla 4- Resultado del Experimento 4.

| N° prueba | Imágenes | Épocas | Tiempo | Acc Train | Acc Test |
|-----------|----------|--------|----------|-----------|----------|
| 1 | 2,948 | 25 | 5h 38min | 0.9732 | 0.0750 |
| 2 | 2,645 | 100 | 3h 21min | 0.9664 | 0.9851 |
| 3 | 1,676 | 100 | 2h 39min | 0.9639 | 0.9250 |
| 4 | 2,887 | 68 | 2h 9min | 0.9839 | 0.0786 |



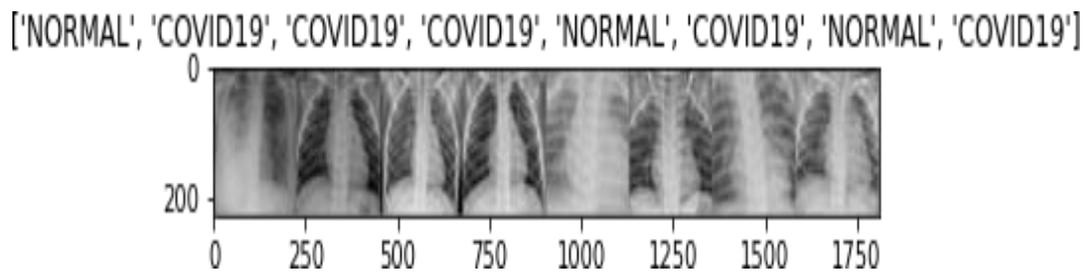


Fig.7- Experimento 4 Clasificación de un pulmón normal y uno con covid-19 aplicando DenseNet y ResNet con un Acc.Train de 0.9664 y un Acc.Test 0.9851, aplicando el modelo Covid-UPeU-TL.

Al usar una red con mayor cantidad de capas e imágenes en el modelo CovidUPeU-TL se ha tenido un tiempo de entrenamiento más prolongado que los resultados previos, dando así resultados satisfactorios.

Discusión y Conclusiones

Los modelos implementados se desarrollaron con el propósito de tener una visión holística de los factores para la optimización en la clasificación de imágenes de COVID-19, tratando en este caso de realizar una contribución a la salud y con el propósito de ser un punto de referencia para trabajos futuros tal como lo mencionan ⁽²⁰⁾, como la integración con imágenes de neumonía en Perú u otras enfermedades que puedan involucrar problemas pulmonares.

Se obtuvieron diferentes resultados en los 4 experimentos; el entrenamiento con mejor resultado se halló en el experimento 4 (prueba N°2), donde se aplicó el modelo Covid-UPeU-TL el cual fue entrenado con 100 épocas y un total de 2645 imágenes, el tiempo de ejecución fue de un total de 2horas con 39min y 19sg. Es por ello que se tuvo como referencia el estudio realizado por ⁽²¹⁾, el cual presenta nuevos modelos de CNN para la detección de COVID 19 y otros casos de neumonía haciendo uso de imágenes Rayos X, donde el resultado óptimo se obtuvo con el modelo ResNet, con una precisión satisfactoria del 99,17%, el cual es una clasificación binaria (COVID-19 y No -COVID). Concluyendo que el uso de imágenes Rayos X y Redes neuronales convolucionales logren un impacto en diferentes escenarios de clasificación y diagnóstico.

El uso de la inteligencia artificial puede ayudar en el diagnóstico efectivo a través de modelos entrenados y óptimos, permitiendo el ahorro de recursos y la certeza de los resultados, con un proceso automatizado de clasificación, donde su integración con otros elementos podría significar el inicio de un nuevo avance tecnológico.



Referencias

1. OMS [Internet]. OMS | Nuevo coronavirus - China. [citado 12 Ene 2020]. Disponible en: <https://www.who.int/es/emergencies/diseases/novel-coronavirus-2019>
2. Guan W, Ni Z, Hu Y, Liang W, Ou C, He J, et al. Clinical Characteristics of Coronavirus Disease 2019 in China. N Engl J Med [Internet]. 2020 Apr [cited 2021 Apr 28];382(18):1708–20. Available from: <http://www.nejm.org/doi/10.1056/NEJMoa2002032>
3. Adhanom Ghebreyesus T. Alocución de apertura del Director General de la OMS en la rueda de prensa sobre la COVID-19 celebrada el 11 de marzo de 2020 [Internet]. 2020 Mar 11 [citado 17 May 2020]. Disponible en: <https://www.who.int/es/director-general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020>
4. Weiss K, Khoshgoftaar TM, Wang DD. A survey of transfer learning. J Big Data [Internet]. 2016 Dec [cited 2020 Jul 8];3(1):[about 40 p.]. Available from: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-016-0043-6>
5. Ahuja AS, Reddy VP, Marques O. Artificial intelligence and COVID-19: A multidisciplinary approach. Integr Med Res [Internet]. 2020 Sep [cited 2021 Apr 28];9(3):[about 3 p.]. Available from: <https://doi.org/10.1016/j.imr.2020.100434>
6. Fierro AN, Nakano M, Yanai K, Pérez HM. Redes Convolucionales Siamesas y Tripletas para la Recuperación de Imágenes Similares en Contenido. Inf Tecnol [Internet]. 2019 [citado 6 Jul 2020];30(6):243–54. Disponible en: <http://dx.doi.org/10.4067/S0718-07642019000600243>
7. Mei X, Lee HC, Diao K yue, Huang M, Lin B, Liu C, et al. Artificial intelligence– enabled rapid diagnosis of patients with COVID-19. Nat Med [Internet]. 2020 Aug [cited 2021 Apr 28];26(8):1224–8. Available from: <https://doi.org/10.1038/s41591-020-0931-3>
8. Cortés E, Sanchez S. Deep Learning Transfer with AlexNet for chest X-ray COVID-19 recognition. IEEE Lat Am Trans [Internet]. 2021 Mar [cited 2021 Apr 23];19:944-51. Available from: <https://latamt.ieeeer9.org/index.php/transactions/article/view/4336>
9. Ozturk T, Talo M, Yildirim EA, Baloglu UB, Yildirim O, Rajendra Acharya U. Automated detection of COVID-19 cases using deep neural networks with Xray images. Comput Biol Med [Internet]. 2020 Jun [cited 2021 Apr 26];121:[about 11 p.]. Available from: <https://www.sciencedirect.com/science/article/abs/pii/S0010482520301621>
10. White T. 4 iniciativas que apuestan por la inteligencia artificial y tecnología inclusiva. El Peruano [Internet]. 29 Jul 2019 [cited 16 May 2020]. Disponible en: <http://www.elperuano.pe/noticia-tecnologia-inclusiva-83801.aspx>
11. Diaz Marquez J. Inteligencia artificial y Big Data como soluciones frente a la COVID-19. Rev Bioética y Derecho [Internet]. 2020 Nov [cited 28 Abr 2021];315–31. Disponible en:



https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1886-58872020000300019

12. Zhou J, Cui G, Zhang Z, Yang C, Liu Z, Wang L, et al. Graph Neural Networks: A Review of Methods and Applications. arXiv [Internet]. 2018 Dec 20 [cited Apr 26];1:57–81. Available from:

<https://www.sciencedirect.com/science/article/pii/S2666651021000012>

13. Curioso WH, Brunette MJ. Artificial intelligence and innovation to optimize the tuberculosis diagnostic process. Rev Peru Med Exp Salud Publica [Internet]. 2020 Jul [cited 2021 Apr 28];37(3):554–8. Available from:

<https://doi.org/10.17843/rpmesp.2020.373.5585>

14. Muñoz Herrera W, Bedoya OF, Rincón ME. Aplicación de redes neuronales para la reconstrucción de series de tiempo de precipitación y temperatura utilizando información satelital. Rev EIA [Internet]. 2020 Oct [citado 26 Abr 2021];17(34):[aprox. 16 p.]. Disponible en: <https://doi.org/10.24050/reia.v17i34.1292>

15. Quintero C, Merchán F, Cornejo A, Galán JS. Uso de Redes Neuronales Convolucionales para el Reconocimiento Automático de Imágenes de Macroinvertebrados para el Biomonitorio Participativo. KnE Eng [Internet]. 2018 Feb [citado 26 Abr 2021];3(1):585-96. Disponible en:

<https://knepublishing.com/index.php/KnEEngineering/article/view/1462/3528>

16. Mooney P. Chest X-Ray Images (Pneumonia) | Kaggle [Internet]. 2018 [cited Apr 27]. Available from:

<https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>

17. Praveen. Hack-D-Covid'20 Track-1 [Internet]. 2020 [cited 2021 Apr 27]. Available from: <https://www.kaggle.com/c/kjsce-hack-d-covid20-track1>

18. Boderó EM, López MP, Congacha AE, Cajamarca EE, Morales CH. Google Colaboratory como alternativa para el procesamiento de una red neuronal convolucional. ISSN [Internet]. 2020 Mar [citado 27 Abr 2021];41(02):[aprox. 10 p.]. Disponible en:

<http://www.revistaespacios.com/a20v41n07/a20v41n07p22.pdf>

19. Albo Hernández RO, Guzmán Sánchez MV, Álvarez Díaz I, Bouza Figueroa JF, Calero Ramos R. Requerimientos para mejorar la normalización de datos en software de análisis métricos de la información. Rev. cuba. inf. cienc. salud [Internet]. 2018 Mar [citado 2022 Ene 26]; 29(1): 55-73. Disponible en:

http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2307-21132018000100005&lng=es.

20. Bardález-Trigoso G, Bazán-Arzapalo JP, Fabián J, Montenegro-Montori P. (2021). Detección del SARS-CoV-2 en radiografías de tórax por medio de descriptores intermedios y técnicas de machine learning. En Universidad de Lima (Ed.), Construyendo un mundo inteligente para la sostenibilidad . Actas del III Congreso Internacional de Ingeniería de Sistemas (pp. 123-136), Lima, 17 y 20 de noviembre del 2020. Disponible en: <https://repositorio.ulima.edu.pe/handle/20.500.12724/13896>



21. Belman López CE. Detection of COVID-19 and Other Pneumonia Cases Using Convolutional Neural Networks and X-ray Images. Ing. Inv. [Internet]. 2022 Jan.1 [cited 2022Jan.26];42(1):e90289. Available from: <https://revistas.unal.edu.co/index.php/inginv/article/view/90289>

Conflicto de Interés

Los autores declaramos que no tenemos ningún tipo de conflicto de interés en este trabajo con ninguna organización académica y/o comercial.

Contribuciones de los autores

Bach. Adiel Joshua Preciado Rodríguez: Levantamiento de las observaciones presentadas en coordinación con los demás autores, aportaciones importantes a la idea y diseño del estudio.

Bach. Flor Mayerli Flores Guillen y Bach. Aldo Emanuel Soraluz Soraluz: Metodología, contribución en la conceptualización de la idea del estudio, redactores y revisores críticos del documento.

Bach. Jonathan Gerhard Ríos Jara: Apoyo en la recogida, análisis e interpretación de datos, asimismo las aportaciones importantes a la idea y diseño del estudio.

