



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Facultad de Medicina

Escuela Profesional de Tecnología Médica

**Precisión del uso del Deep Learning en la síntesis,
detección y segmentación de signos ultrasonográficos
de pulmón sugerentes a Covid-19**

TESIS

Para optar el Título Profesional de Licenciado en Tecnología
Médica en el área de Radiología

AUTOR

Carlos Sebastian ROJAS AZABACHE

ASESORES

Dr. Lusín Antonio PONCE CONTRERAS

Leo Sivori ZEVALLOS MEZA (Coasesor)

Lima, Perú

2022



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Azabache C. Precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid-19 [Tesis de pregrado]. Lima: Universidad Nacional Mayor de San Marcos, Facultad de Medicina, Escuela Profesional de Tecnología Médica; 2022.

Metadatos complementarios

Datos de autor	
Nombres y apellidos	Carlos Sebastian Rojas Azabache
Tipo de documento de identidad	DNI
Número de documento de identidad	45347636
URL de ORCID	https://orcid.org/0000-0002-6093-1574
Datos de asesor	
Nombres y apellidos	Lusin Antonio Ponce Contreras
Tipo de documento de identidad	DNI
Número de documento de identidad	06794361
URL de ORCID	https://orcid.org/0000-0002-5523-8134
Datos de coasesor	
Nombres y apellidos	Leo Sivori Zevallos Meza
Tipo de documento de identidad	DNI
Número de documento de identidad	45912156
URL de ORCID	https://orcid.org/0000-0002-5189-1304
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Misael Jefferson Fajardo Quispe
Tipo de documento	DNI
Número de documento de identidad	44876362
Miembro del jurado 1	
Nombres y apellidos	Elmer Edgardo Santiani Puican

Tipo de documento	DNI
Número de documento de identidad	25832597
Miembro del jurado 2	
Nombres y apellidos	Walter Robin Roca Trejo
Tipo de documento	DNI
Número de documento de identidad	15853128
Datos de investigación	
Línea de investigación	No aplica.
Grupo de investigación	No aplica.
Agencia de financiamiento	Autofinanciamiento.
Ubicación geográfica de la investigación	Universidad Nacional Mayor de San Marcos Edificio: Facultad de Medicina “San Fernando” País: Perú Departamento: Lima Provincia: Lima Distrito: Cercado de Lima Calle: Av. Miguel Grau 755, Lima 15001 Latitud: -12.056643 Longitud: -77.022945
Año o rango de años en que se realizó la investigación	2021 - 2022
URL de disciplinas OCDE	Radiología, Medicina nuclear, Imágenes médicas: https://purl.org/pe-repo/ocde/ford#3.02.12



Universidad Nacional Mayor de San Marcos

Universidad del Perú, Decana de América

Facultad de Medicina

Escuela Profesional de Tecnología Médica

“Año del Fortalecimiento de la Soberanía Nacional”



Firmado digitalmente por
FERNÁNDEZ GIUSTI VDA DE PELLA
Alicia Jesus FAU 20148092282 soft
Motivo: Soy el autor del documento
Fecha: 30.11.2022 09:57:28 -05:00

ACTA DE SUSTENTACIÓN DE TESIS



Firmado digitalmente por SANDOVAL
VEGAS Miguel Hernan FAU
20148092282 soft
Motivo: Soy el autor del documento
Fecha: 29.11.2022 11:17:10 -05:00

Conforme a lo estipulado en el Art. 113 inciso C del Estatuto de la Universidad Nacional Mayor de San Marcos (R.R. No. 03013-R-16) y Art. 45.2 de la Ley Universitaria 30220. El Jurado de Sustentación de Tesis nombrado por la Dirección de la Escuela Profesional de Tecnología Médica, conformado por los siguientes docentes:

Presidente: Dr. Misael Jefferson Fajardo Quispe
Miembros: Dr. Elmer Edgardo Santiani Puican
Lic. Walter Robin Roca Trejo
Asesor(a): Dr. Lusin Antonio Ponce Contreras

Se reunieron en la ciudad de Lima, el día 24 de noviembre del 2022, siendo las 11:15 horas, procediendo a evaluar la Sustentación de Tesis, titulado **“Precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid-19”**, para optar el Título Profesional de Licenciado en Tecnología Médica en el Área de Radiología del señor:

CARLOS SEBASTIAN ROJAS AZABACHE

Habiendo obtenido el calificativo de:

18

DIECIOCHO

(En números)

(En letras)

Que corresponde a la mención de:MUY BUENO.....

Quedando conforme con lo antes expuesto, se disponen a firmar la presente Acta.

Presidente

Dr. Misael Jefferson Fajardo Quispe

D.N.I.: 44876362

Miembro

Dr. Elmer Edgardo Santiani Puican

D.N.I.: 25832597

Miembro

Lic. Walter Robin Roca Trejo

D.N.I.: 15853128

Asesor(a) de Tesis

Dr. Lusin Antonio Ponce Contreras

D.N.I.: 06794361

Av. Grau N° 755. Apartado Postal 529 – Lima 100 – Perú.

Central (511) 619-7000 - IP 4609. Email: eptecnologiamed.medicina@unmsm.edu.pe

Portal Web: <http://medicina.unmsm.edu.pe>



Universidad Nacional Mayor de San Marcos

Universidad del Perú, Decana de América

Facultad de Medicina

Escuela Profesional de Tecnología Médica

“Año del Fortalecimiento de la Soberanía Nacional”



Datos de plataforma virtual institucional del acto de sustentación:

https: <https://us02web.zoom.us/j/84572651785?pwd=Q0RNcEZmK3ZmdFZFdDc3ZW5zTUNGQT09>

ID:

Grabación archivada en:



INFORME DE EVALUACIÓN DE ORIGINALIDAD

El Director de la Escuela Profesional de Tecnología Médica de la Facultad de Medicina de la Universidad Nacional Mayor de San Marcos que suscribe, hace constar que:

El autor: Carlos Sebastian ROJAS AZABACHE

de la tesis para optar el título profesional de Licenciado(a) en Tecnología Médica, en el Área de Radiología,

Titulada:

“Precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid-19”

Presentó solicitud de evaluación de originalidad el 19 de octubre del 2022 y el 19 de octubre del 2022 (UTC-0500) se aplicó el programa informático de similitudes en el software TURNITIN con Identificador de la entrega N°: **1930223518**

En la configuración del detector se excluyó:

- textos entrecomillados.
- bibliografía.
- cadenas menores a 40 palabras.
- anexos.

El resultado final de similitudes fue del 3 %, según consta en el informe del programa TURNITIN.

EL DOCUMENTO ARRIBA SEÑALADO CUMPLE CON LOS CRITERIOS DE ORIGINALIDAD
Operador del software el profesor: Dr. Miguel Hernán Sandoval Vegas.

Lima, 19 de octubre del 2022.



Firmado digitalmente por SANDOVAL
VEGAS Miguel Hernan FAU
20148092282 soft
Motivo: Soy el autor del documento
Fecha: 19.10.2022 22:43:59 -05:00



Dr. MIGUEL HERNÁN SANDOVAL VEGAS
DIRECTOR
EPTM-FM-UNMSM

Dedicatoria

Dedico esta tesis a mis padres por su apoyo incondicional, por sus enseñanzas, por sus esfuerzos para que pueda salir adelante y por ser la principal fuente de aliento e inspiración para mí a lo largo de mi vida.

A mis hermanos por su apoyo incondicional y por ser mi motivación para ser mejor cada día.

Agradecimiento

Agradezco a Dios por permitirme un día más de vida, mantenerme bien de salud y guiar mi destino para poder lograr mis metas.

A mi familia por todo el apoyo brindado durante toda mi formación.

A mis asesores Lusin Ponce y Leo Zevallos por su tiempo y sus consejos para realizar esta investigación.

A los expertos Luis Chumpitaz, Dennis Nuñez y Jeison Fonseca por la evaluación del instrumento de investigación.

A mi enamorada Thalía Romero que me apoyó en cada decisión, por sus opiniones, visión crítica y compañía.

A los docentes de la Facultad de medicina “San Fernando”, en especial de la escuela profesional Tecnología Médica por sus enseñanzas.

A los docentes tecnólogos médicos Mg. José Vásquez y al Dr. Miguel Sandoval por sus cartas de recomendación para llevar cursos de intercambio estudiantil.

A la Universidad Nacional Mayor de San Marcos, a la Oficina General de Cooperación y Relaciones Interinstitucionales (OGCRI) por permitirme llevar cursos de intercambio estudiantil en señales, procesamiento de imágenes médicas e inteligencia artificial, el cual fue un complemento para realizar esta investigación.

ÍNDICE

LISTA DE TABLAS	viii
LISTA DE GRAFICOS.....	ix
Resumen	x
Abstract.....	xi
CAPITULO I.....	1
INTRODUCCIÓN	1
1.1. DESCRIPCIÓN DE LOS ANTECEDENTES.....	2
1.2. IMPORTANCIA DE LA INVESTIGACIÓN.....	10
1.3. OBJETIVOS	11
1.3.1 OBJETIVO GENERAL	11
1.3.2 OBJETIVOS ESPECÍFICOS	11
1.4. BASES TEÓRICAS.....	11
1.4.1 BASE TEÓRICA	11
1.4.2 DEFINICIÓN DE TÉRMINOS	23
1.4.3 FORMULACIÓN DE LA HIPÓTESIS	24
CAPITULO II:.....	25
MÉTODOS.....	25
2.1. DISEÑO METODOLÓGICO	26
2.1.1 TIPO DE INVESTIGACIÓN.....	26
2.1.2 DISEÑO DE LA INVESTIGACIÓN.....	26
2.1.3 POBLACIÓN.....	26
2.1.4 MUESTRA y MUESTREO.....	26

2.1.4.1 CRITERIOS DE INCLUSIÓN.....	26
2.1.4.2 CRITERIOS DE EXCLUSIÓN	27
2.1.5 VARIABLES	27
2.1.6 TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS.....	27
2.1.7 PROCEDIMIENTOS Y ANÁLISIS DE DATOS	28
2.1.8 CONSIDERACIONES ÉTICAS.....	33
CAPITULO III:	35
RESULTADOS	35
CAPÍTULO IV	43
DISCUSIÓN	43
CAPITULO V.....	49
CONCLUSIONES Y RECOMENDACIONES.....	49
REFERENCIAS BIBLIOGRÁFICAS	52
ANEXOS.....	62

LISTA DE TABLAS

Tabla N°1: Hiperparámetros de entrenamiento de la arquitectura DCGAN.....	36
Tabla N°2: Métricas de evaluación de DCGAN	36
Tabla N°3: Hiperparámetros de entrenamiento de la arquitectura Mask R-CNN.....	39
Tabla N°4: Métricas de evaluación del modelo Mask R-CNN	40
Tabla N°5: Valores AP para la detección y segmentación según signos ecográficos sugerentes a COVID-19 durante la evaluación del modelo Mask R-CNN.	40
Tabla N°6: Valores de AP50 y AP75 para la detección y segmentación de signos ecográficos sugerentes a COVID-19.....	41

LISTA DE GRAFICOS

Gráfico N°1: Evaluación durante el entrenamiento de la función de pérdida y de la exactitud de la red generadora y discriminadora del DCGAN.....	37
Gráfico N°2: La exactitud y la función de pérdida durante el entrenamiento del modelo Mask R-CNN	39

Resumen

Objetivo: Evaluar la precisión del uso del deep learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a COVID-19.

Metodología: Para esta investigación se utilizaron dos modelos de deep learning: el DCGAN para la síntesis de imágenes y el Detectron2 (Mask R-CNN) con pesos pre entrenados de RESNET50 para detección y segmentación. Se utilizó el conjunto de datos de acceso libre POCUS, del cual se seleccionaron 1892 frames de ultrasonografía pulmonar de pacientes con COVID-19, 1570 (83%) para el entrenamiento y 323 (17%) para validación. Para la detección y segmentación se hizo una división por categorías utilizando los signos de líneas B, signos de línea pleural anormal y consolidación, los cuales están relacionados con la gravedad de la enfermedad. Para evaluar el rendimiento de ambos modelos se utilizaron las métricas de función de pérdida, exactitud, distancia inicial de Frechet (FID), precisión promedio (AP, por sus siglas en inglés), AP50 Y AP75.

Resultados: Para la síntesis de imágenes de signos ultrasonográficos sugerentes a COVID-19 se obtuvo un valor FID de 20.491; mientras que para la detección y segmentación de imágenes se obtuvo una función de pérdida total de 0.31 (función de pérdida de detección, clasificación y segmentación) y una exactitud de 92%. En la detección, el signo de líneas B obtuvo la mejor precisión promedio (45.50), seguido del signo de consolidación (44.52) y de línea pleural anormal (27.44). También en la segmentación se obtuvieron valores altos de precisión promedio en el signo de líneas B (44.47), seguido del signo de consolidación (39.85) y de línea pleural anormal (23.27).

Conclusión: Se obtuvieron imágenes sintéticas muy realistas, una alta exactitud en la detección y segmentación de signos sugerentes de COVID-19 evaluados por ultrasonografía, muy útil para evaluar la gravedad de la enfermedad. El deep learning es un área muy prometedora para el análisis y pos procesamiento de las imágenes radiológicas, el cual puede servir de apoyo al tecnólogo médico en radiología como a otros profesionales de la salud, así como también para la educación en radiología.

Palabras clave: Deep learning, aprendizaje profundo, ultrasonografía pulmonar, segmentación, síntesis de imágenes, detección, COVID-19.

Abstract

Objective: To evaluate the precision of the use of deep learning in the synthesis, detection and segmentation of lung ultrasonography signs suggestive of COVID-19.

Methodology: Two deep learning models were used for this research: the DCGAN for image synthesis and the Mask R-CNN (Detectron2) with the pre-trained weights of RESNET50 for the detection and segmentation of ultrasound images. The free access POCUS data set was used, from which 1892 pulmonary ultrasonography frames of patients with COVID-19 were selected, 1570 (83%) for training and 323 (17%) for validation. For detection and segmentation, a division was made by categories using the signs of B lines, signs of abnormal pleural line and consolidation, which are related to the severity of the disease. To evaluate the performance of both models, the loss function, accuracy, Frechet inception distance (FID), AP (Average precision), AP50 and AP75 metrics were used.

Results: For the synthesis of images of ultrasonography signs suggested to COVID-19, an FID value of 20,491 was obtained; while for the detection and segmentation of images, a total loss function of 0.31 (detection, classification and segmentation loss function) and an accuracy of 92% were obtained. In detection, the B-line sign obtained the best average accuracy (45.50), followed by the consolidation sign (44.52) and the abnormal pleural line (27.44). Also in the segmentation, high average precision values were obtained in the sign of B lines (44.47), followed by the sign of consolidation (39.85) and abnormal pleural line (23.27).

Conclusion: Very realistic synthetic images were obtained, a high accuracy in the detection and segmentation of signs suggestive of COVID-19 evaluated by ultrasonography, very useful to assess the severity of the disease. Deep learning is a very promising area for the analysis and post-processing of radiological images, which can support the medical radiology technologist as well as other health professionals, as well as for radiology education.

Keywords: Deep learning, pulmonary ultrasonography, lung ultrasound, segmentation, image synthesis, detection, COVID-19.

CAPITULO I

INTRODUCCIÓN

1.1. DESCRIPCIÓN DE LOS ANTECEDENTES:

El COVID-19 es una enfermedad producida por el virus SARS-CoV-2. El Perú reportó su primer caso de coronavirus el día 6 de marzo 2020¹. A pesar de las medidas de aislamiento social, la transmisión se extendió dentro del país; y a la fecha de la redacción de este manuscrito, el número de casos positivos de coronavirus asciende a más de 1 millón y más de 38 mil muertes ².

La técnica molecular estándar para detectar SARS CoV-2 es la “reacción en cadena de la polimerasa con transcriptasa inversa (RT-PCR)”, pero sigue siendo un problema su baja sensibilidad el cual varía y que en promedio es de 80%³, siendo la tomografía computada el estudio con mayor sensibilidad, llegando hasta un 92%⁴; sin embargo, existe un número limitado de tomógrafos en el sistema de salud público peruano⁵, así como también su baja especificidad y la alta dosis de radiación por cada adquisición. También se están utilizando las imágenes radiográficas de tórax, pero estas solo presentan una sensibilidad de 82.1%⁶.

La ultrasonografía pulmonar ha asumido un papel fundamental en la evaluación de pacientes SARS-CoV-2, llegando a una sensibilidad superior que al de la radiografía de tórax y muy cercano a la tomografía computada⁷, incluso hay estudios que ponen a la ecografía por encima de la tomografía computada^{8,9}.

En la actualidad para la evaluación, seguimiento y control de la enfermedad se está utilizando la radiografía y en menor escala la tomografía computada, debido al poco acceso y al uso de dosis relativamente altas al momento de realizar la exploración.

La ultrasonografía pulmonar podría ser una alternativa para tal problema; sin embargo, no se está aprovechando, a pesar de que la ecografía pulmonar tiene una alta capacidad, similar a la tomografía computada, para detectar la gravedad de la enfermedad¹⁰⁻¹⁵, inclusive pudiendo predecir la necesidad de intubación, ventilación mecánica, mortalidad y evolución^{16,17}. La posibilidad de repetir el examen durante el seguimiento hace que esta modalidad sea muy útil en mujeres embarazadas¹⁸.

La pandemia del COVID-19 ha expuesto la vulnerabilidad de los servicios de salud, esto sumado a que existen muy pocos ecografistas (médicos radiólogos, médicos especialistas, tecnólogos médicos o médicos ecografistas) que realicen estos estudios, debido a que es poco utilizado en nuestro país, poca divulgación científica, falta de capacitación, por su característica operador dependiente y por su alta exposición con la enfermedad. Existe una clara necesidad de desarrollar nuevas herramientas del diagnóstico asistido por computadora para que sirva de apoyo en la evaluación, seguimiento, control de la enfermedad, así como para una detección rápida y rentable en lugares donde las pruebas tradicionales falten, ya sea porque no dispongan de la infraestructura de un laboratorio o porque falten los reactivos necesarios para abordar el diagnóstico.

Actualmente el brote de SARS-CoV-2 está trayendo complicaciones no sólo clínicas, sociales, políticas y económicas, sino que también repercusiones educativas. Esta tecnología podría ser de gran apoyo para el entrenamiento de ecografistas para facilitar el aprendizaje, educación médica que en la actualidad está siendo bien demandada en el contexto de la actual emergencia global^{19,20}.

A pesar del auge del procesamiento de imágenes médicas mediante el uso del deep learning, las investigaciones en imágenes ultrasonográficas para la generación de imágenes sintéticas, detección y segmentación de signos sugerentes a COVID-19 son mínimas, por ello es importante desarrollar más investigación al respecto, el cual podría ser de gran ayuda en el futuro para la implementación de un software que pueda apoyar al diagnóstico, la evaluación, seguimiento, control de la enfermedad y a la educación médica²¹.

Como antecedentes tenemos a las siguientes investigaciones:

Jiamin Liang et al. En el año 2022²², en su investigación “Sketch guided and progressive growing GAN for realistic and editable ultrasound image synthesis”, su objetivo fue diseñar una nueva propuesta de red neuronal profunda del tipo Generative Adversarial Networks (GAN) para generar imágenes sintéticas realistas. Para este estudio se utilizaron un conjunto de imágenes de ecografía pulmonar, articulación de cadera y ovario de 6054, 1231 y 3261, respectivamente.

En el diseño de este modelo se propuso el uso de guías de boceto auxiliar en una GAN condicional, también se adoptaron una estrategia de entrenamiento progresivo para generar gradualmente imágenes de alta resolución a partir de imágenes de baja resolución, así como otras estrategias avanzadas para poder mejorar la calidad de las imágenes generadas. Compararon tres modelos; el primero, para demostrar la efectividad de la guía de bocetos y la pérdida de características. Para imágenes de 256x256: línea base, línea base + S y línea base+S+FL. La línea de base solo usó la estructura básica de una GAN, la línea de base + S incorporó el auxiliar guía de bocetos, y línea base + S + FL adicionalmente agregó la característica de pérdida. Para las imágenes de 512x512 se utilizó los métodos del uso del boceto, la red pre entrenada usada anteriormente y el entrenamiento progresivo. Como resultados cualitativos para las imágenes 256x256 obtuvieron que el modelo de línea base y el modelo de línea base + S generaron imágenes con artefactos, en línea base + S + FL se eliminaron los artefactos y demostró ser el más eficaz. Para las imágenes de 512x512 se obtuvieron buenos resultados en los 3 métodos, siendo el más importante el del uso del boceto. Como resultados cuantitativos, en el tercer método de imágenes de 256x256 se obtuvo mejor calidad de las imágenes COVID-19, articulación de cadera y ovario, con un valor Frechet inception distance (FID) de 60.75, 67.68 y 61.41, respectivamente; mientras que para las imágenes de 512x512, en el método del uso del boceto se obtuvo valores FID de 36.36, 57.81, 0.764 y 47.11 para las mismas imágenes evaluadas. El estudio concluye que la red neuronal propuesta es una herramienta útil para generar imágenes de ultrasonografía de alta resolución y alta fidelidad a partir de mapas de etiquetas.

Según Julia Diaz-Escobar et al. (2021)²³, en su investigación “Deep-learning based detection of COVID-19 using lung ultrasound imagery”, el objetivo fue evaluar y comparar el desempeño de técnicas de aprendizaje profundo para detectar infecciones por COVID-19 a partir de imágenes de ultrasonido pulmonar. Utilizaron el conjunto de datos POCUS disponible públicamente que comprende 3326 frames de ultrasonografía pulmonar de pacientes sanos, con COVID-19 y con neumonía. Esta investigación es de diseño aplicativo, y consistió en adaptar diferentes arquitecturas de aprendizaje profundo previamente entrenadas, incluidas

VGG19, InceptionV3, Xception y ResNet50. Como resultados se obtuvieron que la red InceptionV3 logró la mejor precisión promedio (89.1%), precisión equilibrada (89.3%) y área bajo la curva de funcionamiento del receptor (97.1%) para la detección de COVID-19 a partir de neumonía bacteriana y datos de ultrasonido de pulmón sano. Las pruebas ANOVA y Friedman encontraron diferencias de rendimiento estadísticamente significativas entre los modelos en cuanto a precisión, precisión equilibrada y área bajo la curva de funcionamiento del receptor. El análisis post-hoc mostró diferencias estadísticamente significativas entre el rendimiento obtenido con el modelo basado en InceptionV3 y los modelos basados en POCOVID-net, VGG19- y ResNet50. No se encontró diferencias significativas en el rendimiento obtenido con los modelos basados en InceptionV3 y Xception. Llegando a la conclusión de que las técnicas de aprendizaje profundo para el análisis asistido por computadora de imágenes de ultrasonografía pulmonar brindan una vía prometedora para la detección y el diagnóstico de COVID-19. En particular, encontramos que la red InceptionV3 proporciona los resultados predictivos más prometedores de todas las técnicas basadas en IA evaluadas en este trabajo.

Según Marco La Salvia et al. (2021)²⁴, en Italia, en su investigación “Deep learning and lung ultrasound for Covid-19 pneumonia detection and severity classification”, el objetivo fue construir un algoritmo que pueda reconocer y clasificar patrones COVID-19 en frames de ultrasonografía. Se hizo una selección de un conjunto de datos correspondientes a clips de exámenes ultrasonográficos provenientes de transductores lineales y convexos. Se utilizaron 2908 frames para el entrenamiento del modelo de 450 pacientes hospitalizados del Departamento de Emergencias (ED) de Pavía de la Fondazione IRCCS Policlinico San Matteo. Dentro del método utilizado, se adaptó dos redes residuales profundas de 18 y 50 capas, las arquitecturas ResNet18 y ResNet50, respectivamente. A estas redes se les hizo las modificaciones, cambiaron las últimas capas completamente conectadas porque tenían tantas neuronas como clases a detectar, la red residual de 18 capas tiene 11 174 M parámetros, mientras que la red de 50 capas consta de 23 521 M parámetros. Este estudio es de diseño aplicativo. Como resultados se obtuvo que, ambas redes se comportaron notablemente bien en cada escenario y con

excelentes resultados logrados por ResNet50. Además, en cada experimento pudimos obtener niveles de recuerdo (recall) superiores al 97% en promedio, verificando así la solidez de los desempeños de clasificación al predecir si un frame sin patrones de neumonía COVID-19 pertenece a alguna de las clases consideradas, o no es representativo de un pulmón sano. En la validación se obtuvo en promedio un accuracy de 98%, una precisión de 97% y un recall de 96.5 %. El estudio concluye que el modelo utilizado basado en DL para detectar automáticamente neumonía por COVID-19 en las imágenes de LUS y calificar su gravedad nos da resultados innovadores, fiables y revolucionarios en comparación de otras investigaciones.

Según Federico Mento et al. (2021)²⁵, en su investigación “Deep learning applied to lung ultrasound videos for scoring COVID-19 patients: A multicenter study”, tuvieron como objetivo informar sobre el nivel de acuerdo entre los expertos de deep learning (DL) y ultrasonografía pulmonar (LUS, por sus siglas en inglés), al evaluar los datos correspondientes a videos de LUS en el cual se proporcionó, para cada frame de video, una puntuación y la segmentación semántica. Esta investigación evaluó un total de 314 879 frames, correspondientes a 1488 videos de ultrasonografía pulmonar adquiridos de 82 pacientes de la Fondazione Policlinico Universitario Agostino Gemelli (Roma, Italia) y de la Fondazione Policlinico San Matteo (Pavía, Italia). Todos los pacientes dieron positivo a COVID-19 según lo confirmado por la prueba de hisopo RT-PCR. Los pacientes fueron examinados siguiendo el protocolo basado en 14 áreas de escaneo. Todos los datos se adquirieron utilizando un transductor convexo, estableciendo una profundidad de imagen de 8 a 12 cm (según el paciente) y una frecuencia de imagen de 3.5 a 6.6 MHz (según el escáner). Todos los 1488 videos adquiridos fueron evaluados por médicos expertos, quienes asignaron una puntuación de 0 a 3 a cada video. Utilizaron dos algoritmos de deep learning diferentes: el primero etiquetó cada fotograma con una puntuación, y el segundo proporcionó una segmentación semántica. Como resultados se obtiene un porcentaje de acuerdo entre expertos en DL y LUS del 85.96% en la estratificación entre pacientes de alto riesgo de empeoramiento clínico y pacientes de bajo riesgo. El estudio concluye que estos resultados alentadores demuestran el potencial de los modelos DL para la

puntuación automática de datos LUS cuando se aplican a datos de alta calidad adquiridos de acuerdo con un protocolo de imágenes estandarizado.

Robert Arntfield et al. En el año 2020²⁶, en su investigación “Development of a deep learning classifier to accurately distinguish COVID-19 from look-a-like pathology on lung ultrasound”, se plantearon como objetivo conocer si la implementación de la ultrasonografía pulmonar (LUS, por sus siglas en inglés) podrían combinarse con técnicas de aprendizaje profundo para igualar o superar la especificidad diagnóstica a nivel humano entre imágenes de LUS patológicas de apariencia similar. Esta investigación usó 600 videos LUS (121 381 frames) de líneas B de 243 pacientes distintos, divididos en tres categorías: COVID-19, síndrome de dificultad respiratoria aguda (NCOVID) y edema pulmonar hidrostático (HPE). Se diseñó y entrenó una red neuronal convolucional sobre imágenes LUS con líneas B de diferentes etiologías. El rendimiento de diagnóstico de redes neuronales convolucionales (CNN, por sus siglas en inglés), fue validado con el 10% del conjunto de datos y luego se comparó con el de los médicos competentes en LUS encuestados. Como resultados se obtuvieron que el rendimiento de CNN entrenado en el conjunto de datos independientes mostró una capacidad para discriminar entre patologías COVID(AUC 1.0), NCOVID (AUC 0.934) y HPE (AUC 1.0). Esto fue significativamente mejor que la capacidad del médico (AUC de 0.697, 0.704, 0.967 para las clases COVID, NCOVID y HPE, respectivamente), $p < 0.01$. El estudio concluyó que un modelo de aprendizaje profundo puede distinguir patologías LUS de apariencia similar, incluido COVID-19, que los humanos no pueden distinguir. La brecha de rendimiento entre los humanos y el modelo sugiere que podrían existir biomarcadores subvisibles dentro de las imágenes de ultrasonografía, lo cual amerita una investigación multicéntrica.

Subhankar Roy et al. En el año 2020²⁷, en su investigación “Deep Learning for Classification and Localization of COVID-19 Markers in Point-of-Care Lung Ultrasound”, tuvieron como objetivo estudiar la aplicación de técnicas de deep learning (DL) para el análisis de imágenes de ultrasonografía pulmonar (LUS, por sus siglas en inglés). En el cual usó una base de datos italiana de ultrasonografía

pulmonar COVID-19 (ICLUS-DB), que actualmente incluye un total de 277 videos de LUS de 35 pacientes, correspondientes a 58 924 frames. De los 35 pacientes, 17 fueron confirmados positivos a COVID-19 mediante la técnica de hisopo (49%), 4 eran sospechosos de COVID-19 (11%) y 14 eran individuos sanos y asintomáticos (40%). Se diseña una red profunda, derivada de Spatial Transformer Networks, que predice simultáneamente la puntuación de gravedad de la enfermedad asociada a un frame de entrada y proporciona la localización de artefactos patológicos de una manera débilmente supervisada. Además, presentan un nuevo método basado en uninormas para la agregación eficaz de la puntuación de frames a nivel de video. Finalmente, comparan modelos profundos de vanguardia para estimar segmentaciones a nivel de píxel de biomarcadores de imágenes COVID-19. Como resultados en la experimentación de la segmentación semántica observamos que el uso de aumento en línea de imágenes y anotaciones en combinación con el conjunto de modelos, produce una gran ganancia de rendimiento sobre una U-Net de referencia, aumentando el coeficiente de Dice de 0.64 a 0.75 para la unión de marcadores COVID-19. Los experimentos en el conjunto de datos propuesto demuestran resultados satisfactorios en todas las tareas consideradas, el cual abre el camino para futuras investigaciones sobre DL para el diagnóstico asistido de COVID-19 a partir de datos LUS.

Jannis Born et al. En el año 2020²⁸, en su investigación “POCOVID-Net: Automatic Detection of COVID-19 From a New Lung Ultrasound Imaging Dataset (POCUS)”, tuvieron como objetivo cerrar la brecha existente por la falta de investigaciones relacionados con la detección automática de COVID-19 usando aprendizaje profundo en imágenes Point Of Care Ultrasound (POCUS); en el cual, usaron una muestra de 654 imágenes que fueron evaluados mediante el modelo propuesto. Propusieron una red neuronal convolucional que llamaron POCVID-Net para abordar la actual tarea de visión por computadora. Usaron la parte convolucional de VGG-16, y se usa del ajuste fino, en el cual fueron congelados varios parámetros quedando 2 392 963 entrenables y 12 355 008 no entrenables. Se cambia el tamaño de todas las imágenes a 224×224 . Se usaron 1103 imágenes (654 COVID-19, 277 neumonía bacteriana y 172 controles sanos), muestreados de 64 videos. Se obtuvo una precisión del 89% y, una precisión de

video del 92%. Para detectar COVID-19 en particular, el modelo funciona con una sensibilidad de 0.96, una especificidad de 0.79. El estudio concluyó en las sugerencias de posibles mejoras a POCOVID-Net. Primero, realizar inferencias directamente en los videos (por ejemplo, CNN temporales) en lugar del análisis de imagen basado en frames. En segundo lugar, se podría entrenar la red en grandes bases de datos usando imágenes ecográficas de diferentes regiones en vez de utilizar la base de datos de ImageNet. Además, los modelos generativos podrían ayudar a complementar los escasos datos sobre COVID-19.

Mohamed Loey, Florentin Smarandache, Nour Eldeen M. Khalifa, en el año 2020²⁹, en su investigación “Within the Lack of Chest COVID-19 X-ray Dataset: A Novel Detection Model Based on GAN and Deep Transfer Learning”, su objetivo fue diseñar una red neuronal profunda del tipo GAN para generar imágenes sintéticas para de esa manera aumentar la base de datos de entrenamiento para la red neuronal de detección. Para este estudio se recopiló 307 imágenes para cuatro tipos diferentes de clases. Las clases son COVID-19, normal, neumonía bacteriana y virus de la neumonía. En el diseño de la red neuronal se dividió la base de datos en un 90% para el GAN, mientras que el 10% se utiliza en la fase de prueba. Se optó por el uso de tres modelos de transferencia profunda (Alexnet, Googlenet y Resnet18). Como resultados del uso de los tres modelos se obtuvo: en el primer escenario, se usó Googlenet con 80.6% en la precisión de las pruebas. En el segundo escenario, se seleccionó Alexnet con un 85.2% en la precisión de las pruebas, mientras que en el tercer escenario que incluye 2 clases (COVID-19 y normal), se selecciona Googlenet, el cual alcanza a 100% en la precisión de las pruebas y el 99.9% en la precisión de la validación, por lo que será el principal modelo de transferencia profunda a utilizar. El estudio concluye que los modelos de aprendizaje lograron un porcentaje similar de precisión, memoria y métricas de puntuación F1, que refuerzan la decisión de investigación para elegir Googlenet, ya que logró la mayor validación.

¿Cuál es la precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a COVID-19?

1.2. IMPORTANCIA DE LA INVESTIGACIÓN

Actualmente en el contexto de la pandemia del SARS-CoV-2, la ultrasonografía pulmonar podría ser de gran ayuda, por su alta sensibilidad, su portabilidad, su bajo costo, no uso de radiaciones ionizantes y su fácil desinfección, como también por su gran utilidad en el diagnóstico, pronóstico, monitoreo, recuperación y la evaluación de las complicaciones que presentan estos pacientes³⁰. Para este procedimiento es de suma responsabilidad que el personal ecografista realice una correcta detección de los signos, más aún si la ultrasonografía es de carácter operador dependiente, el cual requiere el entrenamiento suficiente para una buena presunción diagnóstica.

El resultado obtenido de esta investigación ayudará a mostrar que tan efectivo puede ser el uso de la inteligencia artificial en la detección y segmentación de signos ecográficos sugerentes a COVID-19, también se evidenciará las limitaciones que se tiene al implementar estos modelos en imágenes médicas ultrasonográficas.

A su vez, evaluaremos que tan efectivo puede ser la síntesis de imágenes ecográficas pulmonares con la finalidad de poder aumentar el conjunto de datos de imágenes ecográficas de pulmón con la enfermedad de COVID-19, que en la actualidad son muy escasos.

La aplicación del deep learning en el análisis y pos procesamiento de imágenes podrían ayudar en el aprendizaje sobre ultrasonografía pulmonar; ya sea en alumnos, tecnólogos médicos en radiología, médicos radiólogos, médicos especialistas o médicos ultrasonografistas. Así mismo, podría ser una herramienta de apoyo al operador que realiza este estudio, de tal manera que pueda agilizar y facilitar el diagnóstico y el seguimiento, reduciéndose así el tiempo de exposición del mismo ³¹. También la utilidad que podría tener este tipo de tecnologías en servicios de telemedicina en lugares alejados donde no existe un profesional de la salud autorizado que realice la ecografía pulmonar.

Cabe resaltar que este proyecto no tiene fines médicos y en ningún caso trata de reemplazar al personal de la salud, sino más bien de difundir ciertas tecnologías como herramienta de apoyo para facilitar el diagnóstico, el seguimiento, pronóstico, monitoreo, así como también la enseñanza de la evaluación COVID-19 mediante ultrasonografía.

Finalmente, este trabajo contribuirá a la actualización del conocimiento científico y servirá como incentivo a la investigación en el procesamiento de imágenes médicas en radiología.

1.3. OBJETIVOS

1.3.1 OBJETIVO GENERAL

- Evaluar la precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a COVID-19.

1.3.2 OBJETIVOS ESPECÍFICOS

- Identificar los hiperparámetros adecuados para el correcto entrenamiento del modelo de deep learning de síntesis de imágenes.
- Identificar los hiperparámetros adecuados para el correcto entrenamiento del modelo de deep learning de detección y segmentación de imágenes.
- Evaluar los resultados de la validación del modelo de deep learning de síntesis de imágenes.
- Evaluar los resultados de la validación del modelo de deep learning de detección y segmentación de imágenes.

1.4. BASES TEÓRICAS

1.4.1 BASE TEÓRICA

NEUMONIA POR COVID -19

La enfermedad del COVID-19, es una infección viral causada por el virus SARS-CoV2, teniendo como genoma al ARN, su tamaño oscila entre los 80 a 120 nm de diámetro, pertenecen a la familia Coronaviridae, algunas cepas de esta familia de virus infectan a los humanos, que provocan desde un leve resfrío hasta infecciones graves, como es el MERS. La nueva enfermedad por SARS-CoV2 apareció en Wuhan (China) en diciembre del año 2019 y el 11 de marzo del 2020 fue declarada como pandemia por la Organización Mundial de la Salud (OMS)³².

- **CLÍNICA**

El periodo de incubación oscila entre 4 a 7 días, mientras que el 95% de casos sintomáticos ya muestran sus síntomas a partir de 11.7 días. Por lo general la enfermedad se desarrolla de forma asintomática (80%) o con sintomatología leve de tos leve y malestar general, mientras que el 15% presenta fiebre, fatiga, tos seca y sin desarrollo de neumonía. El 5% desarrolla un cuadro severo con fiebre constante, tos, dificultad para respirar y con neumonía. La posible muerte y la falla multiorgánica se dan en el 3 a 4% de los afectados.

- **FASES DE EVOLUCIÓN**

Durante la primera semana (Fase 1), la RT-PCR es positiva, mientras que la serología IgM/IgG es positiva desde el día 6. Por otro lado, en la nombrada fase pulmonar que es la fase 2, que inicia el día 15, se encuentra la etapa donde hay complicación más neumonía, mostrando signos de consolidación pulmonar bilateral y periférica. La fase inflamatoria o fase 3, se presenta en los días 10 a 15, pero no en todos los casos, cuando sí se presenta es en pacientes inmunodeprimidos y pacientes con más de 65 años de edad, ya sea con otros tipos de factores de riesgo, resultando una desregularización dando una respuesta inflamatoria agravada^{33, 34}.

- **DIAGNÓSTICO**

El diagnóstico de referencia de la enfermedad por coronavirus (COVID-19) es por detección molecular de SARS-CoV-2; es decir, reacción en cadena de la polimerasa cuantitativa con transcriptasa inversa (RT-PCR) o secuenciación de genomas virales, teniendo una sensibilidad del 85% al 90% considerada el estándar de oro, aunque en los falsos negativos la secuencia es alta³⁵. Asimismo, hay exámenes de radiografía y pruebas rápidas serológicas, que se utilizan en algunos países como complemento al diagnóstico molecular.

PRUEBAS RADIOLÓGICAS PARA LA EVALUACION DE COVID-19

- **RADIOGRAFÍA DE TÓRAX**

Es el estudio de imagen de rutina en los pacientes con sospecha clínica o que hayan dado positivo al COVID-19, debido por su disponibilidad, utilidad y bajo coste; a pesar de tener menos sensibilidad que la tomografía computada³⁶. Los principales hallazgos en el parénquima pulmonar son la opacidad intersticial, opacidad alveolar, opacidad intersticio alveolares y opacidades intersticio alveolares³⁷⁻⁴⁰.

- **TOMOGRAFIA COMPUTADA**

La tomografía computada es considerada como una prueba de diagnóstico de imagen con una alta sensibilidad reportada del 97% para la detección del COVID-19. Algunas investigaciones sugieren que los hallazgos de la tomografía de tórax pueden anteceder la positividad de la RT-PCR. La tomografía computada es particularmente útil para orientar el manejo de circunstancias complejas, para descartar diagnósticos alternativos y pacientes con deterioro clínico.

Existen debates y discrepancias respecto de utilizar la tomografía como una modalidad de diagnóstico, dado que, aunque tenga una alta sensibilidad, posee una especificidad baja de 25%, al sobreponer los hallazgos de la enfermedad por coronavirus (COVID-19) a otros tipos de infecciones virales como el

SARS, el MERS o la gripe porcina (H1N1). Por esta razón, varias sociedades de radiología, han considerado como técnica de segunda línea a la tomografía⁴¹.

La afectación del COVID-19 consiste en una distribución periférica como la afectación subpleural con opacidades múltiples y bilateral^{42,43}. También en fases tempranas, sobretodo puede haber opacidades pulmonares en “vidrio deslustrado” unilaterales. Existe una predilección en la afectación de los lóbulos inferiores aun cuando todos los segmentos del pulmón estén involucrados⁴⁴.

Los hallazgos primordiales que se encuentran son: la reticulación periférica, las opacidades pulmonares en “vidrio deslustrado”, “patrón en empedrado” y consolidación pulmonar⁴⁵.

- **ULTRASONOGRAFÍA EN LA EVALUACIÓN DE PACIENTES COVID-19**

La ecografía pulmonar (LUS, por sus siglas en inglés) ha surgido como una técnica de imágenes para la modalidad de primera línea (detección) con bajos costos y disponibilidad generalizada en la enfermedad COVID-19. Los hallazgos de LUS descritos para la neumonía por COVID-19 son signos de artefactos intersticiales únicos o confluentes, pequeñas regiones pulmonares hiperecoicas, líneas pleurales engrosadas y consolidaciones.

La realización de la ultrasonografía pulmonar es con transductores de 2–5 MHz (baja frecuencia) del tipo convexo o lineales, incluso sectoriales, explorando mejor la profundidad torácica de 6 -10cm. Teniendo en cuenta la actual pandemia se consideran las medidas de bioseguridad, como usar equipos desechables de protección personal una sola vez y cobertores de un solo uso para sondas de ultrasonido, además de una limpieza como también de una desinfección antiviral que sea antes de y después de cada uso.

“Point Of Care Ultrasound” (POCUS) se realiza con el paciente en una posición semiacostada o en decúbito supino, se trazan las líneas de referencia anatómica; línea axilar anterior, línea axilar posterior y una línea transversal a

estas que pasa por debajo del pezón. Los espacios intercostales tanto inferior como superior de las regiones torácicas (lateral, anterior y posterior) derecha e izquierda se examinan, resultando 12 áreas de investigación⁴⁶.

Los hallazgos característicos son: línea pleural irregular con engrosamiento de la misma, líneas B que pueden ser multifocales, confluentes y focales, consolidaciones en diferentes patrones como translobar, no translobar, multifocal pequeño con ocasionales broncogramas móviles aéreos, son pocos comunes los derrames pleurales. En fase de recuperación y en pacientes sanos aparecen las líneas A⁴⁷.

La ultrasonografía (US) y la tomografía computarizada (TC) desde un enfoque técnico brindan valoraciones totalmente diferentes, ya que la tomografía examina el volumen del parénquima pulmonar, en cambio la ultrasonografía proporciona un mapa de densidad superficial; por lo que la concordancia diagnóstica entre la tomografía y la ecografía pulmonar desde el punto de vista de puntuaciones no a menudo fue adecuada.

Habiendo explicado la utilidad de la ecografía pulmonar en la predicción de complicaciones de la neumonía por COVID-19, la ultrasonografía parece ser un fuerte predictor de mortalidad hospitalaria y juega un papel clave en la estratificación de riesgo de los pacientes con la enfermedad por coronavirus (COVID-19)⁴⁸⁻⁵¹.

INTELIGENCIA ARTIFICIAL

La inteligencia artificial (IA) es un método computacional que intenta imitar, la capacidad cognitiva humana para resolver problemas de la vida real y que han desafiado la solución utilizando técnicas computacionales convencionales. La esencia de las técnicas de IA para resolver problemas es aprender mediante ejemplos de datos de entradas y salidas, o solo con datos de entrada como en el caso de los modelos no supervisados, con los que encontrará relaciones funcionales, incluso si existen relaciones desconocidas o de significado difícil de explicar⁵².

- **MACHINE LEARNING (APRENDIZAJE AUTOMATICO)**

Es una rama de la inteligencia artificial donde las máquinas aprenden a reconocer patrones y hacer predicciones gracias al uso de una gran cantidad de datos y el entrenamiento⁵³.

- **DEEP LEARNING (APRENDIZAJE PROFUNDO)**

Es una rama de la inteligencia artificial y es parte emergente del aprendizaje automático, ya que al aumentar la densidad de capas de redes neuronales se convierte a un aprendizaje profundo⁵⁴.

Clasificación: En el aprendizaje automático, la clasificación se refiere a un problema de modelado predictivo donde se predice una etiqueta de clase para un ejemplo dado de datos de entrada. Los tipos de clasificación más conocidas son: clasificación binaria y clasificación de clases múltiples⁵⁵.

Segmentación: Es un problema del campo de la visión artificial, se basa en la subdivisión de las partes u objetos de interés de una imagen⁵⁶.

Pytorch: Es una de las bibliotecas más utilizadas en investigación de deep learning aplicados a visión artificial y al procesamiento de lenguaje natural, es de código abierto. Fue desarrollada por el laboratorio Facebook Artificial Intelligence Research (FAIR)⁵⁷.

Python: Es un lenguaje de programación para ordenadores, aparte de su funcionalidad principal, mediante los módulos o paquetes adquieren capacidades numéricas, científicas, gráficas, etc⁵⁸.

PERCEPTRÓN Y REDES NEURONALES

En 1957 Frank Rosenblatt inventó el perceptrón, definiéndose como una neurona artificial, unidad mínima de una red neuronal, el cual fue inspirado en la neurona biológica.

Varios perceptrones forman una red neuronal y funcionan tomando datos a través de varias entradas, el cual se ponderan y se realiza una suma ponderada, luego pasan a través de una función de activación, el cual hará que la salida no sea lineal, de lo contrario tendría el comportamiento de una regresión lineal. El comportamiento no lineal de la función de activación proporciona a las redes profundas la capacidad para aprender funciones complejas.

Las funciones de activación también son importantes en el ajuste de los gradientes, y convierten a los valores de salida en probabilidades, las más utilizadas son las funciones de activación sigmoide tanh, ReLU y Leaky ReLU.

El proceso de entrenamiento de una red neuronal tiene la finalidad de que la salida de nuestra red neuronal se parezca más a la salida real, para ello debe modificar sus pesos. La diferencia entre la salida de nuestra red neuronal y la salida real se puede cuantificar mediante la función de coste, a mayor coste peor es la predicción, por lo que para reducir el coste y mejorar la predicción, la red neuronal va a reenviar el error hacia atrás mediante un proceso llamado backpropagation (propagación hacia atrás) con la finalidad de modificar los pesos para así poder disminuir el error y obtener una mejor predicción.

El aprendizaje por parte de la red neuronal se detiene cuando el error no se puede reducir más. El proceso de formación aprende las características (patrones) durante la formación.

Descenso de gradiente

Es el método para optimizar la predicción del modelo. Este algoritmo minimiza la función de pérdida (error), mediante la actualización de pesos de forma iterativa. Para conseguir descender al punto mínimo de la gráfica de la función de pérdida, en cada paso necesitamos determinar la dirección del paso (gradiente) y el tamaño del paso (tasa de aprendizaje). Cuando no se toman todos los datos de entrenamiento para calcular el gradiente, sino solo una muestra aleatoria de ella, hablamos del descenso del gradiente estocástico, este es más rápido y el más utilizado actualmente. Una de las variaciones de

este algoritmo que más se utiliza es el ADAM (Adaptive moment estimation).

El desajuste (underfitting): Sucede cuando el modelo no logra ajustarse a los datos de entrenamiento debido a su simplicidad.

El sobreajuste (overfitting): Ocurre cuando el modelo es muy estructurado y se ajusta demasiado a los datos, al punto de memorizarlos perdiendo la capacidad de aprender. Esto se puede observar cuando se consiguen buenos resultados en el entrenamiento, pero funciona mal en el conjunto de validación.

Para evitar el sobreajuste se utilizan principalmente las técnicas de Retiro (Dropout), La normalización por lotes (Batch normalization) y Normalización L1 y L2.

Redes neuronales convolucionales

Son una variante del perceptrón multicapa, estas usan filtros convolucionales que son adecuadas para procesar imágenes. Este tipo de arquitecturas está conformado por capas de redes neuronales, convolucionales y de agrupación (pooling).

Convolución

Es la operación matemática que transforma dos funciones en una tercera función; en el tratamiento de imágenes, dos matrices a una tercera matriz. La convolución usa un kernel (sub matriz) para filtrar los valores del píxel de la imagen. Los filtros aprendidos son los que detectarán patrones en las imágenes.

En el entrenamiento de esta arquitectura cada capa convolucional irá aprendiendo características más complejas conforme aumenta la profundidad de la red.

Generalmente estas arquitecturas convolucionales van acompañadas de capas de agrupación (max pooling) que permiten reducir el tamaño de la imagen

mediante muestreo⁵⁹.

AUMENTACIÓN DE DATOS (DATA AUGMENTATION)

Son técnicas para aumentar el conjunto de datos mediante el uso de ciertas variaciones en los datos. Estas técnicas son útiles para optimizar el rendimiento de los modelos de aprendizaje automático⁶⁰.

TRANSFERENCIA DE APRENDIZAJE

En inglés, Transfer Learning. Son un conjunto de técnicas que permiten transferir conocimiento desde modelos pre-entrenados.

Los modelos de aprendizaje profundo necesitan bastante poder computacional y un gran tiempo de cálculo. Estas técnicas de conocimiento transferido, permiten ahorrar recursos y tiempo, obteniendo resultados óptimos⁶¹.

SÍNTESIS DE IMÁGENES MEDIANTE REDES ADVERSARIAS GENERATIVAS

Un tipo de modelo generativo son las redes adversarias generativas (GAN, por sus siglas en inglés), y están conformadas por una red generadora y una red discriminadora, que compiten entre sí. El generador se encarga de generar imágenes falsas, mientras que el discriminador aprende a diferenciar entre imágenes reales o falsas.

El generador se optimizará al punto de generar imágenes que son difíciles de diferenciar para el discriminador⁶².

Con el desarrollo del aprendizaje profundo, su uso para la síntesis de imágenes médicas se ha incrementado dramáticamente⁶³⁻⁶⁵. Las redes GAN son de mucha utilidad en las aplicaciones médicas y pueden mejorar los procesos de clasificación, segmentación, detección o síntesis de imágenes⁶⁶.

Deep Convolutional Generative Adversarial Networks (DCGAN)

Es una arquitectura GAN que usa capas de convolución y deconvolución, es una

de las primeras GAN muy efectivas para el procesamiento con imágenes. La estructura del generador DCGAN está formada por la entrada de un ruido gaussiano, y por un conjunto de bloques con capas convolucionales transpuestas de dos dimensiones (Conv2DTranspose) y capas de normalización. En cada bloque de capas también hay funciones de activación ReLU, excepto la última que cuenta con una función de activación tanh. La estructura del discriminador está conformada por bloques y cada uno cuenta con capas convolucionales de dos dimensiones (Conv2D), una capa de normalización por lotes y una capa de abandono y funciones de activación LeakyReLU. Finalmente, se agregan una capa de aplanamiento (Flatten), una capa completamente conectada (Fully connected) y una función de activación sigmoide⁶⁷.

DETECCIÓN Y SEGMENTACIÓN DE IMÁGENES MEDIANTE MASCARA R-CNN

Máscara R-CNN

Mask Regional Convolutional Neural Network (Mask R-CNN) es una técnica utilizada para la detección de objetos basada en Faster R-CNN⁶⁸.

Esta arquitectura consiste en la utilización de una red neuronal profunda con el fin de hacer segmentación de instancias para cada cuadro delimitador utilizando una capa totalmente conectada (FC, por sus siglas en inglés).

Mask R-CNN, está conformado por 3 partes:

La primera parte es la columna vertebral, una red neuronal convolucional (generalmente ResNet, VGG o ConvNet) con la finalidad de obtener las características de la imagen.

La segunda parte es una red neuronal denominada RPN (Region Proposal Network), y es la encargada de recibir el mapa de características generado por la red anterior para encontrar las regiones de interés (RoI); es decir, las áreas muy probables de contener los objetos.

La tercera parte contiene una capa FC y una red totalmente convolucional (FCN,

por sus siglas en inglés), generando 3 salidas, el cual se encargará de los cuadros delimitadores, clasificación y máscaras de segmentación⁶⁹.

HIPERPARAMETROS EN DEEP LEARNING

Son las variables que podemos modificar en las redes neuronales y sirven para optimizar la precisión del aprendizaje de los pesos y sesgos.

Número de capas de redes neuronales: Son las capas de redes ocultas que se encuentran entre la capa de entrada y la capa de salida.

Abandonar (Dropout): Técnica para obviar ciertas neuronas de forma aleatoria.

Función de activación: Es una función que determina si una neurona se activa o no, esto permite que se modele el aprendizaje y que nuestro modelo obtenga salidas no lineales, aprendiendo funciones complejas.

Tasa de aprendizaje: Establece la velocidad de aprendizaje de nuestra red, mediante la actualización de pesos.

Beta: Parámetro del optimizador que permite promediar de las últimas iteraciones y los gradientes más antiguos se olvidan, permitiendo direccionar mejor el aprendizaje disminuyendo el error.

Impulso (Momentum): Permite direccionar el siguiente paso en la gráfica de la función del error gracias a los pasos anteriores.

Número de épocas: Es la cantidad de veces que nuestro conjunto de datos de entrenamiento pasa a través de la red.

Tamaño del lote: Es el número de submuestras de nuestro conjunto de datos que pasa en cada época.

MÉTRICAS DE EVALUACIÓN EN MODELOS DE DEEP LEARNING

Son medidas que nos permite evaluar qué tanto aprende el modelo durante

entrenamiento. Por lo general se suele usar la función de pérdida (loss function) y el accuracy (exactitud) para evaluar la convergencia del modelo.

Exactitud (Accuracy): Es utilizada para ver la proporción de predicciones correctas en relación al total de muestras evaluadas. $(TP+TN)/(TP+TN+FP+FN)$

Sensibilidad o Recall: Es utilizada para ver que tan bien se puede detectar la enfermedad (verdaderos positivos), en personas que padecen de la enfermedad. $TP/(TP+FN)$

Especificidad: Se utiliza para calcular la proporción entre los resultados negativos en personas que no tienen la enfermedad. $TN/(TN+FP)$ ⁷⁰.

En las redes generativas adversarias una de las métricas más utilizadas para evaluar la calidad de imágenes generadas es la distancia inicial de Fréchet (FID); para estas redes, la exactitud, como la función pérdida sirven para evaluar la estabilidad y la convergencia durante el entrenamiento.

Distancia inicial de Fréchet

La puntuación FID (Fréchet Distance of Inception) es una de las métricas más utilizadas en la evaluación de modelos generativos y su puntuación es en función de la calidad de las imágenes generadas. A menor puntaje, mejor calidad de imagen y diversidad.

$$FID = \|\mu_r - \mu_g\|^2 + Tr(\Sigma_r + \Sigma_g - 2(\Sigma_r \Sigma_g)^{1/2})$$

μ_r y μ_g : Son la media de las imágenes reales y generadas.

Σ_r y Σ_g : Son la covarianza de las imágenes reales y generadas.

Tr : es la traza, suma de elementos de una diagonal.

Esta fórmula explica cómo el FID toma las distribuciones de las imágenes reales y generadas y realiza una comparación entre su media y su covarianza⁷¹.

Intersección sobre unión (IoU): También conocido como el índice Jaccard. Indica la división entre el área superpuesta de la predicción y la verdad básica con el área de la unión de la predicción y la verdad básica. Esta métrica varía de 0 a 1 (0 a 100 %), un valor de IoU más grande refleja una detección o segmentación más precisa⁷².

AP (Average Precisión): Es una de las métricas de evaluación que se utilizaron en el conjunto de datos de Microsoft Common Objects in Context (MSCOCO), se basa en el promedio de varios IoU (valores IoU que permitan considerar una coincidencia positiva), el AP mencionado en la página oficial de MSCOCO es AP [.50: .05: .95], es decir, IoU con valores de 0.50, 0.55, 0.60, 0.65 ... 0.95, que serán promediados para obtener el valor de AP. Los valores AP 50 y AP 75 se utilizan para indicar la precisión promedio en el nivel de IoU = 0.5 y IoU = 0.75, respectivamente.⁷³

1.4.2 DEFINICIÓN DE TÉRMINOS

Deep learning: Es uno de los métodos de aprendizaje de la inteligencia artificial, llamado aprendizaje profundo debido a la densidad de capas profundas de redes neuronales que contiene⁵⁴.

Síntesis de imágenes: Área de estudio del procesamiento de imágenes y visión artificial, el cual consiste en la creación de imágenes artificiales que sean muy parecidas a las reales⁶³.

Detección y segmentación de imágenes: Áreas de estudio del campo del procesamiento de imágenes en visión artificial que consiste en reconocer un objeto, generar la separación entre objeto de interés y el fondo^{55,56}.

Precisión: Término que hace referencia a la precisión predictiva, y está conformada por varias métricas para evaluar los modelos de deep learning⁷⁴.

Ultrasonografía pulmonar: Procedimiento imagenológico basado en la ultrasonografía de la región pulmonar⁴⁶.

1.4.3 FORMULACIÓN DE LA HIPÓTESIS

La presente investigación no presenta hipótesis.

Según José Supo, toda investigación puede tener o no hipótesis, esto va a depender del enunciado del estudio (formulación del problema), si este es una proposición, el cual se puede afirmar o negar, la investigación va a tener hipótesis⁷⁵. La formulación del problema de la presente tesis no busca encontrar una respuesta afirmativa o negativa; ni mucho menos, comparar modelos o resultados de deep learning, como ocurre en los estudios con prueba de hipótesis; sino más bien, esta investigación busca encontrar valores numéricos (proporciones), dichos valores se obtienen de las métricas de evaluación para modelos de deep learning.

CAPITULO II:
MÉTODOS

2.1. DISEÑO METODOLÓGICO

2.1.1 TIPO DE INVESTIGACIÓN

La presente investigación corresponde al enfoque cuantitativo, ya que utilizamos mediciones numéricas y un análisis estadístico; y de nivel predictivo porque buscamos predicciones a partir del modelo de deep learning con el cual se realizará detección, clasificación y segmentación en función a los hiperparámetros y los datos entregados⁷⁵.

2.1.2 DISEÑO DE LA INVESTIGACIÓN

Según Sampieri esta investigación es de diseño experimental⁷⁶, ya que hubo intervención sobre los hiperparámetros de la arquitectura de deep learning (variable independiente), para luego evaluar las métricas (variable dependiente). Es retrospectivo porque la recolección de datos (exámenes ecográficos) fue ejecutada por otras personas en tiempo pasado⁷⁵.

2.1.3 POBLACIÓN

323 frames de ultrasonografía pulmonar correspondiente al conjunto de datos de validación de un dataset de acceso abierto en la web (https://github.com/BorgwardtLab/covid19_ultrasound)²⁷, recopilados por Jannis Born y colaboradores, proveniente de donaciones de hospitales de China, Alemania, Reino Unido, Italia y Canadá, así como de recursos disponibles públicamente en la web.

2.1.4 MUESTRA y MUESTREO

Tamaño Muestra: está conformado por la población de 323 frames de ultrasonografía pulmonar de un dataset de acceso abierto.

Muestreo: No se usará (muestra censal).

2.1.4.1 CRITERIOS DE INCLUSIÓN

- Exámenes ecográficos pulmonares etiquetados con COVID-19.

- Exámenes ecográficos pulmonares que no presentan demasiado ruido.
- Exámenes ecográficos pulmonares realizados con diferentes transductores.
- Exámenes ecográficos pulmonares que no están pixeleados.

2.1.4.2 CRITERIOS DE EXCLUSIÓN

- Exámenes ecográficos pulmonares que presentaban borrosidad.
- Exámenes ecográficos pulmonares que se encuentren dañados.
- Exámenes ecográficos pulmonares que no tengan el permiso de libre uso.
- Exámenes ecográficos pulmonares que no muestren signos sugerentes de COVID-19.

2.1.5 VARIABLES

- Uso del Deep Learning.
- Síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid- 19

2.1.6 TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Técnica: Se utilizará la observación de cada evento durante la experimentación.

Instrumento: Se utilizará la ficha de recolección de datos donde se volcará la información producto de la experimentación (ANEXO N 1).

La ficha de recolección de datos, está conformado por dos secciones:

- La primera sección corresponde al registro de los hiperparámetros que serán utilizados en el entrenamiento del modelo de deep learning de síntesis de imágenes ecográficas con signos sugerentes a COVID-19, y también el registro de las métricas de evaluación.

- La segunda sección corresponde al registro de los hiperparámetros que serán utilizados en el entrenamiento del algoritmo de deep learning para detección y segmentación de signos ecográficos sugerentes a COVID-19, y también el registro de sus métricas de evaluación para ese modelo de deep Learning.

2.1.7 PROCEDIMIENTOS Y ANÁLISIS DE DATOS

Una vez que el proyecto de investigación fue revisado y aprobado mediante Resolución Decanal (RD), se dio inicio a la ejecución del proyecto.

El desarrollo de esta investigación se realizó bajo la asesoría de un experto en deep learning y en función al “Checklist for Artificial Intelligence in Medical Imaging (CLAIM)”, el cual sirve de guía para la investigación en el campo de la inteligencia artificial aplicado a las imágenes médicas, con el fin de promover una comunicación científica clara y reproducible⁷⁷

Se hizo la selección del conjunto de datos de los estudios ecográficos de pacientes COVID-19 de acceso libre en la web, compartidos por Jannis Born et al, en su investigación “POCOVID-Net: Automatic Detection of COVID-19 From a New Lung Ultrasound Imaging Dataset (POCUS)”²⁷.

El conjunto de datos consiste en 202 videos + 59 imágenes de exámenes de ultrasonografía pulmonar provenientes de transductores lineales, sectoriales y convexos, de pacientes que presentaban la enfermedad COVID-19, con signos ecográficos sugerentes de la enfermedad que fueron verificados por médicos especialistas y con confirmación por medio de la prueba estándar (RT-PCR). El conjunto de datos compartido en dicha web pertenecía a pacientes de los países de Canadá, Italia y China; por lo tanto, pertenecen a diferentes modelos de ecógrafos.

Con un experto en ultrasonografía se realizó la selección de los exámenes ecográficos teniendo en consideración los criterios de inclusión y exclusión.

Los signos ecográficos que se consideraron en esta investigación fueron:

- Signos de línea pleural anormal: Línea pleural irregular y engrosada.

- Líneas B: líneas B continuas y pulmón blanco.
- Consolidación: Signos a nivel de parénquima pulmonar, broncograma aéreo, consolidación sub pleural y derrame pleural con consolidación (signo raro).

Se realizó la extracción de frames de cada video de ultrasonografía, haciendo la selección de 1 892 imágenes que contenían signos sugerentes de COVID-19.

Se obtuvo 1 126 instancias con líneas B, 1 436 instancias con signos de línea pleural anormal y 933 instancias de consolidaciones.

ENTORNO DE DESARROLLO

El lenguaje de programación utilizado para el desarrollo de la investigación fue Python versión 3.6, también se utilizaron las librerías de código abierto de cálculo matricial, visualización de gráficas y procesamiento de imágenes: numpy 1.21.6, matplotlib 3.2.2 y openCV 4.6.0, respectivamente. También se utilizó PyTorch 1.12. como framework de deep learning. El entrenamiento del modelo se realizó en el entorno de Google Colaboratory, el cual es una herramienta web de la compañía Google que permite escribir y ejecutar código de programación. Utilizamos el plan gratuito de esta plataforma con el uso de un GPU Tesla T4 de 16 Gigabytes, memoria RAM de 12, 68 Gigabytes y un disco duro de 78,19 Gigabytes.

PROCESAMIENTO DE DATOS

Los 1 892 frames del conjunto de datos pasaron por un proceso de redimensión a una matriz cuadrada, con el fin de disminuir los bordes negros para facilitar la homogenización de las imágenes provenientes de diferentes transductores, 256x256 la síntesis de imágenes y de 512x512 para la detección y segmentación.

A todo el conjunto de datos se le realiza la normalización, el cual es un proceso para cambiar los valores de los píxeles, de [0, 255] a [0, 1], con ello se reduce la asimetría entre valores y se consigue un mejor aprendizaje del modelo de deep learning

Para la síntesis de imágenes, se utilizó la aumentación de datos (Data augmentation) para aumentar el conjunto de datos inicial. Las técnicas de aumentación de datos fueron el brillo (brightness), contraste(contrast), translación(translation) y recorte (cutout).

Para la parte de detección y segmentación se utilizó los 1 892 frames iniciales y también aplicamos la técnica de aumentación de datos para incrementar nuestro conjunto de datos, de esa manera suministramos más variedad al conjunto de datos para obtener mejor precisión de la detección y segmentación, las técnicas usadas fueron el brillo (brightness), contraste(contrast), rotación(Rotation) y volteo (Flip).

Estas técnicas de normalización y aumentación de datos se encuentran dentro del código de cada modelo de deep learning, alojados en la página oficial de Pytorch.

ARQUITECTURA DE DEEP LEARNING PARA SINTESIS DE IMAGENES

Se realizó una búsqueda de un modelo de generación de imágenes que use redes neuronales convolucionales, use poco poder computacional, sea de libre acceso y que no tenga mucha complejidad, el DCGAN se acomodó a estos requisitos y se encuentra disponible en la página de Pytorch⁷⁶.

La arquitectura original fue modificada debido a que utilizamos imágenes con una matriz más grande que del ejemplo publicado en la web oficial. Al generador se agregaron 02 bloques conformadas por una capa de convolución transpuesta (nn.ConvTranspose2d), 01 de normalización (nn.BatchNorm2d) y 01 activación ReLU (nn.ReLU); mientras que al discriminador se le agregó también dos bloques conformadas por una capa de convolución (nn.Conv2d), 01 de normalización (nn.BatchNorm2d) y una activación Leaky ReLU (nn.LeakyReLU). Por lo tanto, el generador estuvo compuesto por 7 bloques, cada uno con una capa de convolución transpuesta, normalización y función de activación ReLU, con excepción del último bloque que solo cuenta con una capa de convolución transpuesta y una función tanh (nn.Tanh()). Las dimensiones de

los bloques del generador son de 4x4x512, 8x8x256, 16x16x128, 32x32x64, 64x64x32, 128x128x16 y 256x256x1. El discriminador está conformado también por 7 bloques, cada uno con una capa convolucional, 01 de normalización y una función de activación Leaky ReLU, con excepción de la última capa que solo cuenta con una capa convolucional y una función sigmoide (nn.Sigmoid()). La dimensión de los bloques del discriminador es de conformación inversa al del generador (256x256x1, 128x128x16, 64x64x32, 32x32x64, 16x16x128, 8x8x256 y 4x4x512). Las modificaciones de la arquitectura se muestran en la FIGURA 1 y 2.

Otras modificaciones fueron en la entrada del generador, ya que se utilizó el tamaño del vector de ruido de 256, los tamaños del vector de características del generador y del discriminador fueron de 16, el número de canales fue 01 porque trabajamos con imágenes en escala de grises.

ENTRENAMIENTO DEL MODELO DCGAN

Se utilizó el 83% del total del conjunto de datos obtenidos después del procesamiento de imágenes, luego se agrupó en una sola carpeta y las introducimos en la arquitectura DCGAN para la síntesis de imágenes. Los hiperparámetros que modificamos para esta investigación fueron el número de épocas, el Batch size y los parámetros del optimizador para el aprendizaje como la tasa de aprendizaje (Learning rate) y el valor Beta. Realizamos pruebas de ensayo y error probando con diferentes hiperparámetros, usando como guía el comportamiento de la exactitud (accuracy) y la función de pérdida (Loss function), también evaluamos la arquitectura GAN con la métrica distancia inicial de Frechet (FID) para evaluar la calidad de las imágenes generadas⁷⁷, se utilizó un código de programación para el cálculo del FID con la configuración de dimensionalidad de 768, debido a que el conjunto de datos que se utilizó fue menor de 2048 imágenes. La documentación y el código para el cálculo del FID se encuentra disponible en: <https://github.com/mseitzer/pytorch-fid>⁷⁸.

El diagrama de la entrada y la salida de los datos de la red DCGAN se pueden ver en la Figura 3.

ARQUITECTURA DE DEEP LEARNING PARA DETECCION Y SEGMENTACION DE IMAGENES

La elección del modelo Mask R-CNN se hizo por los mismos criterios de selección del modelo GAN, por su mayor velocidad para detección en tiempo real de videos y porque muestra un porcentaje que nos indica la confiabilidad de dicha detección, lo cual se acomodaba a la investigación.

El modelo Mask R-CNN, se usó mediante la plataforma Detectron2, desarrollada por los programadores de Meta (antiguamente FACEBOOK), y que se encuentra disponible de acceso libre⁷⁹.

Para el entrenamiento y evaluación del modelo Detectron2, al igual que Mask R-CNN, se requiere que el conjunto de datos se encuentre etiquetado según las clases a detectar y que dicho conjunto de datos se ubique en dos carpetas, uno de entrenamiento y otro de validación.

El etiquetado de las imágenes consistió en la segmentación manual según el tipo de signo ecográfico a evaluar. Con la ayuda de un experto en la evaluación de pacientes COVID-19 mediante ecografía pulmonar, se realizó la segmentación manual de los signos sugerentes a COVID-19 en las imágenes ecográficas; a su vez, un segundo experto evaluó las segmentaciones realizadas para verificar si la segmentación corresponde al signo segmentado, y también si es que cada segmentación encierra al signo que se quiere segmentar.

La herramienta utilizada para la segmentación fue el VGG Image Annotator (VIA), un software dedicado de anotación manual que se encuentra disponible de acceso libre en la web⁸⁰. Al finalizar la segmentación con esta herramienta, se exporta el registro de segmentación e un archivo JSON (JavaScript Object Notation), el cual es un archivo dedicado a estructurar datos en modo de texto y sirve en el intercambio de información.

Usamos la técnica de transferencia de aprendizaje de la red pre entrenada Mask R-CNN - Resnet-50, el cual fue capacitada con el conjunto de imágenes de Common Objects in Context (COCO), con esta técnica congelamos varios

pesos de la red neuronal de Resnet y agregamos las últimas capas para entrenarlas con nuestras imágenes.

El tamaño de entrada para imágenes fue de 512x512, se utilizó por conveniencia imágenes en BGR (3 canales), ya que la red pre entrenada que utilizamos se encontraba con la distribución de 3 canales.

ENTRENAMIENTO DEL MODELO DE DETECCIÓN Y SEGMENTACIÓN

La división del conjunto de datos fue del 83% total para el entrenamiento del modelo de deep learning, mientras que para el test se le asignó el 17%, cada carpeta con un archivo .json en la cual se encuentra el registro de la segmentación y etiquetados de cada imagen.

Los hiperparámetros que modificamos para esta investigación fueron el número de iteraciones, el Batch size y la tasa de aprendizaje.

Mediante pruebas de ensayo y error se realizó la modificación de los hiperparámetros del modelo de deep learning para la obtención de resultados óptimos, teniendo como guía las métricas de pérdida (Loss) y la exactitud (Accuracy). El diagrama de la entrada y la salida de los datos de la red Detectron2 (Mask R-CNN) se pueden ver en la Figura 4.

Para evaluar la detección y segmentación, debido a que nuestro modelo está pre-entrenado con el conjunto de datos MSCOCO y nuestras segmentaciones se hicieron en ese formato, usamos las métricas AP (Average Precisión), el cual se basa en diferentes valores de umbral de IoU (AP, AP50 y AP75).

Los datos obtenidos se transcribieron en nuestra ficha de recolección de datos.

2.1.8 CONSIDERACIONES ÉTICAS

- El conjunto de datos que se utilizó ya contaba con la eliminación de alguna información personal del paciente o del centro donde se obtuvieron las

imágenes, manteniendo de esa manera el anonimato y confidencialidad a fin de respetar el principio de la autonomía.

- Del conjunto de exámenes ecográficos utilizados para la realizar esta investigación, solo se utilizaron los que tenían licencia para uso libre, el cual fueron citados utilizando las normas de Vancouver.
- Las arquitecturas de deep learning utilizadas igualmente fueron citadas y tienen licencia, el cual nos concede los permisos de modificación, uso de patente, uso comercial, distribución y uso privado con la condición de preservar los avisos de licencia y de derecho de autor.

CAPITULO III:

RESULTADOS

3.1 PRESENTACIÓN Y ANÁLISIS DE LOS RESULTADOS

3.1.1 RESULTADOS DE LA ETAPA DE SÍNTESIS DE IMÁGENES

En la primera parte de esta investigación usamos una DCGAN para la síntesis de imágenes de ultrasonografía, el cual consta de un generador que va a sintetizar imágenes falsas cada vez más reales, y de un discriminador que se encargará de clasificar correctamente como verdadera o como falsa la imagen sintetizada por el generador. Para el entrenamiento del modelo DCGAN se utilizó 1570 frames del conjunto de datos total.

Tabla N°1: Hiperparámetros de entrenamiento de la arquitectura DCGAN

Nro. de épocas	Batch size	Tasa de aprendizaje	Valor beta	Optimizador
4520	64	0.0002	0.5	Adam

Fuente: Elaboración propia.

Se realizaron varias pruebas con diferentes hiperparámetros obteniendo diferentes resultados. En la tabla N°1 se encuentran los hiperparámetros donde el entrenamiento fue más óptimo. La evaluación del modelo DCGAN con la función de pérdida, exactitud y valor FID en su mejor época se muestra en la tabla N°2.

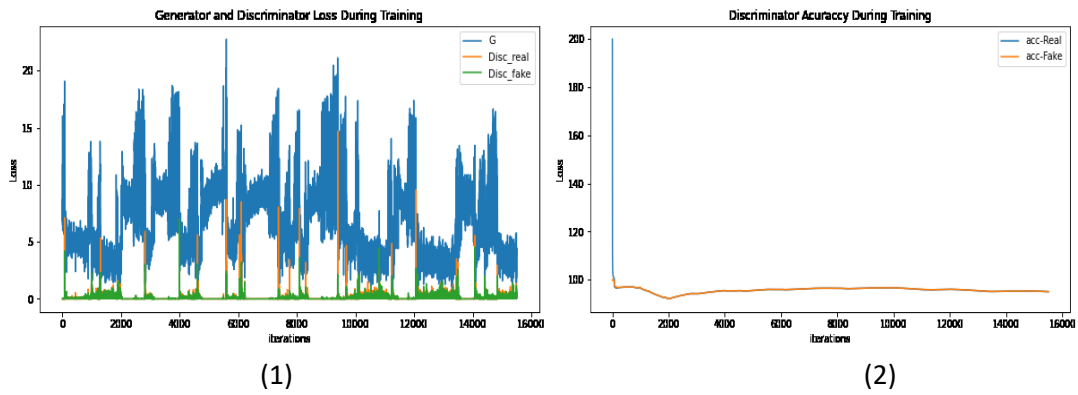
Tabla N°2: Métricas de evaluación de DCGAN

Síntesis de imágenes	Loss			Accuracy		FID
	Disc _{Real}	Disc _{fake}	Gen	Disc _{Real}	Disc _{fake}	
DCGAN	0.16	0.117	4.405	94.982%	95%	20.491

Fuente: Elaboración propia.


La función de pérdida, la exactitud del generador y el discriminador durante el entrenamiento, el cual converge durante la época 4520 (iteración 13 560) a un equilibrio estable se muestra en el Gráfico N°1.

Gráfico N°1: Evaluación durante el entrenamiento de los valores de función de pérdida (1) y exactitud (2) de la red generadora y discriminadora del DCGAN.



Fuente: Matplotlib.

Desde el punto de vista cualitativo no se evidenció la presencia del algún artefacto que distorsione las imágenes generadas por el modelo DCGAN. La figura 5 muestra algunos ejemplos de imágenes reales y sintéticas generadas por el modelo DCGAN en algunas etapas de entrenamiento.






Figura 5. Ejemplos de imágenes sintéticas generadas por el modelo DCGAN con 60 (A), 160 (B), 900 (C), 2580 (D) y 4520 (E) épocas, según signos sugerentes de COVID-19 y las imágenes originales (F).

3.1.2 RESULTADOS DE LA ETAPA DE DETECCIÓN Y SEGMENTACIÓN DE IMÁGENES

El conjunto de datos se dividió en 1570 (83%) para el entrenamiento y 323 (17%) para la validación. En la tabla N°3 se muestran los hiperparámetros que dieron mejores resultados para el entrenamiento de Mask R-CNN.


Tabla N°3: Hiperparámetros de entrenamiento de la arquitectura Mask R-CNN.

Mask R-CNN	Modificados			No modificados	
	Nro. iteraciones	Tasa de aprendizaje	Batch size	Nro. de capas	Batch size (RPN)
Hiperparámetros	8100	0.00010	2	Constante	512

Fuente: Elaboración propia.

Se utilizó la herramienta de Tensorboard para la visualización de las métricas⁸¹. La pérdida y la exactitud durante todo el entrenamiento se resumen en la Gráfico N°2. Se observa que las pérdidas disminuyen de manera constante, sin formar mesetas, a partir de la iteración número 2000, consiguiendo una mejora de aprendizaje a partir de ese nivel.

Gráfico N°2: La exactitud y la función de pérdida durante el entrenamiento del modelo Mask R-CNN.



Fuente: Tensorboard.

El modelo Mask R-CNN mide la función de pérdida mediante la suma de pérdidas de detección, clasificación y segmentación obteniendo un valor de 0,31. En la tabla N°4 se muestran la función de pérdida de clasificación, detección y de segmentación y las demás métricas.

Tabla N°4: Métricas de evaluación del modelo Mask R-CNN

Modelo de deep learning	Función de pérdida (Loss)			Exactitud	Falsos positivos	Falsos negativos
	LOSS _{box}	LOSS _{class}	LOSS _{mask}			
Mask R-CNN	0.08	0.05	0.18	92%	0.08	0.06

Fuente: Elaboración propia.

El valor de precisión promedio (Average Precisión) para cada uno de los signos ecográficos evaluados se muestran en la tabla N°5, el cual nos permite evaluar qué signos ecográficos detecta mejor nuestro modelo.

Tabla N°5: Valores AP para la detección y segmentación según signos ecográficos sugerentes a COVID-19 en la evaluación del modelo Mask R-CNN.

	AP	
	Detección	Segmentación
Líneas B	45.50	44.47
Signo Pleural	27.44	23.27
Consolidación	44.52	39.85

Fuente: Elaboración propia.

Se observó que el patrón mejor aprendido por nuestro modelo fue las líneas B, que es el signo más homogéneo y uno de los más frecuentes en nuestro conjunto de datos; mientras que el menos aprendido fue el signo pleural, esto podría deberse a la gran variabilidad de presentación de este signo.


De manera general también se evaluó la capacidad para detectar y segmentar en función de valores umbrales específicos de la métrica IoU (AP50 y AP75), como se muestra en la tabla N°6.

Tabla N°6: Valores de AP50 y AP75 para la detección y segmentación de signos ecográficos sugerentes a COVID -19.

	AP	AP50	AP75
Detección	39.15	72.58	39.79
Segmentación	34.54	69.77	27.23

Fuente: Elaboración propia.

En la tabla N°6: se observa que para el modelo es más fácil detectar que segmentar; así como también, detecta y segmenta mejor a los que poseen un umbral de IoU DE 50%. Según los resultados de la predicción, el modelo Mask R-CNN tiene buena capacidad para generalizar, pudiendo reconocer diferentes signos que se relaciona con la severidad (Líneas B anormales, Línea pleural anormal y presencia de consolidación), como muestra la figura 6.






Figura 6: Evaluación del modelo de detección y segmentación de signos ecográficos sugestivos a COVID-19 usando deep learning.

Los exámenes ecográficos son procedimientos donde se obtienen varias imágenes en tiempo real, por lo que se realizaron demostraciones de detección y segmentación en videos de ecografías pulmonares que no se utilizaron para el entrenamiento del modelo. Los videos de prueba se pueden encontrar en el siguiente enlace: https://www.youtube.com/playlist?list=PLtw_bMeSBjwoAZu5C8tOo_yOw-irN_8Py

CAPÍTULO IV

DISCUSIÓN

Los estudios publicados anteriormente sobre la aplicación de inteligencia artificial en ecografías pulmonares de COVID-19 se centraron principalmente en la detección (diagnóstico). Mientras que el objetivo principal de esta investigación no solo se enfocó a ver la detección; sino también, evaluar la precisión del modelo para la síntesis de imágenes y segmentación de los signos de las lesiones por SARS-CoV-2 en las ecografías pulmonares.

El aporte de una segmentación automática nos permite observar dónde se encuentra la lesión y delimitarla mediante una máscara, lo que el modelo de deep learning considera como anormal, siendo de gran ayuda para detección y para el seguimiento de la enfermedad.

La primera parte de esta investigación consistió en generar imágenes artificiales de ultrasonografía pulmonar que muestran signos sugerentes de la enfermedad de COVID-19 con el modelo generativo DCGAN.

Las redes generativas adversarias al tratarse de dos redes, no existe una función de pérdida para evaluarla objetivamente. Para evaluar estos modelos existen medidas cuantitativas como log-verosimilitud promedio, Inception Score (IS), Fréchet Inception Distance (FID), siendo esta última la más utilizada y la más aceptada.

En la actualidad existen pocas investigaciones sobre síntesis de imágenes médicas en ultrasonografía, la mayoría se enfocan más en otras modalidades (radiodiagnóstico, tomografía y resonancia). Recientemente Jiamin Liang et al²² hicieron una investigación sobre síntesis de imágenes donde incluían imágenes ecográficas de pulmón con signos sugerentes a COVID-19. Su estudio comparó 3 tipos de redes GAN, una de ellas convolucional, similar a nuestra propuesta, obteniendo imágenes sintéticas de 256x256 con un FID de 60.75 y con presencia de artefactos cuadrados; en comparación de nuestros resultados que no mostraban la presencia de algún artefacto que deforme la imagen, también obtuvimos un valor FID de 20.491, lo que indica que las imágenes sintéticas se acercan en calidad a las imágenes originales. Las otras redes GAN propuestas por Jiamin Liang et al. fueron GANs más avanzadas que utilizan mayor poder computacional, donde su generador usa mapas de etiquetas para generar imágenes sintéticas. Nuestra investigación no utilizó imágenes de 512x512,

tampoco usamos una red GAN avanzada como dicha investigación, debido al limitado conjunto de datos que disponíamos, por lo que no podríamos hacer una comparación con el valor FID para ese tamaño de matriz de imagen.

Se conoce muy poco de las redes generativas adversarias, no existe una base teórica sólida que nos indique como diseñar o entrenar dichos modelos. Las publicaciones científicas actuales nos muestran heurísticas empíricas que pueden ayudar en la práctica.

El DCGAN es una red generativa básica, por lo que son muy inestables, y es necesario observar las imágenes conforme se van generando durante el entrenamiento. Cuando se observa que hay estabilidad durante el entrenamiento y las imágenes generadas son de calidad, se debe detener el entrenamiento o guardar los pesos de esa época; ya que en ese estado generarán mejores imágenes. Si dejamos que el modelo siga entrenándose, las imágenes generadas pueden mejorar o empeorar llegando al colapso y obteniendo imágenes muy distorsionadas.

Para la etapa de detección y segmentación, utilizamos la arquitectura Mask R-CNN, mediante la plataforma detectron2 para conseguir los objetivos planteados.

Nuestros resultados evidenciaron que es posible hacer una detección, clasificación y segmentación de los signos ecográficos pulmonares sugerentes COVID-19.

La exactitud final fue de 92%, mientras que las métricas de detección de AP, AP50 y AP75 fueron de 39.15, 72.58 y 39.79, respectivamente. En la segmentación se obtuvo los valores de AP, AP50 y AP75 de 34.54, 69.77 y 27.23, respectivamente.

El mayor valor en detección en relación a la segmentación, indica que al modelo le es más fácil detectar los signos que poder delimitarlos exactamente, esto podría deberse a las características propias de la imagen ecográfica, la calidad o el formato de las imágenes. Esto se ve más acentuado cuando se hacen pruebas con videos que presentan un cierto grado de borrosidad o pixeleados. El conjunto de datos utilizado para el entrenamiento contiene diferentes grados de calidad y variedad debido a que se utilizaron diferentes ecógrafos, lo que explica el bajo valor del AP para la segmentación, más aún si sumamos estas limitaciones a la gran variabilidad que

poseen los signos de línea pleural anormal, esto también explica porque se obtuvo un valor bajo en tal signo ecográfico.

El valor AP relativamente bajo en signos de línea pleural anormal en la detección (27.44) y segmentación (23.27) podría deberse a la gran heterogeneidad en la imagen de este signo en nuestro conjunto de datos; mientras que en el signo de líneas B los valores altos de AP en detección y segmentación de 45.50 y 44.47, respectivamente, resultaría de su poca variedad en las características de la imagen.

No existe evidencia científica del uso de Mask R-CNN, ni de detectron2, en la detección y segmentación de imágenes ecográficas pulmonares, pero sí en otros modelos de detección, como es el estudio de Jannis Born et al²⁷, que desarrollaron modelos basados en la arquitectura VGG, clasificación basada en frames, encontrando exactitudes de 89% ; en comparación con nuestra exactitud basada en frames de 92%, a pesar de haber utilizado casi el mismo conjunto de datos, nuestro resultado superior podría deberse a la robustez del modelo Mask R-CNN, el pre procesado del conjunto de datos y a los rigurosos criterios de inclusión y exclusión, el cual nos obligó a descartar gran parte del conjunto de datos del repositorio de libre acceso. Jannis Born et al también realizaron clasificación basadas en video obteniendo una exactitud de 92%, el cual no podemos hacer una comparación debido a que no realizamos clasificación basadas en video.

Otra investigación es la de Salvia et al²⁹, donde adaptaron dos redes residuales profundas (ResNet18 y ResNet50), utilizaron 2908 frames de 450 pacientes. En la validación se obtuvo en promedio una exactitud alta de 98%, una precisión de 97% y un recall de 96.5 %; valores más altos respecto a nuestros hallazgos, esto podría ser por la homogeneidad del conjunto de datos que utilizaron; ya que estos fueron adquiridos de un solo centro clínico, a comparación de nuestro conjunto de datos que pertenece a diferentes centros de varios países. Otros estudios como el Julia Diaz-Escobar et al²³, adoptaron diferentes arquitecturas de aprendizaje profundo previamente entrenadas. Obtuvieron que la red Inception V3 logró la mejor exactitud promedio de 89.1%. Resultados similares lo consiguieron Federico Mento et al²⁴, con una exactitud de 85.96% en la estratificación entre pacientes de alto riesgo de empeoramiento clínico y pacientes de bajo riesgo; valores por debajo de nuestra

exactitud, esto indicaría que la robustez del modelo juega un rol importante para obtener buenos resultados, ya que el modelo Mask R-CNN no solo usa redes neuronales convolucionales, sino también redes propuestas de región (RPN, por sus siglas en inglés), el cual permite darnos propuestas donde hay una alta probabilidad de encontrar un objeto.

También en la investigación de Robert Arntfield et al²⁵, mostró una capacidad para discriminar entre patologías COVID-19 con un AUC 1.0, síndrome de dificultad respiratoria aguda (NCOVID) con un AUC 0.934 y edema pulmonar hidrostático (HPE) con un AUC 1.0. Esto fue significativamente mejor que la capacidad del médico (AUC de 0.697, 0.704, 0.967 para las clases COVID-19 (COVID), (NCOVID) y (HPE), respectivamente); a diferencia de nuestra investigación, no nos basamos solo en el signo de líneas B, sino también en los signos de línea pleural anormal y consolidación, lo cual es beneficioso para evaluar el grado de la enfermedad. Tampoco consideramos patologías LUS de apariencia similar en líneas B, lo cual requiere mayor investigación para confirmar la existencia de biomarcadores subvisibles dentro de las imágenes de ultrasonografía como sugiere Robert Arntfield et al.

En la investigación de Subhankar Roy et al²⁶, ellos diseñaron una red avanzada, derivada de Spatial Transformer Networks, que podía predecir la gravedad de la enfermedad y proporciona la localización de artefactos patológicos. En segmentación semántica se obtuvo un coeficiente Dice de 0.75. Si bien es cierto, esta investigación utilizó otras métricas para evaluar su segmentación, los valores altos en sus resultados es producto de la utilización de redes modernas (Transformers), redes de deep learning avanzadas que tienen la capacidad de aprender el contexto mediante relaciones de sus datos secuenciales, estas redes requieren mayor poder computacional.

En contraste con esta investigación, se obtuvieron valores de exactitud aceptables para nuestra cantidad limitada de conjunto de datos, el cual fue aumentado gracias a técnicas de data augmentation. La exactitud podría haber mejorado si es que hubiésemos usado cantidades de datos ecográficos similares a las de otras investigaciones, exámenes en formato DICOM y datos clínicos para condicionar a los algoritmos de deep learning.

LIMITACIONES

Debido a que en nuestro país no se utiliza de forma prioritaria la ecografía pulmonar para evaluación de COVID-19, tampoco se utilizan servicios de base de datos de imágenes biomédicas y la existencia de un déficit de investigación en imágenes médicas ecográficas, no se pudo considerar un conjunto de datos nacional representativo, tampoco se pudo realizar una validación externa con un conjunto de datos de algún establecimiento de salud, por lo que nos limitamos a usar datos extranjeros.

Los conjuntos de datos utilizados en esta investigación también son limitados, ya que solo utilizamos los que se encontraban con licencia para uso libre que cumplían nuestros criterios de inclusión y exclusión.

CAPITULO V
CONCLUSIONES Y RECOMENDACIONES

5.1. CONCLUSIONES

- Los hiperparámetros que mejores resultados mostraron para la síntesis de imágenes con el modelo generativo DCGAN fueron de: 4520 épocas, Batch size de 64, tasa de aprendizaje de 0.0002, valor beta de 0.5 y el optimizador Adam.
- Los mejores resultados en detección y segmentación de imágenes mediante Detectron2 (Mask R-CNN) se dieron con 8100 iteraciones, Batch size de 2 y una tasa de aprendizaje de 0.00010.
- Para la generación de imágenes sintéticas con el modelo DCGAN, se obtuvieron valores de la función de pérdida y exactitud estables en la época 4520 con un valor FID de 20.491. Las imágenes obtenidas son muy parecidas en calidad a las imágenes reales. Nuestros resultados demuestran que es posible generar imágenes aceptables de ultrasonografía pulmonar usando el modelo DCGAN con un pequeño conjunto de datos, 1892 imágenes ultrasonografía pulmonar.
- En la evaluación de la detección y segmentación conseguimos una función de pérdida total de 0,31 (función de pérdida de detección de 0.051, función de pérdida de clasificación de 0.083 y función pérdida de segmentación de 0,18) y una exactitud de 92%. En la detección se obtuvieron buenos resultados en el signo de líneas B (AP = 45.50) y un valor mínimo en signos de línea pleural anormal (AP = 27.44). También en la segmentación se obtuvieron valores altos en el signo de líneas B (AP = 44.47) y un valor menor en los signos de línea pleural anormal (AP = 23.27), debido a que el signo de línea pleural anormal, posee gran variabilidad en las imágenes. Se concluye que el modelo Mask R-CNN mediante la plataforma Detectron2 es efectivo para la detección y segmentación de signos sugerentes de COVID-19 evaluados por ultrasonografía.

5.2. RECOMENDACIONES

- La evolución actual de la tecnología lleva a los tecnólogos médicos en radiología a adaptarse al uso de estos métodos de inteligencia artificial, no solo como usuarios, sino también como investigadores, debido a sus competencias de especialistas en procesamiento de imágenes médicas radiológicas, lo que se recomienda la implementación de estos temas dentro de la malla curricular.
- Para evaluar el comportamiento de los diferentes modelos de deep learning se recomienda realizar estudios comparativos de modelos dedicados a la síntesis, detección y segmentación de imágenes ecográficas.
- Se recomienda hacer investigaciones con imágenes en formato DICOM para evaluar sus métricas y conocer el poder computacional necesario para el análisis de estas imágenes.
- Se recomienda realizar más investigación en el área de inteligencia artificial (deep learning) en ultrasonografía, y en otras modalidades diagnósticas, ya que son una herramienta complementaria para mejorar el diagnóstico, evaluación, seguimiento y control de una enfermedad.

REFERENCIAS BIBLIOGRÁFICAS

1. Munayco C, Tariq A, Rothenberg R, Soto-Cabezas G, Reyes M, Valle A et al. Early transmission dynamics of COVID-19 in a southern hemisphere setting: Lima-Peru: February 29th–March 30th, 2020. *Infectious Disease Modelling*. 2020;5:338338-34
2. COVID-19 en el Perú - Ministerio del Salud [Internet]. covid19.minsa.gob.pe. 2022. Disponible en: https://covid19.minsa.gob.pe/sala_situacional.asp
3. Order Sets [Internet]. Elsevier.com. 2021. Disponible en: https://www.elsevier.com/___data/assets/pdf_file/0004/1016653/COVID-19-Modulo-diagnostico-espanol-COLOMBIA-2020-05-06.pdf
4. Xu B, Xing Y, Peng J, et al. Chest CT for detecting COVID-19: a systematic review and meta-analysis of diagnostic accuracy. *Eur Radiol*. 2020;30(10):5720-5727
5. Pareja-Ramos, Juan J. et al. Importancia de la implementación de la tomografía de tórax para coadyuvar al diagnóstico precoz y triaje oportuno de pacientes con la COVID-19 en hospitales del Perú. *Acta méd. Peru* [online]. 2020, 37(2), pp.239-241
6. Salameh J-P, Leeflang MMG, Hooft L, Islam N, McGrath TA, et al. Thoracic imaging tests for the diagnosis of COVID-19. *Cochrane Database of Systematic Reviews* 2020;9
7. Lopes A, Mafort T, Costa C, Rufino R, Cássia Firmida M, Kirk K et al. Comparison Between Lung Ultrasound and Computed Tomographic Findings in Patients With COVID -19 Pneumonia. *Journal of Ultrasound in Medicine*. 2020.
8. Yang, Y, Huang, Y, Gao, F, et al. Lung ultrasonography versus chest CT in COVID 19 pneumonia: a two centered retrospective comparison study from China. *Intensive Care Med*. 46, 1761–1763
9. Feng, XY, Tao, XW, Zeng, LK, et al. Application of pulmonary ultrasound in the diagnosis of COVID-19 pneumonia in neonates. *Zhonghua Er Ke Za Zhi* 2020; 58: 347–350.

10. Peixoto A, Costa R, Uzun R, Fraga A, Ribeiro J, Marson F. Aplicabilidad de la ecografía pulmonar en el diagnóstico de COVID-19 y evaluación de la progresión de la enfermedad: una revisión sistemática. *Neumología*. 2021;27(6):529-562.
11. Zhao L, Yu K, Zhao Q, Tian R, Xie H, Xie L et al. Puntaje de ultrasonido pulmonar en la evaluación de la gravedad de la enfermedad por coronavirus 2019 (COVID-19) Neumonía. *Ultrasonido en Medicina & Biología*. 2020;46(11):2938-2944.
12. Tung-Chen Y. Ecografía pulmonar en el seguimiento de la infección por COVID-19. *Medicina CLINICA*. 2020;20(4):e62-e65.
13. Lu W, Zhang S, Chen B, Chen J, Xian J, Lin Y et al. A Clinical Study of Noninvasive Assessment of Lung Lesions in Patients with Coronavirus Disease-19 (COVID-19) by Bedside Ultrasound. *Ultraschall in der Medizin - Revista Europea de Ultrasonido*. 2020;41(03):300-307.
14. Tan G, Lian X, Zhu Z, Wang Z, Huang F, Zhang Y et al. Use of Lung Ultrasound to Differentiate Coronavirus Disease 2019 (COVID-19) Pneumonia From Community-Acquired Pneumonia. *Ultrasonido en Medicina & Biología*. 2020;46(10):2651-2658.
15. López Zúñiga D, López Zúñiga M. Diagnóstico de COVID-19 por imagen. *Med Clin (Barc)*. 2020;155(3):140.
16. Lichter Y, Topilsky Y, Taieb P, Banai A, Hochstadt A, Merdler I et al. Lung ultrasound predicts clinical course and outcomes in COVID-19 patients. *Intensive Care Medicine*. 2020;46(10):1873-1883.
17. Lu X, Zhang M, Qian A, Tang L, Xu S. Lung ultrasound score in establishing the timing of intubation in COVID-19 interstitial pneumonia: A preliminary retrospective observational study. *PLOS ONE*. 2020;15(9):e0238679.
18. Inchingolo R, Smargiassi A, Moro F, Buonsenso D, Salvi S, Del Giacomo P et al. The diagnosis of pneumonia in a pregnant woman with coronavirus disease 2019 using maternal lung ultrasound. *American Journal of Obstetrics and Gynecology*. 2020;223(1):9-11.

19. Herrera-Añazco P, Toro-Huamanchumo C. Educación médica durante la pandemia del COVID-19: iniciativas mundiales para el pregrado, internado y el residentado médico COVID -19: iniciativas mundiales para el pregrado, internado y el residentado médico. ACTA MEDICA PERUANA. 2020;37(2).
20. Liang Z, Ooi S, Wang W. Pandemics and Their Impact on Medical Training: Lessons From Singapore. Academic Medicine. 2020;95(9):1359-1361.
21. McDermott C, Łacki M, Sainsbury B, Henry J, Filippov M, Rossa C. Sonographic Diagnosis of COVID-19: A Review of Image Processing for Lung Ultrasound. Frontiers in Big Data. 2021;4.
22. Liang J, Yang X, Huang Y, Li H, He S, Hu X et al. Sketch guided and progressive growing GAN for realistic and editable ultrasound image synthesis. Medical Image Analysis. 2022;79:102461.
23. Diaz-Escobar J, Ordóñez-Guillén NE, Villarreal-Reyes S, Galaviz-Mosqueda A, Kober V, Rivera-Rodriguez R, Lozano Rizk JE. Deep-learning based detection of COVID-19 using lung ultrasound imagery. PLoS One. 2021 Aug 13;16(8):e0255886.
24. La Salvia M, Secco G, Torti E, Florimbi G, Guido L, Lago P et al. Deep learning and lung ultrasound for Covid-19 pneumonia detection and severity classification. Computers in Biology and Medicine. 2021;136:104742.
25. Mento F, Perrone T, Fiengo A, Smargiassi A, Inchingolo R, Soldati G et al. Deep learning applied to lung ultrasound videos for scoring COVID-19 patients: A multicenter study. The Journal of the Acoustical Society of America. 2021;149(5):3626-3634.
26. Arntfield R, VanBerlo B, Alaifan T, Phelps N, White M, Chaudhary R et al. Development of a deep learning classifier to accurately distinguish COVID-19 from look-a-like pathology on lung ultrasound. MedRxiv 2020.
27. Roy, S., Menapace, W., Oei, S., Luijten, B., Fini, E., Saltori, C., et al. Deep Learning for Classification and Localization of COVID-19 Markers in Point-of-Care Lung Ultrasound. IEEE Transactions on Medical Imaging. 2020; 39(8):2676-2687.

28. Born J, Brändle G, Cossio M, Disdier M, Goulet J. POCOVID-Net: Automatic Detection of COVID-19 From a New Lung Ultrasound Imaging Dataset (POCUS). arXiv. 2020.
29. Loey M, Smarandache F, M. Khalifa N. Within the Lack of Chest COVID-19 X-ray Dataset: A Novel Detection Model Based on GAN and Deep Transfer Learning. *Symmetry*. 2020;12(4):651.
30. Sultan L, Sehgal C. A Review of Early Experience in Lung Ultrasound in the Diagnosis and Management of COVID-19. *Ultrasound in Medicine & Biology*. 2020;46(9):2530-2545.
31. McDermott C, Łacki M, Sainsbury B, Henry J, Filippov M, Rossa C. Sonographic Diagnosis of COVID-19: A Review of Image Processing for Lung Ultrasound. *Frontiers in Big Data*. 2021;4.
32. Cronología de la respuesta de la OMS a la COVID-19 [Internet]. Who.int. 2021 [cited 6 September 2022]. Disponible en: <https://www.who.int/es/news/item/29-06-2020-covidtimeline>
33. Maguiña C, Gastelo R, Tequen A. El nuevo Coronavirus y la pandemia del Covid-19. *Rev Med Hered*. 2020;31(2).
34. Pulido S. ¿A partir de que día se detecta el SARS-CoV-2 en PCR o antígenos? [Internet]. *Gaceta Médica*. 2021. Disponible en: <https://gacetamedica.com/investigacion/los-dias-clave-del-sars-cov-2-incubacion-transmisibilidad-y-deteccion/#:~:text=Seg%C3%BAAn%20los%20%C3%BAltimos%20datos%20recopilados,han%20desarrollado%20ya%20sus%20s%C3%ADntomas>
35. Langa LS, Sallent LV, Díez SR. Interpretación de las Pruebas diagnósticas de la covid-19. *FMC - Formación Médica Continuada en Atención Primaria*. 2021;28(3):167–73.

36. Wong H, Lam H, Fong A, Leung S, Chin T, Lo C et al. Frequency and Distribution of Chest Radiographic Findings in Patients Positive for COVID-19. *Radiology*. 2020;296(2):E72-E78.
37. Cheung K, Hung I, Chan P, Lung K, Tso E, Liu R et al. Gastrointestinal Manifestations of SARS-CoV-2 Infection and Virus Load in Fecal Samples From a Hong Kong Cohort: Systematic Review and Meta-analysis. *Gastroenterology*. 2020;159(1):81-95.
38. CDC COVID-19 Response Team. Severe Outcomes Among Patients with Coronavirus Disease 2019 (COVID-19) - United States, February 12–March 16, 2020. *MMWR Morb Mortal Wkly Rep*. 2020;69:343-6.
39. Chen N, Zhou M, Dong X, Qu J, Gong F, Han Y et al. Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study. *The Lancet*. 2020;395(10223):507-513.
40. Petrilli C, Jones S, Yang J, Rajagopalan H, O'Donnell L, Chernyak Y et al. Factors associated with hospital admission and critical illness among 5279 people with coronavirus disease 2019 in New York City: prospective cohort study. *BMJ*. 2020; 369:m1966
41. Li Y, Xia L. Coronavirus Disease 2019 (COVID-19): Role of Chest CT in Diagnosis and Management. *Am J Roentgenol*. 2020;214(6):1280-1286
42. Pan Y, Guan H, Zhou S, Wang Y, Li Q, Zhu T, Hu Q, Xia L. Initial CT findings and temporal changes in patients with the novel coronavirus pneumonia (2019-nCoV): a study of 63 patients in Wuhan, China. *Eur Radiol*. 2020 Jun;30(6):3306-3309.
43. Pan F, Ye T, Sun P, Gui S, Liang B, Li L, Zheng D, Wang J, Hesketh RL, Yang L, Zheng C. Time Course of Lung Changes at Chest CT during Recovery from Coronavirus Disease 2019 (COVID-19). *Radiology*. 2020 Jun;295(3):715-721.
44. Bernheim A, Mei X, Huang M, Yang Y, Fayad ZA, Zhang N, Diao K, Lin B, Zhu X, Li K, Li S, Shan H, Jacobi A, Chung M. Chest CT Findings in Coronavirus Disease-

- 19 (COVID-19): Relationship to Duration of Infection. *Radiology*. 2020 Jun;295(3):200463.
45. Ojha V, Mani A, Pandey NN, Sharma S, Kumar S. CT in coronavirus disease 2019 (COVID-19): a systematic review of chest CT findings in 4410 adult patients. *Eur Radiol*. 2020 Nov;30(11):6129-6138.
46. Pecho-Silva S, Navarro-Solsol AC, Taype-Rondan A, Torres-Valencia J, Arteaga-Livias K, Herriman DA, et al. Pulmonary Ultrasound in the Diagnosis and Monitoring of Coronavirus Disease (COVID-19): A Systematic Review. *Ultrasound Med Biol*. 2021 Aug;47(8):1997-2005.
47. Peng, Q., Wang, X. and Zhang, L. Findings of lung ultrasonography of novel coronavirus pneumonia during the 2019–2020 epidemic. *Intensive Care Medicine*, 2020;46(5):849-850.
48. Wang M, Luo X, Wang L, Estil J, Lv M, Zhu Y, et al. A comparison of lung Ultrasound and Computed Tomography in the diagnosis of patients with COVID-19: A systematic Review and Meta-Analysis. *Diagnostics (Basel)*. 2021 Aug; 11(8): 1351.
49. Portale G, Ciolina F, Arcari L, Giraldi GDL, Danti M, Pietropaolo L, et al. Lung Ultrasound in COVID-19: Clinical Correlates and Comparison with Chest Computed Tomography. *SN Compr Clin Med*. 2021;3(10):2075-2081.
50. Buda N, Cylwik J, Mróz K, Rudzińska R, Dubik P, Malczewska A, et al. Lung Ultrasound Examination in Patients with SARS-CoV-2 Infection: Multicenter Study. *J Clin Med*. 2021 Jul 23;10(15):3255.
51. Colombi D, Petrini M, Maffi G, Villani G. Comparison of admission chest computed tomography and lung ultrasound performance for diagnosis of COVID-19 pneumonia in populations with different disease prevalence. *European Journal of Radiology*. 2020;133:109344.
52. Shahin M. State-of-the-art review of some artificial intelligence applications in pile foundations. *Geoscience Frontiers*. 2016;7(1):33-44.

53. Murphy, K.P.: Machine Learning: A Probabilistic Perspective. The MIT Press (2012)
54. Goodfellow, I, Bengio, Y, Courville, A.: Deep Learning. The MIT Press (2016)
55. Brownlee J. 4 Types of Classification Tasks in Machine Learning [Internet]. Machine Learning Mastery. 2021. Disponible en: <https://machinelearningmastery.com/types-of-classification-in-machine-learning/#:~:text=In%20machine%20learning%2C%20Classification%20refers,one%20of%20the%20known%20characters.>
56. Hesamian M, Jia W, He X, Kennedy P. Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. Journal of Digital Imaging. 2019;32(4):582-596.
57. Lorica B. Why AI and machine learning researchers are beginning to embrace PyTorch [Internet]. O'Reilly Media. 2017. Disponible en: <https://www.oreilly.com/radar/podcast/why-ai-and-machine-learning-researchers-are-beginning-to-embrace-pytorch/>
58. Shukla X, Parmar D. Python – A comprehensive yet free programming language for statisticians. Journal of Statistics and Management Systems. 2016;19(2):277-284.
59. Russell S, Norvig P. Inteligencia artificial. Un enfoque moderno. 2nd ed. Madrid: Pearson Educación, S. A.; 2004.
60. Takimoglu A. What is Data Augmentation? Techniques, Examples & Benefits [Internet]. AIMultiple. 2022. Disponible en: <https://research.aimultiple.com/data-augmentation/>
61. Rédac T. ¿Qué es el Transfer Learning? [Internet]. Formation Data Science | DataScientest.com. 2022. Disponible en: <https://datascientest.com/es/que-es-el-transfer-learning>

62. Goodfellow I.J, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. Generative adversarial networks; Proceedings of the Advances in Neural Information Processing Systems; Montreal, QC, Canada. 2014;8–13.
63. Missert AD, Yu L, Leng S, Fletcher JG, McCollough CH. Synthesizing images from multiple kernels using a deep convolutional neural network. *Med Phys.* 2020; 47: 422– 430.
64. Yu B, Wang Y, Wang L, Shen D, Zhou L. Medical image synthesis via deep learning. *Adv Experim Med Biol.* 2020; 1213: 23– 44.
65. Han X. MR-based synthetic CT generation using a deep convolutional neural network method. *Med Phys.* 2017; 44: 1408– 1419.
66. Yi X., Walia E., Babyn P. Generative adversarial network in medical imaging: A review. *Med. Image. Anal.* 2019;58:101552.
67. Radford A, Metz L, Chintala S. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. Cornell University. 2015.
68. Ren S, He K, Girshick R, Sun J. Faster R-CNN: Towards real-time object detection with region proposal networks, *IEEE Trans. Pattern Anal. Mach. Intell.* 2017;39(6):1137-1149.
69. He K, Gkioxari G, Dollár P, Girshick R. Mask R-CNN, *IEEE Trans. Pattern Anal. Mach. Intell.* 2020;42(2):386-397.
70. Alzubaidi L, Zhang J, Humaidi A.J. et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data.* 2021; 8(1):53.
71. Heusel, Martin and Ramsauer, Hubert and Unterthiner, Thomas and Nessler, Bernhard and Hochreiter, Sepp. GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium. *arXiv.* 2017.

72. Programador CLIC [Internet]. Intersección sobre Unión-IoU-Intersección sobre Unión (1) - programador clic. [Acceso el 10 de agosto]. Disponible en: <https://programmerclick.com/article/53301895785/>
73. Lin T, Patterson G, Ranchi M, Cui Y, Maire M, Belongie S. et al. COCO - Common Objects in Context [Internet]. Cocodataset.org. Disponible en: <https://cocodataset.org/#detection-eval>
74. Amazon Machine Learning Guía para desarrolladores [Internet]. Amazon Machine Learning Guía para desarrolladores. 2022. Disponible en: https://docs.aws.amazon.com/es_es/machine-learning/latest/dg/machinelearning-dg.pdf
75. José Supo, Héctor Zacarías. METODOLOGÍA DE LA INVESTIGACIÓN CIENTÍFICA: Para las Ciencias de la Salud y las Ciencias Sociales. 3era ED. Arequipa. Independiente; 2020.
76. Hernández Sampieri, R., Fernández Collado, C. and Baptista Lucio, M., 2014. Metodología de la investigación. 6th ed. MCGRAW-HILL, pp.128-129.
77. Mongan J, Moy L, Kahn CE. Checklist for Artificial Intelligence in Medical Imaging (Claim): A guide for authors and reviewers. Radiology: Artificial Intelligence. 2020;2(2).
78. DCGAN tutorial — PYTORCH tutorials 1.12.1+CU102 documentation [Internet]. dcgan_faces_tutorial.[Acceso el 10 de agosto del 2022]. Disponible de: https://pytorch.org/tutorials/beginner/dcgan_faces_tutorial.html
79. Brownlee J. How to identify and diagnose gan failure modes [Internet]. Machine Learning Mastery. 2021 [Acceso el 10 de agosto del 2022]. Disponible de: <https://machinelearningmastery.com/practical-guide-to-gan-failure-modes/>
80. Maximilian Seitzer. pytorch-fid: FID Score for PyTorch.2020. [Acceso el 15 de agosto del 2022]. Disponible de: <https://github.com/mseitzer/pytorch-fid>

81. Yuxin Wu and Alexander Kirillov and Francisco Massa and Wan-Yen Lo and Ross Girshick, Detectron2, url{<https://github.com/facebookresearch/detectron2>, 2019
82. Dutta A, Zisserman A. The VIA Annotation Software for Images, Audio and Video. Proceedings of the 27th ACM International Conference on Multimedia. 2019;:2276–2279.
83. Torch.utils.tensorboard — PyTorch 1.12 documentation [Internet]. Pytorch.org. 2022. Disponible en: <https://pytorch.org/docs/stable/tensorboard.html>

ANEXOS

ANEXO N° 1: FICHA DE RECOLECCIÓN DE DATOS



Universidad Nacional Mayor de San Marcos

Facultad de Medicina

Escuela Profesional de Tecnología Médica



FICHA DE RECOLECCIÓN DE DATOS

“Precisión del uso del deep learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid- 19”

Signos ecográficos que se tomarán en cuenta en esta investigación:

-**Signos de línea pleural anormal:** Línea pleural irregular, línea pleural engrosada.

-**Líneas B:** líneas B continuas y pulmón blanco.

-**Consolidación:** Signos a nivel de parénquima pulmonar, broncograma aéreo y consolidación sub pleural.

I. SECCIÓN 1: SÍNTESIS DE IMÁGENES ECOGRÁFICAS

a) Hiperparámetros en el entrenamiento del modelo de deep learning de síntesis de imágenes:

- Numero de épocas: _____

- Tamaño de Batch Size: _____

- Tasa de aprendizaje (Learning rate): _____

- Valor beta (optimizador): _____

b) Métricas de evaluación del modelo de deep learning de síntesis de imágenes:

- Exactitud (Accuracy): _____

- Función de pérdida (Loss): _____

- Distancia de frechet (FID): _____

II. SECCIÓN 2: DETECCIÓN Y SEGMENTACIÓN DE SIGNOS ECOGRÁFICOS SUGERENTES A COVID-19

a) Evaluación del algoritmo de deep learning para detección y segmentación.

- Numero de iteraciones: _____

- Tamaño de Batch Size: _____

- Tasa de aprendizaje (Learning rate): _____

b) Métricas de evaluación del modelo de deep learning de detección y segmentación:

- Exactitud (Accuracy): _____

- Función de pérdida (Loss): _____

- Average Precisión (AP): _____

- Average Precisión con umbral IoU de 50%(AP50): _____

- Average Precisión con umbral IoU de 75% (AP75): _____

- Average Precisión (AP) en signos de líneas B: _____

- Average Precisión (AP) en signos de línea pleural anormal: _____

- Average Precisión (AP) en signos de consolidación: _____

VALIDEZ DE CONTENIDO: PRUEBA BINOMIAL JUICIO DE EXPERTOS

CRITERIOS	JUECES			p
	J1	J2	J3	
1	1	1	1	3
2	1	1	1	3
3	1	1	1	3
4	1	1	1	3
5	1	1	1	3
6	1	1	1	3
7	1	1	1	3
8	1	1	1	3
TOTAL	8	8	8	24

1: de acuerdo 0: desacuerdo

PROCESAMIENTO:
Ta: N° TOTAL DE ACUERDO DE JUECES
Td: N° TOTAL DE DESACUERDO DE JUECES

Prueba de Concordancia entre los Jueces

$$b = \frac{T_a}{T_a + T_d} \times 100$$

b: Grado de Concordancia Significativa

b: $\frac{32}{32 + 0} \times 100 = \mathbf{1.0}$

Según Herrera



0,53 a menos	Validez nula
0,54 a 0,59	Validez baja
0,60 a 0,65	Válida
0,66 a 0,71	Muy válida
0,72 a 0,99	Excelente validez
1.00	Validez perfecta

VALIDACIÓN DEL INSTRUMENTO POR JUICIO DE EXPERTOS

“Precisión del uso del deep learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid-19”

Autor: Rojas Azabache Carlos Sebastián

Teniendo como base los escritos que a continuación se presenta, le solicitamos su opinión sobre el instrumento que se adjunta. Marque con una X (aspa) en SÍ o NO en cada criterio según su opinión. Marque SI, cuando el ítem cumpla con el criterio señalado o NO cuando no cumpla con el criterio.

	CRITERIOS	Opinión		
		SI	NO	Observación
1	El instrumento recoge información que permite dar respuesta al problema de investigación.	X		considerar los aspectos y características de las diferentes imágenes generadas por los distintos transductores en ultrasonografía
2	El instrumento propuesto responde a los objetivos del estudio.	X		
3	La estructura del instrumento es adecuada.	X		para covid 19 si existe signos ecográficos validados (neumonía), considerar colocarlo de manera textual en el entregable para delimitar con mayor claridad en el pre procesado de las imágenes
4	Los ítems (preguntas) del instrumento están correctamente formuladas. (claras y entendibles)	X		
5	Los ítems (preguntas) del instrumento responde a la operacionalización de la variable.	X		
6	La secuencia presentada facilita el desarrollo del instrumento.	X		
7	Las categorías de cada pregunta (variables) son suficientes.	X		
8	El número de ítems (preguntas) es adecuado para su aplicación.	X		

Opinión de aplicabilidad: Aplicable () Aplicable después de corregir (X) No aplicable()

Nombre del Experto: Luis Angel Giovanni Chumpitaz Francia

Profesión: Tecnólogo.Médico.....

N° Colegiatura: 08716.....

Grado Académico: Licenciado.....

Especialidad del validador: Radiología.....



Firma de experto

VALIDACIÓN DEL INSTRUMENTO POR JUICIO DE EXPERTOS

“Precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid-19”

Autor: Rojas Azabache Carlos Sebastián

Teniendo como base los escritos que a continuación se presenta, le solicitamos su opinión sobre el instrumento que se adjunta. Marque con una X (aspa) en SI o NO en cada criterio según su opinión. Marque SI, cuando el ítem cumpla con el criterio señalado o NO cuando no cumpla con el criterio.

	CRITERIOS	Opinión		
		SI	NO	Observación
1	El instrumento recoge información que permite dar respuesta al problema de investigación.	X		
2	El instrumento propuesto responde a los objetivos del estudio.	X		
3	La estructura del instrumento es adecuada.	X		
4	Los ítems (preguntas) del instrumento están correctamente formuladas. (claras y entendibles)	X		
5	Los ítems (preguntas) del instrumento responde a la Operacionalización de la variable.	X		
6	La secuencia presentada facilita el desarrollo del instrumento.	X		
7	Las categorías de cada pregunta (variables) son suficientes.	X		
8	El número de ítems (preguntas) es adecuado para su aplicación.	X		


Opinión de aplicabilidad: Aplicable (X) Aplicable después de corregir () No aplicable()

Nombre de experto: ..Dennis Hernando Núñez Fernández

Profesión: Ingeniería Electrónica

Grado Académico: Estudiante de Maestría en Ciencias Digitales con enfoque en Deep Learning

Especialidad del validador: Ciencias Digitales con enfoque en Deep Learning


Firma de experto

ANEXO 3

VALIDACIÓN DEL INSTRUMENTO POR JUICIO DE EXPERTOS

“Precisión del uso del deep learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid-19”

Autor: Rojas Azabache Carlos Sebastián

Teniendo como base los escritos que a continuación se presenta, le solicitamos su opinión sobre el instrumento que se adjunta. Marque con una X (aspa) en SÍ o NO en cada criterio según su opinión. Marque SI, cuando el ítem cumpla con el criterio señalado o NO cuando no cumpla con el criterio.

	CRITERIOS	Opinión		
		SI	NO	Observación
1	El instrumento recoge información que permite dar respuesta al problema de investigación.	X		
2	El instrumento propuesto responde a los objetivos del estudio.	X		
3	La estructura del instrumento es adecuada.	X		
4	Los ítems (preguntas) del instrumento están correctamente formuladas. (claras y entendibles)	X		
5	Los ítems (preguntas) del instrumento responde a la operacionalización de la variable.	X		
6	La secuencia presentada facilita el desarrollo del instrumento.	X		
7	Las categorías de cada pregunta (variables) son suficientes.	X		
8	El número de ítems (preguntas) es adecuado para su aplicación.	X		

Opinión de aplicabilidad: Aplicable (X) Aplicable después de corregir () No aplicable()

Nombre del Experto: Jason Fonseca Huamán

Profesión: Tecnólogo Médico

Nº Colegiatura: 14190

Grado Académico: Licenciado

Especialidad del validador: Radiología

CLINICA MONTELUZ
INSTITUTO MATEO SANTI MONTELUZ S.A.C

Lc. FORBECA HUAMAN JEISON SAMUEL
Tecnólogo Médico

S.T.M.P. 14190

Firma de experto

ANEXO N° 3: Resolución de Decanato



Firmado digitalmente por PODESTA GAVILANO Luis Enrique FAU
2014892282 hard
Motivo: Soy el autor del documento
Fecha: 21.01.2021 08:41:30 -05:00

UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú. Decana de América
FACULTAD DE MEDICINA
DECANATO

Lima, 21 de Enero del 2021

RESOLUCIÓN DECANAL N° 000161-2021-D-FM/UNMSM

Visto el expediente digital N° F01B4-20210000025, de fecha 19 de enero de 2021 de la Facultad de Medicina, sobre aprobación de Proyecto de tesis

CONSIDERANDO:

Que, mediante Resolución de Decanato N° 1569-D-FM-2013 ratificada con Resolución Rectoral N° 01717-R-2016 de fecha 19 de abril de 2016, se aprueba el Reglamento para la Elaboración de Tesis para optar el Título Profesional en las Escuelas Académico Profesionales de la Facultad de Medicina, que en su **Capítulo I. Introducción, Art. 2:** establece que: *“La tesis debe ser un trabajo inédito de aporte original, por la cual se espera que los estudiantes adquieran destrezas y conocimientos que los habiliten para utilizar la investigación como un instrumento de cambio, cualquiera sea el campo del desempeño”* así mismo, en su **Capítulo VI: Del Asesoramiento de la tesis: Art. 28** establece que: *“La Dirección de la EAP con la opinión favorable del Comité de Investigación, solicitará a la Dirección Académica la Resolución Decanal respectiva para proceder a su ejecución”;*

Que, mediante Oficio N° 000026-2021-EPTM-FM/UNMSM, el Director de la Escuela Profesional de Tecnología Médica, solicita la emisión de la Resolución de Decanato aprobando el Proyecto de tesis titulado *“Precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid- 19”*, presentado por el tesista ROJAS AZABACHE, CARLOS SEBASTIAN - Código 14010137 del área de Radiología, el cual tiene los méritos en forma y en fondo para ser considerado apto para su ejecución y cuenta con la aprobación del Comité de Investigación de la EP de Tecnología Médica. Su asesor es el Mg. Lusín Antonio Ponce Contreras – Código 0A3064; y,

Estando a lo establecido por el Estatuto de la Universidad Nacional Mayor de San Marcos y las atribuciones conferidas por la Ley Universitaria N°30220;

SE RESUELVE:

1° Aprobar el Proyecto de Tesis, según detalle:

Estudiante: Carlos Sebastian Rojas Azabache Código de matrícula N° 14010137 E.P. de Tecnología Médica Área: Radiología	Título del Proyecto de Tesis: “Precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid- 19”
Asesor: Mg. Lusín Antonio Ponce Contreras Código docente: 0A3064	

2° Encargar a la Escuela Profesional de Tecnología Médica el cumplimiento de la presente resolución.

Regístrese, comuníquese, archívese.



Firmado digitalmente por FERNÁNDEZ GIUSTI VDA DE PELLA Alicia Jesús FAU
2014892282 soft
Motivo: Soy el autor del documento
Fecha: 21.01.2021 08:32:58 -05:00

DRA. ALICIA J. FERNÁNDEZ GIUSTI VDA. DE PELLA
VICEDECANA ACADÉMICA

mmb

DR. LUIS ENRIQUE PODESTA GAVILANO
DECANO

Esta es una copia auténtica imprimible de un documento electrónico archivado por la Universidad Nacional Mayor de San Marcos, aplicando lo dispuesto por el Art. 25 de D.S. 070-2013-PCM y la Tercera Disposición Complementaria Final del D.S. 026-2016-PCM. Su autenticidad e integridad pueden ser contrastadas a través de la siguiente dirección web: <https://epsgd.unmsm.edu.pe/verifica/inicio.do> e ingresando el siguiente código de verificación: **GМКSTEI**



ANEXO N° 4: FIGURAS




Figura 1. Configuración de la arquitectura DCGAN utilizada para la síntesis de imágenes.

GENERADOR

```
# 1
nn.ConvTranspose2d(nz, ngf * 32, 4, 1, 0, bias=False),
nn.BatchNorm2d(ngf * 32),
nn.ReLU(True),
# 2
nn.ConvTranspose2d(ngf * 32, ngf * 16, 4, 2, 1, bias=False),
nn.BatchNorm2d(ngf * 16),
nn.ReLU(True),
# 3
nn.ConvTranspose2d(ngf * 16, ngf * 8, 4, 2, 1, bias=False),
nn.BatchNorm2d(ngf * 8),
nn.ReLU(True),
# 4
nn.ConvTranspose2d(ngf * 8, ngf * 4, 4, 2, 1, bias=False),
nn.BatchNorm2d(ngf * 4),
nn.ReLU(True),
# 5
nn.ConvTranspose2d(ngf * 4, ngf * 2, 4, 2, 1, bias=False),
nn.BatchNorm2d(ngf * 2),
nn.ReLU(True),
# 6
nn.ConvTranspose2d(ngf * 2, ngf, 4, 2, 1, bias=False),
nn.BatchNorm2d(ngf),
nn.ReLU(True),
# 7
nn.ConvTranspose2d(ngf, nc, 4, 2, 1, bias=False),
nn.Tanh()
```

DISCRIMINADOR

```
# 1
nn.Conv2d(nc, ndf, 4, 2, 1, bias=False),
nn.LeakyReLU(0.2, inplace=True),
# 2
nn.Conv2d(ndf, ndf * 2, 4, 2, 1, bias=False),
nn.BatchNorm2d(ndf * 2),
nn.LeakyReLU(0.2, inplace=True),
# 3
nn.Conv2d(ndf * 2, ndf * 4, 4, 2, 1, bias=False),
nn.BatchNorm2d(ndf * 4),
nn.LeakyReLU(0.2, inplace=True),
# 4
nn.Conv2d(ndf * 4, ndf * 8, 4, 2, 1, bias=False),
nn.BatchNorm2d(ndf * 8),
nn.LeakyReLU(0.2, inplace=True),
# 5
nn.Conv2d(ndf * 8, ndf * 16, 4, 2, 1, bias=False),
nn.BatchNorm2d(ndf * 16),
nn.LeakyReLU(0.2, inplace=True),
# 6
nn.Conv2d(ndf * 16, ndf * 32, 4, 2, 1, bias=False),
nn.BatchNorm2d(ndf * 32),
nn.LeakyReLU(0.2, inplace=True),
# 7
nn.Conv2d(ndf * 32, 1, 4, 1, 0, bias=False),
nn.Sigmoid()
```

Figura 2: Fragmento de código original de la red DCGAN al cual se le agregó 2 bloques al generador y al discriminador

SÍNTESIS DE IMÁGENES




Figura 3: Diagrama para la síntesis de imágenes mediante la DCGAN

DETECCIÓN Y SEGMENTACIÓN DE IMÁGENES CON DETECTRON2




Figura 4: Diagrama para la detección y segmentación con el modelo Detectron2(Mask R-CNN)




Figura 7: Captura de pantalla de la página de VGG Image Annotator (VIA), herramienta para las segmentaciones y anotaciones.



Figura 8: Captura de pantalla de Google Colaboratory, entorno de google research que permite programar y ejecutar código Python.

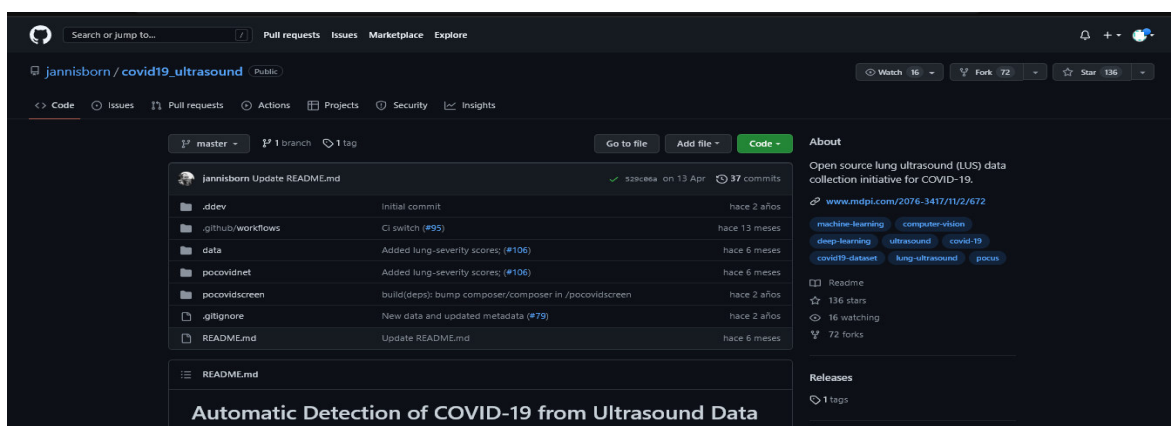


Figura 9: Captura de pantalla del Portal GitHub, web que permite alojar repositorios en la nube. El repositorio de JannisBorn contiene el conjunto de datos de ecografía pulmonar con signos sugerentes a COVID-19.

```

[4515/6000] [0/25]   loss_D_real: 0.0361   loss_D_fake: 0.2418   Loss_G: 2.9681\tAcc_D_real: 95.0669   Acc_D_fake: 95.0918
[4516/6000] [10/25]  loss_D_real: 0.1693   loss_D_fake: 0.1460   Loss_G: 3.3075\tAcc_D_real: 95.0574   Acc_D_fake: 95.0814
[4517/6000] [20/25]  loss_D_real: 0.1284   loss_D_fake: 0.1619   Loss_G: 3.7789\tAcc_D_real: 95.0517   Acc_D_fake: 95.0755
[4518/6000] [0/25]   loss_D_real: 0.1113   loss_D_fake: 0.5935   Loss_G: 2.9438\tAcc_D_real: 95.0499   Acc_D_fake: 95.0740
[4519/6000] [10/25]  loss_D_real: 0.8989   loss_D_fake: 0.0253   Loss_G: 1.8596\tAcc_D_real: 95.0412   Acc_D_fake: 95.0678
[4520/6000] [20/25]  loss_D_real: 0.0308   loss_D_fake: 0.2317   Loss_G: 3.5348\tAcc_D_real: 95.0351   Acc_D_fake: 95.0589
[4521/6000] [0/25]   loss_D_real: 0.2039   loss_D_fake: 0.1143   Loss_G: 3.0254\tAcc_D_real: 95.0328   Acc_D_fake: 95.0573
[4522/6000] [10/25]  loss_D_real: 0.1295   loss_D_fake: 0.0968   Loss_G: 3.8597\tAcc_D_real: 95.0291   Acc_D_fake: 95.0527
[4523/6000] [20/25]  loss_D_real: 0.1396   loss_D_fake: 0.1312   Loss_G: 3.4062\tAcc_D_real: 95.0245   Acc_D_fake: 95.0484
[4524/6000] [0/25]   loss_D_real: 0.2198   loss_D_fake: 0.1601   Loss_G: 2.7982\tAcc_D_real: 95.0218   Acc_D_fake: 95.0462
[4525/6000] [10/25]  loss_D_real: 0.0360   loss_D_fake: 0.0870   Loss_G: 4.6379\tAcc_D_real: 95.0175   Acc_D_fake: 95.0409
[4526/6000] [20/25]  loss_D_real: 0.2336   loss_D_fake: 0.0399   Loss_G: 3.1533\tAcc_D_real: 95.0132   Acc_D_fake: 95.0382
[4527/6000] [0/25]   loss_D_real: 0.3737   loss_D_fake: 0.0948   Loss_G: 2.4973\tAcc_D_real: 95.0101   Acc_D_fake: 95.0352
[4528/6000] [10/25]  loss_D_real: 0.0243   loss_D_fake: 0.0526   Loss_G: 3.3708\tAcc_D_real: 95.0061   Acc_D_fake: 95.0305
[4529/6000] [20/25]  loss_D_real: 0.1639   loss_D_fake: 0.0079   Loss_G: 3.7084\tAcc_D_real: 95.0019   Acc_D_fake: 95.0249
[4530/6000] [0/25]   loss_D_real: 0.0350   loss_D_fake: 0.3536   Loss_G: 3.5073\tAcc_D_real: 94.9965   Acc_D_fake: 95.0203
[4531/6000] [10/25]  loss_D_real: 0.0134   loss_D_fake: 0.0541   Loss_G: 3.9692\tAcc_D_real: 94.9931   Acc_D_fake: 95.0168
[4532/6000] [20/25]  loss_D_real: 0.1630   loss_D_fake: 0.1171   Loss_G: 4.4055\tAcc_D_real: 94.9829   Acc_D_fake: 95.0067
[4533/6000] [0/25]   loss_D_real: 0.1135   loss_D_fake: 0.0568   Loss_G: 3.2933\tAcc_D_real: 94.9786   Acc_D_fake: 95.0034
[4534/6000] [10/25]  loss_D_real: 0.0818   loss_D_fake: 0.5219   Loss_G: 3.6906\tAcc_D_real: 94.9743   Acc_D_fake: 94.9978
[4535/6000] [20/25]  loss_D_real: 0.2690   loss_D_fake: 0.1565   Loss_G: 2.3039\tAcc_D_real: 94.9694   Acc_D_fake: 94.9944
[4536/6000] [0/25]   loss_D_real: 0.0091   loss_D_fake: 0.2872   Loss_G: 3.0135\tAcc_D_real: 94.9661   Acc_D_fake: 94.9908
[4537/6000] [10/25]  loss_D_real: 0.0552   loss_D_fake: 0.1445   Loss_G: 3.2918\tAcc_D_real: 94.9606   Acc_D_fake: 94.9850
[4538/6000] [20/25]  loss_D_real: 0.1048   loss_D_fake: 0.0544   Loss_G: 3.7683\tAcc_D_real: 94.9565   Acc_D_fake: 94.9803
[4539/6000] [0/25]   loss_D_real: 0.1034   loss_D_fake: 0.4581   Loss_G: 3.7384\tAcc_D_real: 94.9533   Acc_D_fake: 94.9764
[4540/6000] [10/25]  loss_D_real: 0.2690   loss_D_fake: 0.1801   Loss_G: 3.0493\tAcc_D_real: 94.9481   Acc_D_fake: 94.9725
[4541/6000] [20/25]  loss_D_real: 0.3229   loss_D_fake: 0.1990   Loss_G: 2.2338\tAcc_D_real: 94.9431   Acc_D_fake: 94.9675
[4542/6000] [0/25]   loss_D_real: 0.1092   loss_D_fake: 0.1168   Loss_G: 3.7546\tAcc_D_real: 94.9410   Acc_D_fake: 94.9643
[4543/6000] [10/25]  loss_D_real: 0.0133   loss_D_fake: 0.3693   Loss_G: 3.6248\tAcc_D_real: 94.9350   Acc_D_fake: 94.9582
[4544/6000] [20/25]  loss_D_real: 0.1612   loss_D_fake: 0.2538   Loss_G: 3.3770\tAcc_D_real: 94.9307   Acc_D_fake: 94.9535
[4545/6000] [0/25]   loss_D_real: 0.1801   loss_D_fake: 0.2909   Loss_G: 3.2566\tAcc_D_real: 94.9245   Acc_D_fake: 94.9483

```

Figura 10: Captura de pantalla del historial de entrenamiento del modelo DCGAN en su última época.

```

Average Recall (AR) @ 100x.50:0.95 | area=all | maxDet=100 | 0.452
Average Recall (AR) @ 100x.50:0.95 | area=small | maxDet=100 | 0.214
Average Recall (AR) @ 100x.50:0.95 | area=medium | maxDet=100 | 0.319
Average Recall (AR) @ 100x.50:0.95 | area=large | maxDet=100 | 0.571
[15/05 21:02:00.02 evaluation_done_evaluation] Evaluation results for segm:
| AP | AP50 | AP75 | APs | APm | APl |
|-----|-----|-----|-----|-----|-----|
| 28.155 | 72.575 | 29.789 | 24.485 | 28.892 | 28.532 |
|-----|-----|-----|-----|-----|-----|
[15/05 21:02:00.02 evaluation_done_evaluation] Per-category bbox AP:
| category | AP | category | AP | category | AP |
|-----|-----|-----|-----|-----|-----|
| LINDAS B | 40.509 | SIGMO PIZURAL | 27.442 | CONSOLIDACION | 44.520 |
Loading and preparing results...
done. (0.01s)
creating index...
index created!
[15/05 21:02:00.02 evaluation_fast_eval_ap1] Evaluate annotation type "segm"
[15/05 21:02:00.02 evaluation_fast_eval_ap1] COCOEval_aps.evaluate() finished in 0.12 seconds.
[15/05 21:02:00.02 evaluation_fast_eval_ap1] Accumulating evaluation results...
[15/05 21:02:00.02 evaluation_fast_eval_ap1] COCOEval_aps.coco_summary() finished in 0.02 seconds.
Average Precision (AP) @ 100x.50:0.95 | area=all | maxDet=100 | 0.345
Average Precision (AP) @ 100x.50 | area=all | maxDet=100 | 0.289
Average Precision (AP) @ 100x.75 | area=all | maxDet=100 | 0.272
Average Precision (AP) @ 100x.50:0.95 | area=small | maxDet=100 | 0.098
Average Precision (AP) @ 100x.50:0.95 | area=medium | maxDet=100 | 0.215
Average Precision (AP) @ 100x.50:0.95 | area=large | maxDet=100 | 0.284
Average Recall (AR) @ 100x.50:0.95 | area=all | maxDet=100 | 0.437
Average Recall (AR) @ 100x.50:0.95 | area=small | maxDet=100 | 0.147
Average Recall (AR) @ 100x.50:0.95 | area=medium | maxDet=100 | 0.200
Average Recall (AR) @ 100x.50:0.95 | area=large | maxDet=100 | 0.449
[15/05 21:02:00.02 evaluation_done_evaluation] Evaluation results for segm:
| AP | AP50 | AP75 | APs | APm | APl |
|-----|-----|-----|-----|-----|-----|
| 28.155 | 72.575 | 29.789 | 24.485 | 28.892 | 28.532 |
|-----|-----|-----|-----|-----|-----|
[15/05 21:02:00.02 evaluation_done_evaluation] Per-category segm AP:
| category | AP | category | AP | | |
|---|---|---|---|---|---|
| LINDAS B | 40.472 | SIGMO PIZURAL | 27.280 | CONSOLIDACION | 49.481 |
[15/05 21:02:00.02 evaluation_testing] Evaluation results for cordinates_val in csv format:
[15/05 21:02:00.02 evaluation_testing] cordinates: Task bbox
[15/05 21:02:00.02 evaluation_testing] cordinates: AP:28.155,AP75:29.789,APs:28.532,APm:28.155,APl:28.532
[15/05 21:02:00.02 evaluation_testing] cordinates: Task segm
[15/05 21:02:00.02 evaluation_testing] cordinates: AP:34.5,AP75:39.784,APs:38.071,APm:34.5,APl:38.071
[15/05 21:02:00.02 evaluation_testing] cordinates: AP:28.155,AP75:29.789,APs:28.532,APm:28.155,APl:28.532

```

Figura 11: Captura de pantalla del historial de entrenamiento del modelo Mask R-CNN, mediante la plataforma detectron2, en su última iteración.




Figura 12: Captura de pantalla de la herramienta de Tensorboard y las métricas que brinda Detectron2.

ANEXO 5

MATRIZ DE CONSISTENCIA

TITULO	PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES	TIPO DE ESTUDIO
Precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid-19	¿Cuál es la precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a COVID-19?	<p>Objetivo general</p> <p>Evaluar la precisión del uso del Deep Learning en la síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a COVID - 19</p> <p>Objetivos específicos</p> <ul style="list-style-type: none"> - Identificar los hiperparámetros adecuados para el correcto entrenamiento del modelo de deep learning de síntesis de imágenes. - Identificar los hiperparámetros adecuados para el correcto entrenamiento del modelo de deep learning de detección y segmentación de imágenes. - Evaluar los resultados de la validación del modelo de deep learning de síntesis de imágenes. - Evaluar los resultados de la validación del modelo de deep learning de detección y segmentación de imágenes. 	Esta investigación es de nivel predictivo, sin hipótesis.	<p>Variable 1:</p> <p>Uso del Deep Learning.</p> <p>Variable 2:</p> <p>Síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a COVID- 19</p>	Cuantitativo, retrospectivo, experimental y predictivo

VARIABLES OPERACIONALIZACIÓN

VARIABLE INDEPENDIENTE	DEFINICIÓN CONCEPTUAL	DIMENSIONES	SUBDIMENSION	TIPOS DE VARIABLE	ESCALA	VALOR FINAL	INSTRUMENTO DE MEDICIÓN
Uso del Deep Learning	Fragmentos de código de programación de Inteligencia Artificial que sintetiza, detecta y segmenta imágenes .	Algoritmo de deep learning para la síntesis de imágenes	Número de épocas	Cuantitativa	Razón	Número	Ficha de recolección de datos.
			Batch size	Cuantitativa	Razón	Número	
			Tasa de aprendizaje (Learnig rate)	Cuantitativa	Razón	Número	
			Valor beta (optimizador)	Cuantitativa	Razón	Número	
		Algoritmo de deep learning para detección y segmentación.	Número de iteraciones	Cuantitativa	Razón	Número	
			Batch Size	Cuantitativa	Razón	Número	
			Tasa de aprendizaje (Learnig rate)	Cuantitativa	Razón	Número	

VARIABLE DEPENDIENTE	DEFINICIÓN CONCEPTUAL	DIMENSION	SUBDIMENSION	TIPOS DE VARIABLE	ESCALA	VALOR FINAL	INSTRUMENTO DE MEDICIÓN
Síntesis, detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid- 19	Áreas de estudio del campo de la visión artificial aplicados a imágenes médicas (signos ecográficos sugerentes a Covid-19).	Síntesis de imágenes ultrasonográficas con signos sugerentes a covid-19	Accuracy	Cuantitativo	Razón	Porcentaje	Ficha de recolección de datos.
			Loss	Cuantitativo	Razón	Número	
			Distancia de frechet (FID)	Cuantitativo	Razón	Número	
		Detección y segmentación de signos ultrasonográficos de pulmón sugerentes a Covid-19	Accuracy	Cuantitativo	Razón	Porcentaje	
			Loss	Cuantitativo	Razón	Número	
			AP	Cuantitativo	Razón	Número	
			AP50	Cuantitativo	Razón	Número	
			AP75	Cuantitativo	Razón	Número	
			AP _{Lineas B}	Cuantitativo	Razón	Número	
			AP _{Línea pleural}	Cuantitativo	Razón	Número	
AP _{Consolidación}	Cuantitativo	Razón	Número				