

Digital Analysis of fetal lung ultrasound using deep learning techniques

Análisis digital de ultrasonido pulmonar fetal mediante técnicas de aprendizaje profundo

Pérez-Escamilla, Javier^{1*}, García-Ríos, Elizabeth¹, Cruz-Guerrero, René², Vargas-Ruiz Lauro²,

¹*TecNM-Instituto Tecnológico Superior del Occidente del Estado de Hidalgo. Paseo del Agrarismo 2000. Carr. Mixquiahuala - Tula, km 2.5 Mixquiahuala de Juárez, Hidalgo.*

²*TecNM-Instituto Tecnológico Superior del Oriente del Estado de Hidalgo, Carretera Apan-Tepeapulco Km 3.5, Colonia Las Peñitas, C.P. 43900, Apan, Hidalgo, México. (0009-0008-4090- 2259, 0000-0001-5066-8859, 0000-0003-1276-2419, 0000-0003-1623-1797)*

Sent date: 13/June/2024 Acceptance date: 30/July/2024

Abstract:

Worldwide, about 15 million infants are born each year without completing their gestational stage. According to data from the World Health Organization in the "WHO Recommendations for the care of preterm or low birth weight infants", 45% of all deaths of infants under 5 years of age, 60% to 80% are premature due to major respiratory deficiencies. Lung malformation results in induced abortion or Respiratory Distress Syndrome (RDS). RDS can be prevented by clinical studies and radiological criteria. This work addresses the task of identifying malformations using digital analysis of fetal lung images using deep learning tools in a multiclass categorization of bronchopulmonary sequestration, cystic malformations and diaphragmatic hernia, where there is a risk of misdiagnosis and death. Resulting in a model accuracy of 88.88%, from a set of 42 two-dimensional sonograms.

Keywords: Fetal lung, Transfer learning, Lung injury.

Resumen:

En el mundo, alrededor de 15 millones de niños nacen al año sin completar su etapa gestacional. De acuerdo a datos de la Organización Mundial de la Salud en las "Recomendaciones de la OMS para cuidado del lactante prematuro o bebé de bajo peso al nacer", el 45% de todas las defunciones de infantes menores de 5 años, del 60% al 80% son prematuros a causa mayor de deficiencias respiratorias. La malformación pulmonar, resulta en aborto inducido o Síndrome de Dificultad Respiratoria, RDS por sus siglas del inglés de Respiratory Distress Syndrome. RDS puede prevenirse por medio de estudios clínicos y criterios radiológicos. Este trabajo aborda la tarea de identificar malformaciones usando el análisis digital de imágenes de pulmones en etapa fetal, mediante herramientas de aprendizaje profundo en una categorización multiclase de secuestro broncopulmonar, malformaciones quísticas y hernia diafragmática, donde existe riesgo de diagnóstico errado y

fallecimiento. Resultando en una exactitud del modelo de 88.88%, de un conjunto de 42 sonogramas bidimensionales.

Palabras clave: Pulmón fetal, Transferencia de aprendizaje, Lesión pulmonar.

* Corresponding author. E-mail: javierperez@itsoeh.edu.mx; rcruz@itesa.edu.mx
Tel. 73-87-35-40-00, Fax 73-87-35-40-00

1. Introducción

La salud de la población es una preocupación en años recientes para los países en vías de desarrollo, posicionándose como un factor incidente en el desarrollo humano, económico y social. Es de importancia para los centros e institutos de salud, fortalecer las tecnologías para el apoyo a la prevención de forma rápida y no intrusiva. Una tarea fundamental es, acercar los servicios de diagnóstico no invasivos a poblaciones vulnerables y de escasos recursos. Por ello, las técnicas de visión por computadora en conjunto con herramientas de aprendizaje de máquina, fortalecen la tarea del personal de salud para mitigar los riesgos derivados de un padecimiento. El Síndrome de Dificultad Respiratoria (SDR), es un padecimiento que puede ser prevenido mediante el análisis del estudio de la Madurez Pulmonar Fetal (MPF) dentro del periodo de desarrollo gestacional. La búsqueda de métodos seguros, que no atenten a la salud del neonato y la madre, se presentan como oportunidad de investigación ante los procedimientos tradicionales.

15 millones de niños nacen al año de forma anticipada, un grupo de estos son infantes en etapa gestacional de hasta 37 semanas de las 40 recomendadas. Del 45% de todas las muertes de infantes menores de 5 años, entre el 60% al 80%, son nacimientos prematuros, de acuerdo a datos de la Organización Mundial de la Salud (OMS) en las “recomendaciones de la OMS para cuidado del lactante prematuro o bebé de bajo peso al nacer”, resaltando que la mayor mortalidad se da por deficiencias respiratorias (World Health Organization, 2022).

En México, el número de defunciones fetales tiene una tasa de 6.7 mujeres en edad fértil por cada 10,000. En el año 2021 se contabilizaron una total de 23,000 muertes registradas, de las cuales 2,016 son por problemas respiratorios (Instituto Nacional de Estadística y Geografía, 2022).

La OMS considera que la prevención de la salud fetal y de la madre son focos de atención en los países de las Américas. Para mitigar los riesgos y reducir las defunciones, ha establecido que la ecografía es el medio que permite afrontar el reto. Siendo un método que puede ser mejorado y junto a otros servicios de radiología, pueden ser claves en la detección temprana. (Organización Panamericana de la Salud, 2015).

Las malformaciones congénitas afectan la vida intrauterina, para el correcto diagnóstico se requieren técnicas no invasivas, aquí es donde el estudio ecográfico permite facilitar la vigilancia y la atención. Un experto tiene la capacidad de encontrar deficiencias en las partes del cuerpo, como los daños al sistema nervioso, la espina bífida, gastroquisis y microcefalia

por mencionar algunas. Además de deficiencias del feto, resalta la importancia del seguimiento médico, dónde resulta más sencillo la prevención en las primeras etapas de desarrollo (Espinosa y Lucio, 2020).

La prevención de complicaciones pulmonares en recién nacidos, es un foco de atención en la mortalidad neonatal, causado por la deficiencia de surfactante pulmonar. Por ello, las técnicas no invasivas presentan la oportunidad de predecir la morbilidad respiratoria. La evaluación de la madurez pulmonar ha demostrado que un algoritmo puede predecir la aparición de RDS (Albinagorta, 2022).

La ecografía es una herramienta visual que presenta la ventaja de ser un método no invasivo y seguro, que apoya en la detección de anomalías. El estudio de la MPF, se usa sobre imágenes en formato DICOM o JPEG, donde la diferenciación de tejido y la semana de gestación, habilita al personal de salud a realizar un diagnóstico del desarrollo de los órganos y del feto en general. Este proyecto, propone el desarrollo de una aplicación de software que permita al personal de salud procesar una ecografía pulmonar fetal, aplicar técnicas de visión artificial y obtener una caracterización del desarrollo pulmonar. Así entonces, obtener una clasificación y etiquetado de la imagen para el apoyo en la búsqueda de malformaciones pulmonares que derive en RDS o en aborto.

2. Revisión de la literatura

Durante el desarrollo pulmonar fetal, se pueden generar lesiones que conforman anomalías sustentadas en una displasia en la embriogénesis del árbol pulmonar. Entre estas se encuentra la malformación adenoidea quística pulmonar (MAQ), donde la clasificación se basa en quistes en pulmones que están en rangos que van desde dos centímetros en quistes únicos, quistes menores a un centímetro, y micro-quistes. El diagnóstico médico, se fundamenta en la valoración morfológica pulmonar fetal. Una característica de importancia de diferenciación del diagnóstico entre el secuestro broncopulmonar, los quistes bronco-génicos y la hernia diafragmática, es si está presente un vaso nutricio. Un estudio diferencial para determinar el padecimiento es requerido. En MAQ es característico que no existe conexión de irrigación. La evolución de los quistes, desencadena el fenómeno de hídrops y eventualmente la muerte fetal (Vega *et al.*, 2015).

Entre los estudios para la madurez pulmonar, se encuentran los tradicionales, como: a) el recuento de cuerpos lamelares, b) la relación lecitina/esfingomielina, c) presencia de fosfatidilglicerol, d) densidad óptica de los cuerpos lamelares y e) el índice de estabilidad de la espuma (Test de Clements). El método ecográfico QuantusFLM es una herramienta que usa técnicas de pre-procesamiento de imagen digital, para extraer características de textura y algoritmos de aprendizaje automático, pudiendo predecir el riesgo de morbilidad respiratoria. En la práctica, el procedimiento tradicional líquido amniótico (b) y el procedimiento de sonograma, obtienen los mejores resultados clínicos (Zuñiga *et al.*, 2023).

En el trabajo de Pando García (2020), se realizó un estudio cuantitativo del método QuantusFLM para predecir la MPF usando las métricas de precisión, especificidad,

sensibilidad y valor predictivo negativo obteniendo 87%, 86%, 91% y 98% respectivamente. La invarianza en la adquisición de la ecografía (posición, iluminación, sombras, resolución), permite la extracción de características de textura de la imagen en una región de interés (ROI del inglés Region of Interest), esta ROI corresponde al tejido de estudio. Una vez que se pueden detectar similitudes de las entradas, es cuando un clasificador puede ser entrenado para la tarea de discriminar muestras.

Hernández Sancho y Rojas Maruri (2020) tratan médicamente un secuestro pulmonar, realizan el diagnóstico mediante técnicas de ecografía, en este caso ecocardiografía. A través de un análisis visual, identifican el padecimiento de estenosis valvular aórtica y coartación aórtica moderada, con dilatación de la aurícula izquierda. Mediante observaciones en el sonograma, les permite pronosticar riesgo de SBR intralobar con quistes basales de uno a dos cm (MAQ), además que existe vaso nutricio aórtico aberrante de origen supra celíaco en la aorta abdominal. La correcta identificación de las partes, permitió una intervención adecuada. El aprendizaje profundo, es una técnica basada en vectores, se sustenta en un punto en el espacio geométrico. Las entradas se convierten en un espacio vectorial inicial y existe un espacio vectorial objetivo. Las transformaciones geométricas, son realizadas por las capas de procesamiento sobre los datos de entrada. La complejidad geométrica aumenta entre las capas, pero es descompuesta en transformaciones simples. Es decir, se mapea el espacio de la entrada en el espacio de destino, punto por punto. El proceso es parametrizado por los pesos sinápticos, directamente relacionado con el rendimiento del modelo. La diferenciación de cada plano, permite aprender sus parámetros. Una técnica de optimización muy usada es el gradiente descendiente, siendo una descomposición de manera suave y continua. Los modelos de aprendizaje profundo, son máquinas para descomponer colectores de datos de alta dimensión (Chollet, 2017).

La visión por computadora, es un conjunto de procedimientos de procesamiento de imágenes y reconocimiento de patrones, inteligencia artificial y de gráficos por computadora. La entrada se base en imágenes digitales, el objetivo que se persigue es la obtención de información mediante descripciones sustentada en la extracción de características. La salida del proceso es el entendimiento de la escena. Se puede enfocar en tareas como el mejoramiento o el reconocimiento, siendo dependiente de la tecnología computacional (Wiley y Lucas, 2018).

Para las tareas de clasificación los datos categóricos constan de etiquetas discretas, cuando se trabaja en aprendizaje automático, normalmente es necesario convertir estas categorías en valores numéricos antes de introducirlos en un modelo. One-hot encoding, es una técnica común utilizada para representar variables categóricas que se representa como un vector binario, donde solo un elemento se establece en uno (1), lo que indica la presencia de la categoría. La mayoría de los vectores codificados consistirán en ceros, lo que dará como resultado una gran cantidad de memoria desperdiciada. La escasa representación de datos categóricos, tiene como objetivo abordar esta ineficiencia mediante el uso de un índice entero para representar cada clase (Brownlee, 2020).

Los modelos de aprendizaje profundo requieren ajustarse, por ello “Categorical accuracy” es una métrica que mide la exactitud de las predicciones, calculando la fracción de muestras clasificadas correctamente en el conjunto de datos de entrenamiento. “Value Categorical Accuracy” se utiliza durante la fase de validación del entrenamiento, mide la precisión de las predicciones del modelo en un conjunto de datos de validación separado, que no se utiliza para el entrenamiento. Esto le ayuda a evaluar qué tan bien se generaliza el modelo a datos nuevos e invisibles (Brownlee, 2020). “Loss”, y “Value Loss”, ayudan a determinar cómo cambia el rendimiento a lo largo de las épocas y apoyan a diagnosticar cualquier problema con el aprendizaje (Álvarez, 2022). Los valores de “Sensitivity” y “Specificity” son la proporción de clasificación de positivos y negativos por clase. En la AUC, la sensibilidad y la especificidad son distribuciones relacionadas, donde las zonas solapadas entre ellas, indican la capacidad del modelo para discriminar (Brownlee, 2021).

3. Metodología

Se realizó una revisión cuantitativa de una red neuronal, mediante el uso de aprendizaje profundo y técnicas de transferencia de aprendizaje. El objetivo es la clasificación de tres diagnósticos médicos que, sin atención, pueden provocar la muerte fetal o RDS. Se usan las funciones de extracción de características automatizadas, en conjunto de técnicas preestablecidas para la toma de radiografías, sobre una ROI como el objeto de estudio. Se enfoca en la detección de las condiciones anormales en la MPF. Los tres padecimientos a tratar son: el SBR, MAQ y hernia diafragmática (HD), la Figura 1 ilustra el proceso.

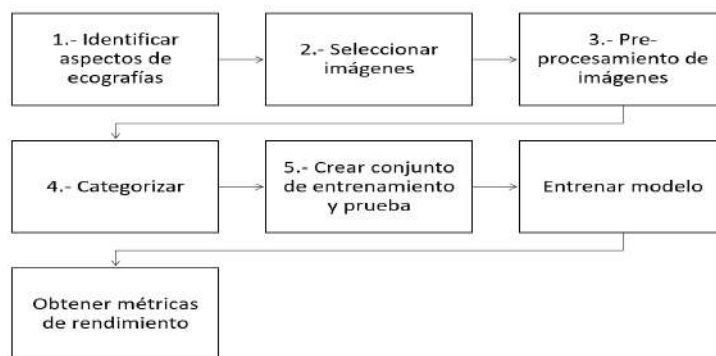


Figura 1. Proceso de implementación.

Se inicia con un análisis sobre qué características ecográficas se van a considerar, posteriormente se realiza la recolección de imágenes y se les aplica un pre-procesamiento. Una vez que los datos están preparados se realiza la categorización de las clases, se crean los conjuntos necesarios, se establecen los parámetros del modelo para efectuar su entrenamiento y finalmente, se obtienen las métricas necesarias.

Identificar aspectos de ecografía. Mediante una investigación documental, se identificaron aspectos de los planos y cortes anatómicos usados en los casos reportados en la literatura.

Además, se amplió el conocimiento adquirido de los métodos de toma de ecografía y detalles técnicos de la operación de las máquinas que generan los sonogramas.

Seleccionar imágenes. Los criterios usados para seleccionar los sonogramas que forman parte de la investigación son: presencia de algún padecimiento, asociado a los tres diagnósticos mencionados; el tipo de plano anatómico, ya sea en corte axial o longitudinal; el tamaño de la imagen, mínimo de 96ppp y 24bits de color en al menos 100x100píxeles. Mediante la técnica de raspado web, se localizaron y seleccionaron las imágenes para la investigación. El uso de los sonogramas obtenidos es de alcance académico.

Pre-procesamiento de la entrada. Se transformaron las entradas en arreglos de 227 por 227 píxeles y de tres canales de color. Finalmente, se realizó un proceso de normalización de las imágenes.

Categorización. Se implementó una técnica de categorización multiclase (one-hot encode) sobre el conjunto de datos para poder usar la clasificación, resultando en tres codificaciones: 0 0 1 = HD, 0 1 0 =MAQ, y 0 0 1 = SBR.

Conjunto de entrenamiento y de prueba. Los índices de cada sonograma se reorganizaron de forma aleatoria usando `s` y con la librería Scikit-learn se creó el conjunto de entrenamiento y de prueba en una relación de 80%-20%.

Crear modelo, seleccionar métricas y compilar modelo. Usando el software TensorFlow y Keras mediante Transfer Learning, se implementaron varios modelos de red profunda AlexNet: a) Usando todas las capas de pre-procesamiento, b) con pre-procesamiento de brillo y contraste y c) sin pre-procesamiento, cuya configuración de optimización es método de descenso de gradiente estocástico basado en la estimación adaptativa “adam”. Las métricas seleccionadas para el entrenamiento y la validación se muestran en la Tabla 1.

Tabla 1. Métricas del modelo.

Entrenamiento	Validación
Categorical Accuracy	Value Categorical Accuracy
Loss (Categorical crossentropy)	Value Loss
AUC (Area Under Curve)	
Sensitivity	
Specificity	

Las métricas de entrenamiento y validación, ayudan a ajustar el modelo.

Entrenar modelo. Para el entrenamiento, se utilizaron 1000 épocas, usando un sub-muestreo de 8 y derivado de que hay pocas imágenes, se utilizó el conjunto de prueba con el propósito de evitar el sobre entrenamiento.

Métricas de rendimiento. Finalmente se ejecutó la predicción del modelo para obtener las métricas, las cuales se muestran en la sección de resultados. El rendimiento macro del modelo, usando variantes en el pre procesamiento se encuentran en la Tabla 2.

Tabla 2. Resultado de métrica de exactitud del modelo

Métrica	AlexNet con pre-procesamiento	AlexNet Contraste y Brillo	AlexNet sin pre-procesamiento
Exactitud categórica	55.56%	77.77%	88.88%
Capas de pre procesamiento	Rotación, Factor = (-0.2, 0.3). Flip= Horizontal y Vertical. Contraste, Factor = [0.1, 0.4]. Brillo = [-0.8, 0.8]. Traslación = Factor Altura = 0.2, Factor ancho = 0.2.	Contraste, Factor = [0.1,0.4] Brillo = [-0.8, 0.8]	NA

Las capas de pre-procesamiento, no apoyaron a obtener un resultado mejor, la mayor exactitud la tiene el modelo sin procesamiento.

4. Resultados

Derivado del método propuesto, se obtuvo una muestra de 42 estudios ecográficos, correspondientes a los tres padecimientos a tratar. La Tabla 3 muestra los valores que contiene el conjunto de datos.

Tabla 3. Padecimiento y plano anatómico.

Sonogramas	Padecimiento	Plano o corte anatómico
12	Secuestro Pulmonar (SBR)	Sagital
16	Malformación Adenoidea Quística Pulmonar (MAQ)	Transversal
14	Hernia Diafragmática (HD)	Transversal

La tabla muestra los padecimientos, el número de imágenes asociadas al mismo, así como el plano o corte anatómico. El conocimiento de los planos anatómicos, habilita a los médicos a verificar los elementos característicos que permiten diagnosticar el padecimiento. Las imágenes encontradas están relacionadas con los casos médicos reportados. El uso es meramente académico y de investigación. Se ha revisado con un médico especialista, que cada sonograma corresponda a la clase señalada.

El conjunto de imágenes durante la investigación, se ilustra en la Figura 2. Los sonogramas fueron obtenidos mediante raspado web y su propósito es para fines académicos.




Figura 2. Parte del dataset utilizado en el modelo

AlexNet, sin pre procesamiento se entrenó durante 1000 épocas, dónde se obtuvo la gráfica de monitoreo, que se ilustra en la Figura 3. Obteniendo como mejor resultado 88.88% de exactitud categórica y un valor de área bajo la curva de 90.43%. En la Tabla 4 se detallan los resultados obtenidos.

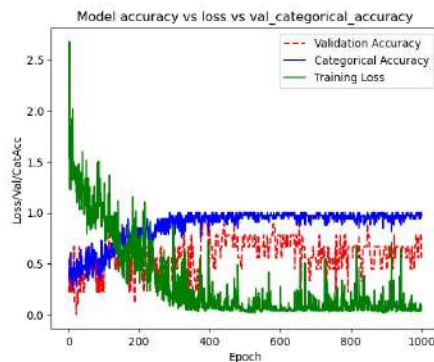


Figura 3. Gráfica de Exactitud categórica versus valor de exactitud categórica versus pérdida

En la época 378 obtuvo su mejor desempeño (88.88%). Iteraciones posteriores, ya no reflejan mayor aprendizaje. En las conclusiones se discutirá este resultado. Por medio de Scikit-Learn se obtuvo los valores micro, ponderado, y macro de las métricas Precisión, Recuerdo, F1 Score, los resultados se encuentran en la Tabla 4 y la gráfica de la matriz de confusión en la Figura 4.

Tabla 4. Resultados macro, ponderado y micro.

	Precisión	Recuerdo	F1 score	Soporte
HD	1.00	1.00	1.00	2
MAQ	1.00	0.80	0.89	5

	SBR		0.67	1.00	0.80	2
micro	Avg		0.89	0.89	0.89	9
macro	Avg		0.89	0.93	0.90	9
weighted	Avg		0.93	0.89	0.89	9
samples	Avg		0.89	0.89	0.89	9
For	HD Precisión:		1.00			
For	MAQ Precisión:		1.00			
For	SBR Precisión:		0.67			
Macro	Precisión:		0.89			

Los valores obtenidos, pueden suponer que el modelo discrimina bien.




Figura 4. Matriz de confusión, ilustra la clasificación de cada padecimiento en la predicción.

El método ModelCheckpoint de la clase callbacks de Keras, fue utilizado para guardar los pesos sinápticos en función del mejor rendimiento del valor de exactitud categórica. También puede usarse para detener el entrenamiento antes de tiempo, si el rendimiento en el conjunto de validación comienza a degradarse.

Para la predicción del modelo se usaron las imágenes mostradas en la Figura 5. Cada uno de los sonogramas, pertenece a una clase, en este caso un valor categórico.



Figura 5. Conjunto de prueba, cada imagen pertenece a una clase: 0 0 1 = HD, 0 1 0 =MAQ, 0 0 1 = SBR. Se observa que sólo un elemento (esquina izquierda superior) ha sido mal clasificado.

Una comparativa de los resultados en el método propuesto y un método de diagnóstico QuantusFLM se desglosa en la Tabla 5.

Tabla 5. Comparativo de métricas de rendimiento del modelo en términos de clasificación

Métricas	AlexNet sin pre procesamiento	QuantusFLM
Macro Precisión:	94.00%	87.00%
Exactitud:	88.89%	NA
AUC (Área bajo la curva):	91.67%	NA
Especificidad	94.44%	86.00%
Sensibilidad	88.89%	91.00%

La red neuronal convolucional, es capaz de obtener métricas similares al método QuantusFLM.

La prevención de padecimientos en el producto durante el desarrollo embrionario, utilizando la ecografía fetal y técnicas de aprendizaje profundo, se posiciona como una herramienta no invasiva y de acercamiento a procedimientos más económicos y de más fácil acceso. Las condiciones de automatización del diagnóstico, como apoyo a los médicos, posiciona al conjunto de redes neuronales como tema de estudio. Así entonces, se motiva a los investigadores a realizar investigación sobre malformaciones, no sólo pulmonar, sino de otros órganos durante la gestación.

5. Conclusiones

El trabajo ayuda facilitando la identificación del padecimiento para su rápido tratamiento, esto debido a que para discriminar entre SBR, MAQ y HD, se requiere un estudio diferencial. El sustento del rendimiento del modelo propuesto, es dado que cada sonograma contiene las características que la red es capaz de percibir para discriminar entre cada padecimiento, se pudo observar que las diferentes opciones con pre-procesamiento, no mostraron mejor resultado que el modelo sin pre-procesamiento. Esta característica puede estar asociada a que los aparatos que generan las imágenes, ya realizan ajustes como el contraste y brillo, las técnicas específicas para la captura de la ecografía están fuera del alcance de este trabajo.

Un modelo sobre ajustado, se desempeña bien en las instancias de entrenamiento, pero mal en la validación. En general implica que la red neuronal, en algunas épocas se ajusta y en otras no se ajusta bien para ambos conjuntos. El mejor resultado, no necesariamente es el que tiene la mayor exactitud, sino que de acuerdo a las pruebas realizadas el que mejor discrimina entre las clases y no está sobre ajustado.

Aunque los tres padecimientos tienen similitud en la ROI, difieren en la forma y el tipo de plano anatómico., la red usa funciones de extracción de características adecuadas para distinguir cada uno de los padecimientos en un grado aceptable. Las métricas de validación fueron útiles para ajustar el modelo, herramientas como Keras facilitaron la tarea de mantener supervisado el entrenamiento.

Es útil considerar un valor, que permita monitorear el desempeño del modelo en los datos de entrenamiento y guiar el proceso de optimización, los ajustes en las capas de pre-procesamiento ayudan a mejorar el rendimiento y la aumentación de los datos, en la mayoría de los casos permite obtener mejores resultados, considerando los resultados obtenidos, el modelo generado es recomendado para apoyar a especialistas en el área médica y para uso didáctico.

Se espera que, en trabajos futuros, se usen técnicas de pre-procesamiento ajustadas manualmente y funciones de eliminación de ruido. La tarea de la adquisición de sonogramas, excede la capacidad de las instituciones que colaboran en este trabajo. Se debe hacer hincapié, en que el sistema de salud, debe considerar una estrategia para generar bancos de datos accesibles a los investigadores de las instituciones de educación superior.

6. Referencias

- Albinagorta Olórtogui, R. y Miranda Tapia, M. (2015). Actualización en la evaluación de la madurez pulmonar fetal por ultrasonido. *Revista Peruana de Ginecología y Obstetricia Vol.61(No.4)*, 433-438.
- Brownlee, J. (2020). 3 Ways to encode categorical variables for Deep Learning. Machine Learning Mastery Ed., <https://machinelearningmastery.com/how-to-prepare-categorical-data-for-deep-learning-in-python/>.

- Brownlee, J. (2020). How to Use Metrics for Deep Learning with Keras in Python. M. L. Mastery, Ed, <https://machinelearningmastery.com/custom-metrics-deep-learning-keras-python/>.
- Brownlee, J. (2021). Sensitivity Analysis of Dataset Size vs. Model Performance, Python Machine Learning, <https://machinelearningmastery.com/sensitivity-analysis-of-dataset-size-vs-model-performance>.
- Chollet, F. (2017). The limitations of deep learning. Deep learning with Python. Word Press, ISBN 9781617294433, 384 Pag.
- Espinosa Arreaga, G. B., and Lucio Aldaz, C. (2020). Diagnóstico de malformaciones congénitas en embarazadas de 30 a 40 años mediante screening ecográfico en el hospital gineco obstétrico pediátrico universitario de guayaquil. Universidad de guayaquil Ecuador.
- Hernández Sancho, R., & Rojas Maruri, M. (2020). Secuestro pulmonar: opciones de tratamiento desde la perspectiva de las teorías embrionarias. Acta Pediátrica de México 41(2), 72-84.
- Álvarez, L., Lozano, C., Bravo, D. (2022). Metodología para el mantenimiento predictivo de transformadores de distribución basada en aprendizaje automático. Ing, vol. 27, no. 3, 2022. e17742
- Vega, R., Gonzáles, J., Valdés, E., Gonzáles, A., del Olmo Bautista, S., y Camino, F. (2015). Malformación adenomatoide quística pulmonar. Diagnóstico prenatal. Cystic adenomatoid malformations of the lung: Prenatal diagnosis, Clínica e Investigación en Ginecología y Obstetricia (Elsevier), 42(2), 83-85.
- Wiley, V., & Lucas, T. (2018). Computer vision and image processing: a paper review. International Journal of Artificial Intelligence Research 2(1), 29-36, 22. 10.29099/ijair.v2i1.42.
- World Health Organization. (2022). WHO recommendations for care of the preterm or low-birth-weight infant., <https://www.who.int/publications/i/item/9789240058262>.
- Zuñiga Vico, i., Gila Sánchez, M., & Hurtado Sánchez, f. (2023.). Diagnóstico ecográfico de la madurez pulmonar fetal. Journal of Physiotherapy and Medical Technology 7, 7-18