

**UNIVERSIDAD NACIONAL DEL CALLAO
FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**



**“DISEÑO DE UN MODELO DE RED NEURONAL
CONVOLUCIONAL PARA MEJORAR EL PROCESO DE
DIAGNÓSTICO DE NEUMONÍA EN LOS PACIENTES DEL
HOSPITAL GUSTAVO LANATTA LUJÁN DE BAGUA,
2024”**

**TESIS PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO DE
SISTEMAS**

AUTORES:

**ALVA ITA JUNIOR EDERSON
ASUNCION RUIZ DANTYA MIRIELLI
HUAMAN LLANOS ALEX ALFREDO**

ASESOR:

VALDIVIA SANCHEZ LUIS ALBERTO

LINEA DE INVESTIGACIÓN: INGENIERÍA Y TECNOLOGÍA

Callao, 2024

PERÚ

1A, ASUNCION RUIZ, HUAMAN LLANOS, ALVA ITA- TESIS PREGRADO-2024



Nombre del documento: 1A, ASUNCION RUIZ, HUAMAN LLANOS, ALVA
ITA- TESIS PREGRADO-2024.docx
ID del documento: efa67564c553041032330467e38ecc9bc946d042
Tamaño del documento original: 2.13 MB

Depositante: IITIS PREGRADO UNIDAD DE INVESTIGACION
Fecha de depósito: 6/5/2024
Tipo de carga: interface
fecha de fin de análisis: 6/5/2024

Número de palabras: 18,005
Número de caracteres: 120,541

Ubicación de las similitudes en el documento



Fuentes de similitudes

Fuentes principales detectadas

| Nº | Descripciones | Similitudes | Ubicaciones | Datos adicionales |
|----|---|-------------|-------------|---|
| 1 | repositorio.uca.edu.pe https://repositorio.uca.edu.pe/handle/documento/2530012012899156urlq_PU_G3.pdf?sequence=1 2 fuentes similares | < 1% | | Palabras idénticas: + 16 (103 palabras) |
| 2 | Documento de otro usuario: 86482 El documento proviene de otro grupo 17 fuentes similares | < 1% | | Palabras idénticas: + 16 (108 palabras) |
| 3 | repositorio.uca.edu.pe https://repositorio.uca.edu.pe/handle/documento/253001413010231811C1C71132_4871896_7_CAYA_05022_... 2 fuentes similares | < 1% | | Palabras idénticas: + 16 (120 palabras) |
| 4 | repositorio.uca.edu.pe https://repositorio.uca.edu.pe/handle/documento/253001308464811UGARCIA_CORTEGANO_CARLOS_612... 1 fuente similar | < 1% | | Palabras idénticas: + 16 (82 palabras) |
| 5 | repositorio.uca.edu.pe Registro Nacional de Trabajos de Investigación - Evaluación... https://repositorio.uca.edu.pe/handle/documento/253001308464811UGARCIA_CORTEGANO_CARLOS_612... 2 fuentes similares | < 1% | | Palabras idénticas: + 16 (94 palabras) |

Fuentes con similitudes fortuitas

| Nº | Descripciones | Similitudes | Ubicaciones | Datos adicionales |
|----|---|-------------|-------------|--|
| 1 | Archivo: 1.A.Fuentes Quezueco Jeremy Huayhua Abregó Jhairo Quezada ... El documento proviene de mi grupo | < 1% | | Palabras idénticas: + 16 (38 palabras) |
| 2 | Documento de otro usuario: 810237 El documento proviene de otro grupo | < 1% | | Palabras idénticas: + 16 (19 palabras) |
| 3 | Documento de otro usuario: 864278 El documento proviene de otro grupo | < 1% | | Palabras idénticas: + 16 (23 palabras) |
| 4 | tesis.uca.edu.pe https://repositorio.uca.edu.pe/handle/documento/25300124219488317L_Borra-Correa.pdf | < 1% | | Palabras idénticas: + 16 (27 palabras) |
| 5 | cybertesis.unmsm.edu.pe Sistema Inteligente basado en redes neuronales para... https://repositorio.uca.edu.pe/handle/documento/2530012613179747borra-c.pdf | < 1% | | Palabras idénticas: + 16 (35 palabras) |

INFORMACIÓN BÁSICA

UNIDAD DE INVESTIGACIÓN:

FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS

TÍTULO:

DISEÑO DE UN MODELO DE RED NEURONAL CONVOLUCIONAL PARA MEJORAR EL PROCESO DE DIAGNÓSTICO DE NEUMONÍA EN LOS PACIENTES DEL HOSPITAL GUSTAVO LANATTA LUJÁN DE BAGUA, 2024

AUTORES:

BACHILLER ALVA ITA, JUNIOR EDERSON

CODIGO ORCID: 0009-0007-8832-2459

DNI: 76168802

BACHILLER ASUNCIÓN RUIZ, DANTYA MIRIELLI

CÓDIGO ORCID: 0009-0009-6898-8856

DNI: 73765249

BACHILLER HUAMAN LLANOS, ALEX ALFREDO

CÓDIGO ORCID: 0009-0006-6780-8161

DNI: 70053909

ASESOR: VALDIVIA SANCHEZ LUIS ALBERTO

CÓDIGO ORCID: 0000-0003-1574-4275

DNI: 07639852

LUGAR DE EJECUCIÓN: HOSPITAL DE APOYO GUSTAVO LANATTA LUJÁN DE BAGUA, AMAZONAS.

UNIDAD DE ANÁLISIS: ÁREA DE IMAGENOLOGÍA DEL HOSPITAL DE APOYO GUSTAVO LANATTA LUJÁN DE BAGUA, AMAZONAS

TIPO: APLICADA

ENFOQUE: CUANTITATIVO

DISEÑO DE INVESTIGACIÓN: EXPERIMENTAL

TEMA OCDE: INGENIERÍA Y TECNOLOGÍA

HOJA DE REFERENCIA DEL JURADO Y APROBACIÓN

MIEMBROS DEL JURADO DE SUSTENTACIÓN

- MG. FARFAN AGUILAR JOSE ANTONIO **PRESIDENTE**
- MG. ANGELINO ABAD RAMOS CHOQUEHUANCA **SECRETARIO**
- MG. ANIVAL ALFREDO TORRE CAMONES **VOCAL**
- DR. RUIZ NIZAMA JOSE LEONOR **SUPLENTE**

ASEDOR: DR. VALDIVIA SANCHEZ, LUIS ALBERTO

N° de Libro: 001

N° de Folio: 030

N° de Acta: 007-2024-II-CTT-IS

Fecha de Aprobación de la tesis:

18 de Mayo de 2024

Resolución de Sustentación:

RESOL.N°361-2024-CF-FIIS



ACTA DE SUSTENTACIÓN



ACTA DE SUSTENTACION POR MODALIDAD DE CICLO TALLER DE TESIS PARA LA OBTENCIÓN DEL TÍTULO PROFESIONAL DE INGENIERO DE SISTEMAS

ACTA N° 007-2024-II-CTT-IS

Siendo las 17:40 horas del día 18 de Mayo del año 2024, encontrándose reunidos en el Auditorio de la FIIS, el **DR. ENRIQUE GARCÍA TALLEDO**, en representación de la Rectora de la UNAC; el **JURADO DE SUSTENTACIÓN DE TESIS** (designado por resolución **361-2024-CF-FIIS**) de la Facultad Ingeniería Industrial y de Sistemas de la Universidad Nacional del Callao, para la evaluación de las Tesis que conllevan a la obtención del Título Profesional de **INGENIERO DE SISTEMAS**, el que se encuentra conformado por los siguientes docentes ordinarios:

| | |
|------------|--------------------------------------|
| PRESIDENTE | MG. FARFÁN AGUILAR JOSÉ ANTONIO |
| SECRETARIO | MG. ANGELINO ABAD RAMOS CHOQUEHUANCA |
| VOCAL | DR. ANIVAL ALFREDO TORRE CAMONES |
| SUPLENTE | DR. RUIZ NIZAMA JOSE LEONOR |

Con el quórum reglamentario de ley y de conformidad con lo establecido por el Reglamento de Grados y Títulos vigente se dio inicio al Acto de Sustentación de la Tesis de los Bachilleres: **ASUNCION RUIZ DANTYA MIRIELLI, HUAMAN LLANOS ALEX ALFREDO** y **ALVA ITA JUNIOR EDERSON**; quienes, habiendo cumplido con los requisitos para optar el Título Profesional de **INGENIERO DE SISTEMAS**, sustentan la tesis titulada **"DISEÑO DE UN MODELO DE RED NEURONAL CONVOLUCIONAL PARA MEJORAR EL PROCESO DE DIAGNÓSTICO DE NEUMONÍA EN LOS PACIENTES DEL HOSPITAL GUSTAVO LANATTA LUJÁN DE BAGUA, 2024"**, cumpliendo con la sustentación en acto público, de manera presencial.

Luego de la exposición, y de la absolución de las preguntas formuladas por el Jurado de Sustentación y efectuadas las deliberaciones pertinentes, **SE ACORDÓ**: Dar por **APROBADO** con la escala de calificación cuantitativa (**16**) y calificación cualitativa (**Muy Bueno**) a la presente tesis, conforme a lo dispuesto en el Art. 24 del Reglamento de Grados y Títulos de la UNAC, aprobado por Resolución de Consejo Universitario N° 150-2023-CU del 15 de junio del 2023.

Se dio por concluida la Sesión a las 18.10 horas del día 18 de Mayo del 2024.


.....
MG. FARFÁN AGUILAR JOSÉ ANTONIO
Presidente


.....
MG. ANGELINO ABAD RAMOS CHOQUEHUANCA
Secretario


.....
DR. ANIVAL ALFREDO TORRE CAMONES
Vocal


.....
DR. JOSE LEONOR RUIZ NIZAMA
Suplente

INFORME N° 007-2024-JS-II-CTT-IS

PARA : DR. PAUL GREGORIO PAUCAR LLANOS
DECANO FIIS

DE : JURADO DE SUSTENTACIÓN DEL II CICLO TALLER DE TESIS DE INGENIERÍA DE SISTEMAS

ASUNTO : INFORME FAVORABLE DEL JURADO DE SUSTENTACIÓN

FECHA : Callao, 18 de Mayo del 2024

Los miembros del Jurado de Sustentación designados por **Resolución N° 361-2024-CF-FIIS** y de acuerdo al Reglamento de Grados y Títulos, aprobado por Resolución 150-2023-CU del 15 de junio de 2023 Art. 71, visto el Acta de Sustentación **N° 007-2024-II-CTT-IS** de Tesis Titulada: **"DISEÑO DE UN MODELO DE RED NEURONAL CONVOLUCIONAL PARA MEJORAR EL PROCESO DE DIAGNÓSTICO DE NEUMONÍA EN LOS PACIENTES DEL HOSPITAL GUSTAVO LANATTA LUJÁN DE BAGUA, 2024"**

Presentado por:
ASUNCION RUIZ DANTYA MIRIELLI
HUAMAN LLANOS ALEX ALFREDO
ALVA ITA JUNIOR EDERSON

Para obtener Título de Profesional de **INGENIERO DE SISTEMAS**, por modalidad de Tesis con Ciclo Taller de Tesis, habiendo obtenido nota aprobatoria de [16] Dieciséis, Muy Bueno.

En tal sentido, los miembros del Jurado de Sustentación informan que no existe observación alguna a dicha Tesis por lo que se da la **CONFORMIDAD**, la cual se debe comunicar a los interesados.

Sin otro particular reiteramos los sentimientos y estima personal.


.....
MG. FARFÁN AGUILAR JOSÉ ANTONIO
Presidente


.....
MG. ANGELINO ABAD RAMOS CHOQUEHUANCA
Secretario


.....
DR. ANIVAL ALFREDO TORRE CAMONES
Vocal


.....
DR. JOSE LEONOR RUIZ NIZAMA
Suplente

DEDICATORIA

Elevamos nuestra gratitud y reconocimiento a Dios, fuente inagotable de fortaleza y sabiduría. A nuestros padres, pilares inquebrantables de amor y sacrificio, les dedicamos este logro excepcional con profundo agradecimiento por su apoyo incondicional y aliento constante. Agradecerles por darnos la vida y por enseñarnos a vivirla con propósito y pasión.

AGRADECIMIENTO

Con profunda gratitud y reverencia, elevamos nuestros corazones en agradecimiento a Dios, fuente inagotable de sabiduría y fortaleza, que iluminó nuestro camino y nos sostuvo para superar cada desafío. A nuestros queridos padres, pilares de nuestra existencia y arquitectos de nuestros sueños; su amor incondicional y apoyo inquebrantable nos han sostenido en cada paso de esta travesía académica. A nuestros estimados docentes, quienes no solo compartieron conocimiento, sino también su pasión por la ciencia y tecnología. Agradecerles por su paciencia, por desafiarnos a crecer y por alentarnos a alcanzar nuestros sueños. Este logro no es solo de nosotros, sino también de quienes nos han acompañado a lo largo de este viaje.

INDICE

| | | |
|-------|---|----|
| I. | PLANTEAMIENTO DEL PROBLEMA | 20 |
| 1.1 | Descripción de la realidad problemática | 20 |
| 1.2 | Formulación del Problema | 27 |
| 1.2.1 | Problema General | 27 |
| 1.2.2 | Problemas Específicos | 27 |
| 1.3 | Objetivos | 27 |
| 1.3.1 | Objetivo General | 27 |
| 1.3.2 | Objetivos Específicos | 27 |
| 1.4 | Justificación | 28 |
| 1.4.1 | Justificación Teórica | 28 |
| 1.4.2 | Justificación Práctica | 28 |
| 1.4.3 | Justificación Económica | 29 |
| 1.4.4 | Justificación social..... | 29 |
| 1.5 | Delimitantes de la Investigación..... | 29 |
| 1.5.1 | Teórica | 29 |
| 1.5.2 | Temporal | 30 |
| 1.5.3 | Espacial..... | 30 |
| II. | MARCO TEÓRICO | 31 |
| 2.1 | Antecedentes | 31 |
| 2.1.1 | Antecedentes Internacionales | 31 |
| 2.1.2 | Antecedente Nacionales..... | 35 |
| 2.2 | Bases Teóricas | 41 |
| 2.2.1 | Inteligencia Artificial..... | 41 |
| 2.2.2 | Machine Learning..... | 42 |

| | | |
|--------|---|----|
| 2.3 | Marco Conceptual..... | 45 |
| 2.3.1 | Neumonía | 45 |
| 2.3.2 | Diagnóstico de la neumonía | 45 |
| 2.3.3 | Radiografía de tórax (RXT)..... | 46 |
| 2.3.4 | Deep learning | 46 |
| 2.3.5 | Redes neuronales artificiales | 47 |
| 2.3.6 | Redes neuronales convolucionales | 47 |
| 2.3.7 | Estructura de una Red Neuronal Convolucional..... | 48 |
| 2.3.8 | Arquitectura de una Red Neuronal Convolucional..... | 49 |
| 2.3.9 | Data Augmentation..... | 52 |
| 2.3.10 | Matriz de Confusión | 53 |
| 2.4 | Definición de Términos Básicos..... | 55 |
| III. | HIPOTESIS Y VARIABLES | 59 |
| 3.1 | Hipótesis | 59 |
| 3.1.1 | Hipótesis General..... | 59 |
| 3.1.2 | Hipótesis Específicas..... | 59 |
| 3.2 | Operacionalización de variables | 59 |
| 3.2.1 | Definición operacional de las variables | 59 |
| 3.2.2 | Operacionalización de las Variables..... | 63 |
| IV. | METODOLOGÍA DEL PROYECTO | 64 |
| 4.1 | Diseño Metodológico..... | 64 |
| 4.2 | Método de Investigación | 64 |
| 4.3 | Población y Muestra..... | 65 |
| 4.4 | Lugar de Estudio | 65 |
| 4.5 | Técnicas e instrumentos para la recolección de la información | 65 |
| 4.6 | Metodología Propuesta de la Solución..... | 65 |

| | | |
|-------|---|-----|
| V. | RESULTADOS..... | 71 |
| 5.1 | Resultados Descriptivos | 71 |
| 5.1.1 | Hipótesis General..... | 71 |
| 5.1.2 | Hipótesis Específicas..... | 75 |
| 5.2 | Resultados Inferenciales..... | 87 |
| 5.2.1 | Hipótesis General..... | 87 |
| 5.2.2 | Hipótesis Específicas..... | 90 |
| VI. | DISCUSIÓN DE RESULTADOS | 102 |
| 6.1 | Contrastación y demostración de la hipótesis con los resultados | 102 |
| 6.2 | Contrastación de los resultados con otros estudios similares | 111 |
| 6.3 | Responsabilidad ética de acuerdo con los reglamentos vigentes | 113 |
| VII. | CONCLUSIONES..... | 114 |
| VIII. | RECOMENDACIONES | 116 |
| IX. | REFERENCIAS..... | 117 |
| X. | ANEXOS..... | 123 |
| | ANEXO 01: Matriz de consistencia..... | 124 |
| | ANEXO 03: Ficha de Registro: Exactitud Post Test | 127 |
| | ANEXO 04: Ficha de Registro: Precisión Pre Test..... | 128 |
| | ANEXO 05: Ficha de Registro: Precisión Post Test | 129 |
| | ANEXO 06: Ficha de Registro: Sensibilidad Pre Test | 130 |
| | ANEXO 07: Ficha de Registro: Sensibilidad Post Test..... | 131 |
| | ANEXO 08: Ficha de Registro: Especificidad Pre Test..... | 132 |
| | ANEXO 09: Ficha de Registro: Especificidad Post Test..... | 133 |
| | ANEXO 10: Consentimiento Informado | 134 |
| | ANEXO 11: Instrumentos Validados..... | 136 |
| | ANEXO 12: Base de Datos SPSS..... | 141 |

| | |
|---|-----|
| ANEXO 13: Modelo de Red Neuronal Convolucional | 142 |
| ANEXO 14: Proceso de Diagnóstico de Neumonía con el Diseño Implementado..... | 156 |
| ANEXO 15: Lugar de Investigación | 157 |
| ANEXO 16: Solicitud de Apoyo al Diagnóstico de Rayos X | 158 |
| ANEXO 17: Reporte de Autenticidad y Similitud | 159 |

ÍNDICE DE TABLAS

| | |
|--|----|
| Tabla 1. Operacionalización de las Variables | 63 |
| Tabla 2. Distribución de las radiografías..... | 66 |
| Tabla 3. Estadísticos descriptivos de la hipótesis general | 72 |
| Tabla 4. Estadísticos descriptivos de la hipótesis específica 1 | 75 |
| Tabla 5. Estadísticos descriptivos de la hipótesis específica 2..... | 78 |
| Tabla 6. Prueba de muestras relacionadas del diagnóstico de neumonía | 89 |
| Tabla 7. Estadísticos de muestras relacionadas del diagnóstico de neumonía | 89 |
| Tabla 8. Correlaciones de muestras relacionadas del diagnóstico de neumonía | 89 |
| Tabla 9. Prueba de normalidad de la exactitud pre y post test de los datos | 90 |
| Tabla 10. Prueba de muestras relacionadas de la exactitud del diagnóstico de neumonía | 92 |
| Tabla 11. Estadísticos de muestras relacionadas de la exactitud diagnóstico de neumonía | 92 |
| Tabla 12. Correlación de muestras relacionadas de la exactitud de diagnóstico de neumonía | 92 |
| Tabla 13. Prueba de normalidad de la precisión pre y post test de los datos | 93 |
| Tabla 14. Prueba de muestras relacionadas de la precisión del diagnóstico de neumonía | 95 |
| Tabla 15. Estadísticos de muestras relacionadas de la precisión del diagnóstico de neumonía | 95 |
| Tabla 16. Correlación de muestras relacionadas de la precisión de diagnóstico de neumonía | 95 |
| Tabla 17. Prueba de normalidad de la sensibilidad pre y post test de los datos | 96 |
| Tabla 18. Prueba de muestras relacionadas de la sensibilidad del diagnóstico de neumonía | 98 |
| Tabla 19. Estadísticos de muestras relacionadas de la sensibilidad del diagnóstico de neumonía | 98 |

| | |
|---|-----|
| Tabla 20. Correlación de muestras relacionadas de la sensibilidad de diagnóstico de neumonía | 98 |
| Tabla 21. Prueba de normalidad de la especificidad pre y post test de los datos | 99 |
| Tabla 22. Prueba de muestras relacionadas de la especificidad del diagnóstico de neumonía | 101 |
| Tabla 23. Estadísticos de muestras relacionadas de la especificidad del diagnóstico de neumonía | 101 |
| Tabla 24. Correlación de muestras relacionadas de la especificidad de diagnóstico de neumonía | 101 |
| Tabla 25. Matriz de Consistencia | 124 |
| Tabla 26. Ficha de Registro de Exactitud Pre Test | 126 |
| Tabla 27. Ficha de Registro de Exactitud Post Test..... | 127 |
| Tabla 28. Ficha de Registro de Precisión Pre Test | 128 |
| Tabla 29. Ficha de Registro de Precisión Post Test..... | 129 |
| Tabla 30. Ficha de Registro de Sensibilidad Pre Test..... | 130 |
| Tabla 31. Ficha de Registro de Sensibilidad Post Test..... | 131 |
| Tabla 32. Ficha de Registro de Especificidad Pre Test..... | 132 |
| Tabla 33. Ficha de Registro de Especificidad Post Test | 133 |

ÍNDICE DE FIGURAS

| | |
|---|----|
| Figura 1. Muertes de neumonía a nivel municipal por edad..... | 20 |
| Figura 2. Incidencia acumulada de neumonías en menores de 5 años..... | 22 |
| Figura 3. Tendencia de neumonías en mayores de 60 años..... | 23 |
| Figura 4. Incidencia acumulada de neumonía en mayores..... | 24 |
| Figura 5. Proceso actual de diagnóstico de la neumonía..... | 26 |
| Figura 6. Machine Learning y Deep Learning como subconjuntos de la IA..... | 42 |
| Figura 7. Técnicas del aprendizaje automático..... | 44 |
| Figura 8. Rayos X de tórax señalizadas..... | 46 |
| Figura 9. Arquitectura de la red neuronal convolucional..... | 48 |
| Figura 10. Arquitectura AlexNet..... | 50 |
| Figura 11. Arquitectura ResNet..... | 51 |
| Figura 12. Arquitectura InceptionV3..... | 52 |
| Figura 13. Comparación de diferentes modelos..... | 52 |
| Figura 15. Matriz de Confusión..... | 54 |
| Figura 16. Deep learning Software Architecture..... | 56 |
| Figura 17. Etapas de la Metodología Propuesta..... | 65 |
| Figura 18. Construcción del Modelo..... | 67 |
| Figura 19. Épocas..... | 68 |
| Figura 20. Matriz de Confusión Dataset Test..... | 68 |
| Figura 21. Métricas del Modelo..... | 69 |
| Figura 22. Interfaz de la Detección de la Neumonía..... | 69 |
| Figura 23. Predicción de un paciente con neumonía..... | 70 |
| Figura 24. Predicción de un paciente sin neumonía..... | 70 |
| Figura 25. Gráfico de barras de diagnóstico de neumonía pre y post test..... | 73 |
| Figura 26. Histograma de curva normal de diagnóstico de neumonía Pre-Test..... | 74 |
| Figura 27. Histograma de curva normal de diagnóstico de neumonía Post-Test..... | 74 |
| Figura 28. Gráfico de barras de exactitud del diagnóstico de neumonía pre y post test..... | 76 |
| Figura 29. Histograma de la curva normal de la exactitud del proceso de diagnóstico Pre-Test..... | 77 |

| | |
|--|----|
| Figura 30. Histograma de la curva normal de exactitud de diagnóstico Post-Test | 77 |
| Figura 31. Gráfico de barras de precisión del diagnóstico de neumonía pre y post test | 79 |
| Figura 32. Histograma de la curva normal de la precisión del proceso de diagnóstico Pre-Test | 80 |
| Figura 33. Histograma de la curva normal de la precisión del proceso de diagnóstico Pre-Test | 80 |
| Figura 34. Estadísticos descriptivos de la hipótesis específica 3 | 81 |
| Figura 35. Gráfico de barras de sensibilidad de diagnóstico de neumonía pre y post test | 82 |
| Figura 36. Histograma de la curva normal de sensibilidad de proceso de diagnóstico Pre-Test | 83 |
| Figura 37. Histograma de la curva normal de sensibilidad de proceso de diagnóstico Post-Test..... | 83 |
| Figura 38. Estadísticos descriptivos de la hipótesis específica 4 | 84 |
| Figura 39. Gráfico de barras de especificidad de diagnóstico de neumonía pre y post test | 85 |
| Figura 40. Histograma de la curva normal de especificidad de proceso de diagnóstico Pre-Test | 86 |
| Figura 41. Histograma de la curva normal de especificidad de proceso de diagnóstico Post-Test..... | 86 |
| Figura 42. Prueba de normalidad del pre y post test de los datos..... | 87 |

RESUMEN

El presente trabajo de investigación tiene como objetivo general diseñar una herramienta tecnológica que permita mejorar el proceso de diagnóstico de neumonía a través de una radiografía de tórax. Esta herramienta, busca ayudar al personal médico del Hospital General Gustavo Lanatta Luján en la realización de diagnósticos de neumonía y de esta manera el tratamiento del paciente sea oportuno.

La solución tecnológica desarrollada en esta investigación es un diseño de un modelo predictivo basado en algoritmos de aprendizaje automático. Para la elaboración del modelo, se utilizó un algoritmo de aprendizaje supervisado basado en redes neuronales convolucionales y un dataset de 624 imágenes de radiografías de tórax, estos datos se obtuvieron del área de Imagenología del Hospital General Gustavo Lanatta Luján de Bagua, utilizando la técnica del fichaje. Se logró en la fase de entrenamiento una precisión del modelo de un 91.98%, el cual es un porcentaje elevado de precisión y se procedió a realizar las pruebas en el área respectiva, logrando obtener una aceptación alta de la solución tecnológica. Referente al tipo de diseño metodológico, se aplicó un diseño de investigación experimental, de tipo aplicada y de nivel explicativa, con ello se estableció el procedimiento y metodología adecuada para la elaboración del trabajo de investigación.

El diseño del modelo de red neuronal convolucional generó mejoras significativas en las métricas clave del diagnóstico de neumonía. Se observaron incrementos notables del 5.1438% en el proceso de diagnóstico de neumonía; así como, del 4.6758% en la exactitud, 6.245% en la precisión, 4.5867% en la sensibilidad y un 5.0675% en la especificidad. Estos resultados muestran un impacto positivo, directo y estadísticamente significativo del diseño, respaldando las hipótesis planteadas y la eficacia del diseño del modelo para la mejorar del proceso de diagnóstico de neumonía.

Palabras clave: Aprendizaje automático, diagnóstico de neumonía, modelo predictivo, radiografía de tórax, red neuronal convolucional

ABSTRACT

The overarching objective of this research is to develop a technological tool to enhance the process of diagnosing pneumonia through a chest X-ray. This tool is designed to assist the medical staff of the General Hospital Gustavo Lanatta Luján in the diagnosis of pneumonia and thus the treatment of the patient in a timely manner.

The technological solution developed in this research is a predictive model design based on machine learning algorithms. The model was developed using a supervised learning algorithm based on convolutional neural networks and a dataset of 624 images of chest X-rays. These data were obtained from the imaging area of the General Hospital Gustavo Lanatta Luján de Bagua, using the technique of punching. The model achieved an accuracy of 91.98% during the training phase, which is a high level of accuracy. Tests were carried out in the respective area, and the results were highly satisfactory. With regard to the methodological design, an experimental research design was applied, of an applicative and explanatory type. This established the appropriate procedure and methodology for the elaboration of the research work.

The convolutional neural network model design yielded considerable enhancements in key metrics associated with the diagnosis of pneumonia. Notable increases of 5.1438% were observed in the pneumonia diagnostic process, as well as 4.6758% in accuracy, 6.245% in precision, 4.5867% in sensitivity and 5.0675% in specificity. The results demonstrate a positive, direct and statistically significant impact of the design, supporting the hypotheses and the efficacy of the model design in improving the pneumonia diagnostic process.

Keywords: Machine learning, pneumonia diagnosis, predictive model, chest x-ray, convolutional neural network

INTRODUCCIÓN

En la actualidad, la neumonía es una enfermedad que es complicada detectarla en una etapa temprana, y cuando se encuentra en una fase tardía, provoca la muerte. Adicional a ello, la falta de especialistas, personal técnico encargado y hospitales en el país genera una alta tasa de mortalidad a causa de esta enfermedad. La presente investigación ha sido motivada por el deseo de mejorar el proceso de diagnóstico de neumonía en una etapa temprana utilizando machine learning.

Para la implementación de esta solución tecnológica, ha sido necesario analizar las principales causas de los problemas en el proceso de diagnóstico en el área de Imagenología del Hospital General Gustavo Lanatta Luján. Los actuales sistemas de automatización basados en algoritmos tradicionales tardan demasiado tiempo, no son adaptables a nuevas imágenes y la precisión de la misma es demasiada baja.

El desarrollo del trabajo de investigación inicia con el primer capítulo, donde se menciona el planteamiento del problema, realidad problemática, formulación del problema general y específicos, el objetivo general y específicos, puntos cruciales para comprender el estudio. Así como, se muestran las justificaciones y limitantes del estudio.

En el segundo capítulo, se encuentran los antecedentes del estudio, los cuales sirvieron de base para el desarrollo del trabajo. Además, se muestra las bases teóricas con los principales conceptos relacionados a redes neuronales, machine learning, deep learning e inteligencia artificial. También se mencionan los principales conceptos y la definición de términos básicos.

En el tercer capítulo, se presenta la hipótesis general y específicas de la investigación; así como, la definición operacional de la variable dependiente e independiente.

En el cuarto capítulo, se muestra la metodología del proyecto, considerando el diseño metodológico de la investigación, método del mismo, población y

muestra, lugar de estudio y el instrumento que se ha utilizado para la recolección de la información.

En el quinto y sexto capítulo, se presentan los resultados descriptivos e inferenciales y la discusión de los mismos, respectivamente. Finalmente, se presentan las conclusiones y recomendaciones del trabajo de investigación; los cuales brindarán una base para futuros trabajos de investigación que utilicen el mismo tema y puedan ser utilizados para implementar el mismo modelo, de tal manera que pueda ser usado en el área de Imagenología con el objetivo de poder tratar la neumonía, la cual tiene un alto índice de mortalidad a nivel mundial.

I. PLANTEAMIENTO DEL PROBLEMA

1.1 Descripción de la realidad problemática

Actualmente, la neumonía es una de las enfermedades respiratorias que generan mayores desafíos en el mundo de la medicina, con tasas de morbilidad y mortalidad muy altas. Según la Organización Mundial de la Salud (2021), la neumonía es la principal causa individual de mortalidad infantil en todo el mundo. Se calcula que la neumonía mató a unos 920 136 niños menores de 5 años en 2015, lo que supone el 15% de todas las defunciones de niños menores de 5 años a nivel mundial.

A nivel mundial Dadonaite y Roser (2019) mencionaron que, 2.56 millones de personas murieron por neumonía. De estas, casi un tercio de las víctimas fueron niños menores de cinco años y el grupo con mayores muertes por neumonía fue la población de 70 años a más, tal y como lo muestra la figura 1.

Figura 1. Muertes de neumonía a nivel mundial por edad



Fuente: Our World in Data (2019)

Según el Fondo de las Naciones Unidas para la Infancia (2022) el 84% de los niños fallecidos a causa de la neumonía se concentra

en 30 países de África Subsahariana y Asia. Aquí, los niños tienen 60 veces más probabilidades de verse afectados y morir debido a la situación socioeconómica en los países más pobres. Dentro de estos, cinco países representan más de la mitad de todos los casos mortales de neumonía infantil: Nigeria es el país que más defunciones registra, con 162.000. Le siguen La India con 127.000, Pakistán con 58.000, República Democrática del Congo con 40.000 y Etiopía con 32.000.

A nivel mundial los médicos siguen un estándar para realizar un correcto diagnóstico de neumonía, se basan en un examen físico, evaluando diversos signos y síntomas, luego el médico para validar la existencia de neumonía procede a realizar exámenes de imágenes, los cuales pueden ser una tomografía computarizada torácica (TAC) o una radiografía torácica, a pesar del surgimiento de nuevas técnicas de diagnóstico por imagen. Ante una sospecha clínica, hoy en día la realización de una radiografía de tórax es una de las técnicas más ampliamente empleadas en la práctica habitual para el diagnóstico de neumonías (Consejo Nacional de Colegios Farmacéuticos, 2019).

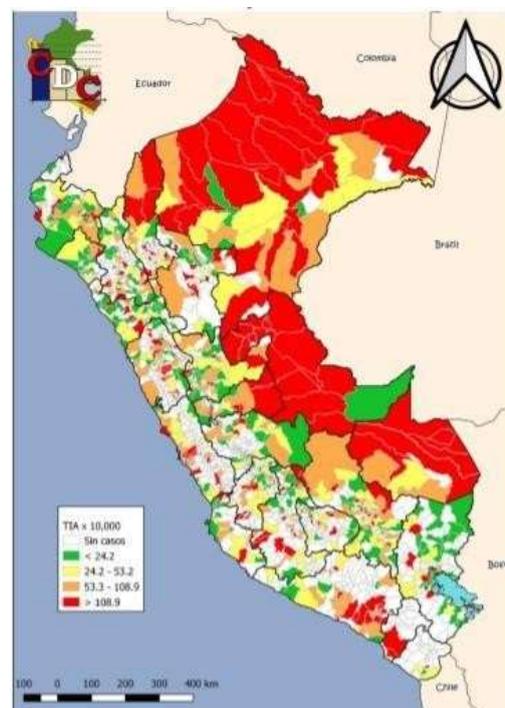
Según un informe técnico de la Organización Panamericana de la Salud (2017), muestra que en 1999 fallecieron 550.000 niños menores de 5 años en América Latina y el Caribe a causa de la neumonía. La cifra más alta de mortalidad la registró Haití con un 23% de defunciones, seguido de Guatemala con un 17%, Nicaragua con un 16% y Bolivia con un 14%. Además, la incidencia de neumonía en Latinoamérica es preocupante, se calcula cerca de 120 mil casos anuales registrados en Argentina, 170 mil en Chile y 1 millón 920 mil casos en Brasil.

En el Perú las cifras de neumonía han ido en incremento desde el 2015. En el 2018 se registró 30 733 casos de neumonía, la cifra más alta en los últimos cinco años. En los seis primeros meses del

2013 se registró 27 447 casos de neumonía y 20 395 en el 2014, sin embargo, a partir del 2015, la cifra ha ido aumentando. Lo mismo ocurre mismo ocurre con las muertes a causa de esta enfermedad entre enero y junio murieron 679 personas y 501 en 2014 (Fows, 2018).

Además, en nuestro país, el 40% de los casos de neumonía ocurre en niñas y niños menores de 5 años. En este grupo los niños menores de un año tienen riesgos más elevados que los niños entre 1 y 4 años. Es importante destacar que los riesgos se elevan notablemente en varias regiones de la selva. En Ucayali, por ejemplo, la incidencia es de 271 por cada 10, 000 niños menores de 5 años, mientras que en Madre de Dios y Loreto es de 208 y 191 respectivamente (UNICEF,2020).

Figura 2. Incidencia acumulada de neumonías en menores de 5 años



Fuente: Centro Nacional de Epidemiología, Prevención y Control de Enfermedades (2019)

En el análisis de los casos de neumonías por departamentos, se puede apreciar que la región oriental (selva), se concentra las tasas de incidencias más elevadas de neumonías según la figura 02 mostrada.

Según el boletín epidemiológico del Ministerio Nacional de Salud (2020), los casos graves de neumonías son hospitalizados, en el 2018 fueron hospitalizados 10,513 menores de 5 años, lo que significa un 36,1% de tasa de hospitalización. En el 2019 se han notificado 191 defunciones por neumonía no que significa una tasa de letalidad del 0.75 muertes por cada 100 episodios de neumonía.

La neumonía también afecta de manera significativa a los mayores de 60 años ya que presenta una tendencia al incremento en los últimos 6 años, tal como lo muestra la figura 03. En el 2019 se ha notificado 20,823 episodios de neumonía, lo que representa una incidencia acumulada de 62.2 episodios de neumonía por cada 10 000 mayores de 60 años.

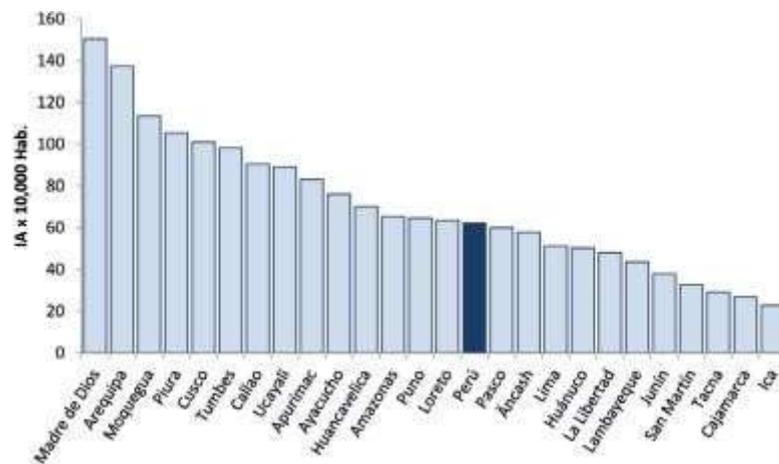
Figura 3. Tendencia de neumonías en mayores de 60 años



Fuente: Centro Nacional de Epidemiología, Prevención y Control de Enfermedades (2019)

El departamento de Madre de Dios presenta la tasa de incidencia por neumonías más elevada con $150.5 \times 10\,000$ mayores de 60 años, seguido de Arequipa, Moquegua, Piura y Cusco, muy por encima del nivel nacional. Por otra parte, los departamentos de Ica, Cajamarca, Tacna y San Martín son las que presentan las tasas más bajas, muy por debajo del nivel nacional.

Figura 4. Incidencia acumulada de neumonía en mayores de 60 años por departamento



Fuente: Centro Nacional de Epidemiología, Prevención y Control de Enfermedades (2019)

La Neumonía representa un desafío crítico en la atención médica del Hospital de Bagua, en donde los pacientes que padecen esta enfermedad han sido afectados negativamente al no ser tratados oportunamente. Lo que ha generado daños en órganos importantes como el pulmón y en otros casos ha ocasionado la muerte. Es por ello, que la tasa de mortalidad ha aumentado considerablemente debido a la neumonía y seguirá afectando al Hospital de Bagua. Actualmente, el proceso de diagnóstico de neumonía (ver figura 5) está basado en técnicas de análisis de imágenes, como radiografías e impone una carga significativa para los profesionales de la salud. La fatiga y el estrés laboral resultantes prolongan los

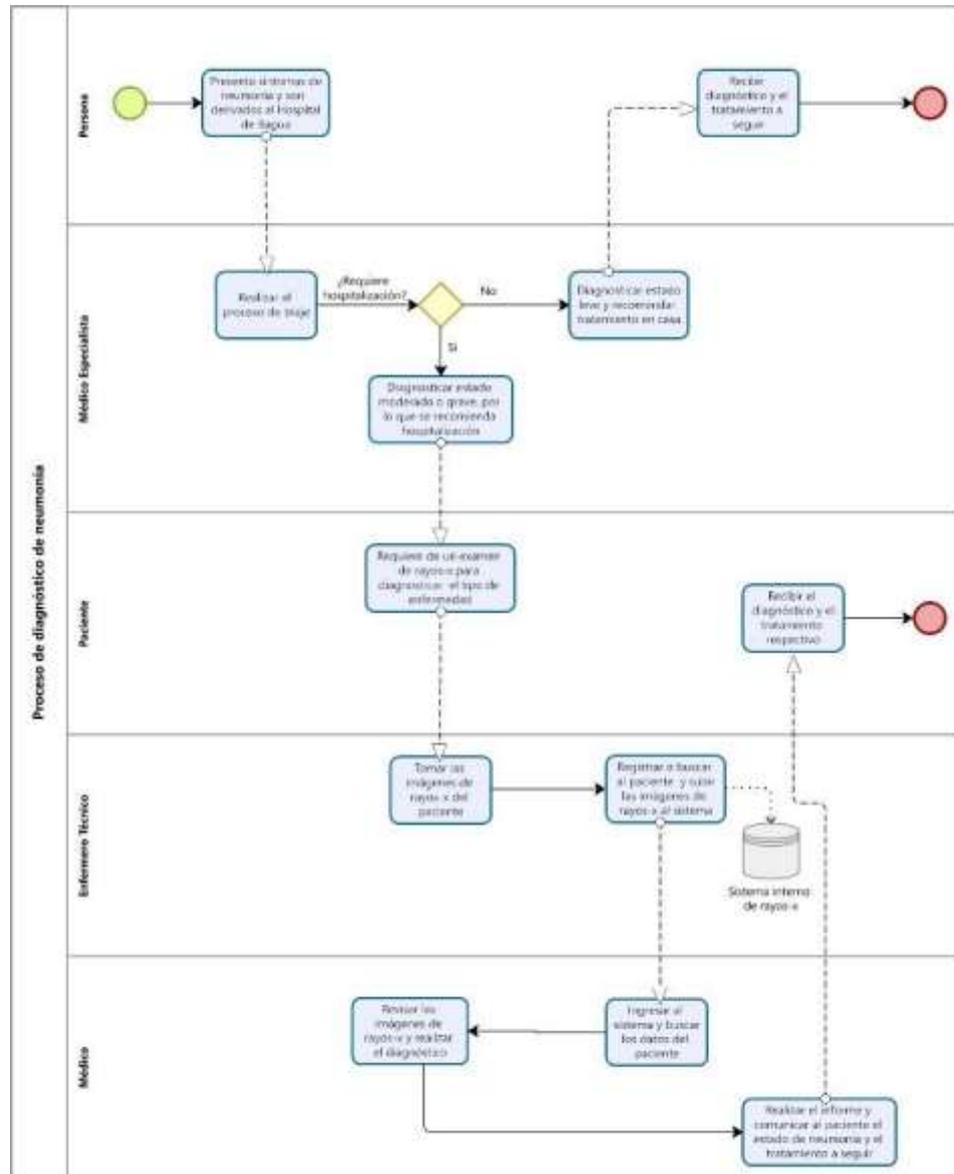
tiempos de diagnóstico, afectando la detección temprana de la enfermedad.

En este sentido la presente investigación busca diseñar un modelo predictivo basado en redes neuronales convolucionales para optimizar el proceso de diagnóstico y facilitar la detección temprana de la neumonía en el Hospital de Bagua, brindando pronósticos y tratamientos oportunos a los pacientes.

El proceso de diagnóstico inicia cuando una persona con síntomas de neumonía acude o es trasladado por un centro de salud al hospital de Bagua, donde lo primero que se realiza es determinar el estado de salud del paciente, para ello se deberá realizar un proceso de triaje, en el cual se determinará si el paciente será tratado en casa o requieran una hospitalización inmediata. Es por eso por lo que, un doctor especialista revisa al paciente y determinade acuerdo a su estado actual el tipo de tratamiento a seguir. En caso de que el paciente tenga un estado leve, deberá ser tratado en casa con medicación; por otra parte, si el paciente se encuentra en un estado moderado grave, requerirá de hospitalización.

Es preciso mencionar que, para los pacientes hospitalizados que requieran un análisis más profundo sobre el avance de la neumonía, se deberá hacer uso de los rayos-x para la toma de radiografía de tórax y determinar la gravedad del caso, para ello el enfermero técnico, encargado del área de radiografía, procederá a la toma de rayos-x, para luego subir las imágenes al sistema del Hospital de Bagua. Finalmente, el médico de turno revisará las imágenes de rayos-x en el sistema e informará al paciente de su estado actual y el tratamiento a seguir.

Figura 5. Proceso actual de diagnóstico de la neumonía



1.2 Formulación del Problema

1.2.1 Problema General

¿De qué manera el diseño de un modelo de red neuronal convolucional mejora el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?

1.2.2 Problemas Específicos

PE1. ¿De qué manera el diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?

PE2 ¿De qué manera el diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?

PE3. ¿De qué manera el diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?

PE4. ¿De qué manera el diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?

1.3 Objetivos

1.3.1 Objetivo General

Diseñar un modelo de red neuronal convolucional para mejorar el proceso de diagnóstico de neumonía en los pacientes de un Hospital de Bagua-Amazonas.

1.3.2 Objetivos Específicos

O.E.1. Diseñar un modelo de red neuronal convolucional para mejorar la exactitud en el proceso de diagnóstico de la

neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

O.E.2. Diseñar un modelo de red neuronal convolucional para mejorar la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

O.E.3. Diseñar un modelo de red neuronal convolucional para mejorar sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

O.E.4. Diseñar un modelo de red neuronal convolucional para mejorar especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

1.4 Justificación

1.4.1 Justificación Teórica

Considerando la existencia de una amplia gama de diversos tipos de redes neuronales y su aplicación en diferentes campos profesionales, se ha llevado a cabo una revisión sistemática para consolidar la información teórica esencial. Este proceso nos permitirá diseñar un modelo predictivo basado en redes neuronales convolucionales para el diagnóstico de la neumonía.

1.4.2 Justificación Práctica

Es de vital importancia contribuir al sector salud mediante la implementación de una herramienta basada en redes neuronales convolucionales para el diagnóstico de la neumonía. En la actualidad, la elevada tasa de mortalidad a causa de esta enfermedad en nuestro país exige la necesidad de un diagnóstico temprano; por lo que, esta investigación busca ofrecer una solución que facilite

tratamientos oportunos y reduzca la pérdida de vidas humanas.

1.4.3 Justificación Económica

El diagnóstico oportuno de la neumonía, facilitado por la presente propuesta, no solo puede reducir la duración de la hospitalización y los costos asociados, sino que también mejora significativamente la calidad de vida de los pacientes. Adicionalmente, la implementación de esta tecnología en el ámbito de la salud tiene el potencial de optimizar los recursos hospitalarios y del sistema de salud en general.

1.4.4 Justificación social

La implementación de un modelo de red neuronal convolucional para mejorar el diagnóstico de neumonía tiene un impacto significativo en la sociedad al mejorar la atención médica y la salud pública en general. Los beneficiarios directos de esta investigación son los pacientes que pueden recibir un diagnóstico más rápido y preciso de neumonía, lo que conduce a un tratamiento más oportuno y efectivo. Además, los sistemas de salud se benefician al reducir la carga de trabajo de los profesionales médicos y al optimizar los recursos disponibles. En última instancia, la implementación de esta tecnología puede contribuir a la reducción de la mortalidad y morbilidad asociada con la neumonía, mejorando así la calidad de vida de la población en general.

1.5 Delimitantes de la Investigación

1.5.1 Teórica

Se empleará la teoría de redes neuronales convolucionales correspondiente al campo de aprendizaje profundo. Esta elección se basa en la robustez y eficacia demostrada por esta teoría en contextos similares, asegurando una base

sólida para el diseño e implementación del modelopredictivo.

1.5.2 Temporal

Las fases de planteamiento, desarrollo, implementación y verificación de los resultados se restringen al año 2023, periodo en el que se considera factible su aplicación. Esta limitación temporal garantiza la coherencia y relevancia del estudio con respecto al contexto específico del hospital.

1.5.3 Espacial

La recolección y validación de los resultados se realizará mediante un modelo predictivo para el diagnóstico de la neumonía utilizando redes neuronales convolucionales con los pacientes del Hospital General de Bagua. A pesar de la confidencialidad de los datos de esta población, se busca maximizar la utilidad de la investigación, considerando las limitaciones espaciales inherentes.

II. MARCO TEÓRICO

2.1 Antecedentes

2.1.1 Antecedentes Internacionales

En la Universidad de Granada, (De la Vega Jiménez, 2021) desarrolló la tesis “Aplicación de redes neuronales convolucionales profundas al diagnóstico asistido de la enfermedad de Alzheimer”. El objetivo de la tesis fue implementar una red neuronal convolucional que sea capaz de tomar como entrada una imagen cerebral 3D y clasificarlas en tres clases posibles (Alzheimer’s disease, Mild cognitive impairment y cognitively normal) según el grado de desarrollo de la enfermedad. Para el desarrollo de una red neuronal convolucional se estudió la profundidad adecuada de las redes, la importancia del preprocesamiento de imágenes médicas, el uso de las técnicas de transferencia de aprendizaje y de aumento de datos como herramientas para reducir los efectos del problema que supone tener pocos datos. Como resultados, se observó que el procedimiento usado consiguió una exactitud del 68%, y con un conjunto de datos independientes el modelo alcanzó un 70% de exactitud, un resultado bueno teniendo en cuenta el tamaño de la muestra. En conclusión, el aumento de profundidad de las redes neuronales es de vital importancia para diagnosticar el Alzheimer, el procesamiento de imágenes es un proceso fundamental para abarcar problemas médicos, el uso de la técnica de aumento de datos y el uso de redes pre entrenadas con imágenes de otras enfermedades aportan mejoras notables en el modelo. Además, es de vital importancia el uso del aprendizaje automático y las redes neuronales convolucionales para realizar el diagnóstico de distintas enfermedades, así como

aplicar la técnica transfer learning para afrontar el problema de clasificación.

En la tesis titulada “Prototipo de Herramienta de Software con Aprendizaje de Máquinas para la diferenciación de Neumonía Bacteriana o Viral con el uso de Radiografías de Tórax” elaborado por (Martinez Tarazona, 2021) en la Universidad Autónoma De Bucaramanga, Colombia, plantea desarrollar un prototipo de sistema que permita la clasificación de pacientes según el tipo de neumonía, basado en el análisis de los rayos-x de tórax usando aprendizaje profundo. El diseño metodológico de la investigación es aplicada, explicativa, cuantitativa, y propone incorporar actividades realizadas en la investigación, tomando en cuenta la infraestructura tecnológica (Arquitectura, Hardware), el procesamiento de los datos (desde descartar imágenes ilegibles hasta la segmentación de los rayos-x y el aumento de los datos), la metodología de prueba para la validación y el diseño del prototipo. En la aplicación de tecnologías propone un análisis comparativo de los datos con Matlab y Python, y realiza una comparación entre 3 tipos de modelos de redes neuronales de distinta precisión, para clasificar imágenes, una red de costo computacional bajo, medio y alto que son las redes VGG 16, Resnet-50 y Xception con el fin de elegir la metodología de métricas y para la reducción de problemas binarios y conseguir una mayor eficacia en la clasificación multiclase, se decidió utilizar una máquina de soporte vectorial. Por ello se optó usar el algoritmo de selección, que obtiene las características principales, por medio de un análisis de los vecinos o datos próximos, es llamado “Algoritmo FSCNCA”. Y para el diseño se eligió el prototipado evolutivo porque es un modelo de diseño rápido. Asimismo se distribuyeron las

imágenes de rayos-x en Neumonía bacteriana (2780), neumonía vírica (1493) y sin neumonía (1583), un total de 5.863 imágenes y antes de distribuir en 3 carpetas (entrenamiento, prueba, validación) se balanceo los grupos tomando como muestra el 10% correspondiente al número de imágenes de cada clase, para aplicar técnicas de aumento de datos, teniendo en cuenta el porcentaje y la diferencia existente entre las clases, se logró obtener un dataset de 15.000, de los cuales se tomó el 60% para el training (12000), 20% para Test y otro 20% para la validación. Los resultados obtenidos en el análisis para definir el lenguaje del modelo, y con gran diferencia entre ambos, se demostró que con Matlab había más precisión, sensibilidad y especificidad. Y durante el entrenamiento de las 3 redes diferentes (Xception, Resnet-50, Vgg16) se determinó que Xception sería la elegida por tener mejores resultados respecto a la sensibilidad, (se desarrollaron los test con dos diferentes bases de datos de prueba) aunque solo logro la mitad del entrenamiento debido a su alto coste computacional.

En la tesis titulada “Método de apoyo para diagnóstico en imágenes radiológicas de neumonía pediátrica mediante técnicas de inteligencia artificial” elaborada por (Bustos Jiménez, 2022) en la Universidad El Bosque, Colombia, Bogotá. Se plantea como objetivo desarrollar una IA basado en aprendizaje profundo que ayude al personal médico a diagnosticar la neumonía pediátrica, usando redes neuronales convolucionales. Para el desarrollo del proyecto, la metodología comprende 3 etapas: Fase de diseño y entrenamiento del modelo: Diseño del dataset (Base de datos, Preprocesamiento, procesamiento, Normalización), Arquitectura (Lenguaje de programación), validación del

diseño, y el entrenamiento CNN, como segunda etapa implementación (Backend y Frontend) y finalmente la validación estadística para la construcción del modelo de acuerdo con los objetivos establecidos. Para la elección del modelo de red neuronal se realizó una investigación entre modelos como método residual , VGG16 , Xception y Inception v3 donde se observó el valor de sus indicadores como precisión, sensibilidad y especificidad siendo este último modelo el mejor, asimismo se optó por el uso de redes neuronales convolucionales (CNN) por ser una herramienta que trabaja con grandes conjuntos de datos e imágenes etiquetadas (datasets), donde toma datos sin procesar como entrada y realiza operaciones convolucionales, para aprender y determinar patrones de cada imagen radiológica permitiendo un diagnóstico y tratamiento temprano. Para el entrenamiento del modelo se hizo uso del dataset “Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification” que contiene 5,864 imágenes radiográficas de tórax en pacientes pediátricos, cada imagen tiene diferentes dimensiones y están clasificadas entre neumonía y normales, las cuales se distribuyeron en Train, Val y test. El funcionamiento del modelo estuvo basado en combinaciones binarias de 0 y 1. Los resultados obtenidos demostraron que la transferencia de aprendizaje Secuencial, logra obtener menos parámetros y mayor precisión que con ResNet o ConvNet y con respecto a la clasificación de imágenes el modelo permitió mejorar el rendimiento para ayudar al personal médico con el fin de garantizar una atención más óptima en el diagnóstico de neumonía pediátrica.

2.1.2 Antecedente Nacionales

En la investigación titulada “Diseño de un modelo predictivo para la detección temprana de la Neumonía utilizando Deep Learning y Visión Computacional” realizada por (Aguilar Guizado, y otros, 2020) en la Universidad Tecnológica del Perú, se planteó como objetivo diseñar un modelo predictivo para la detección temprana de la neumonía utilizando Deep Learning y Visión Computacional. Para lograr el diseño predictivo los autores propusieron una metodología compuesta por cinco fases, las cuales son: selección del conjunto de datos, preprocesamiento de las imágenes del conjunto de datos, aumento de datos, transferencia de aprendizaje y la clasificación en conjunto a través de tres arquitecturas empleadas, con el objetivo de obtener mejores resultados. Los resultados del estudio muestran que la presencia de neumonía se puede detectar tempranamente en las radiografías de tórax utilizando el modelo de predicción propuesto. Además, el autor también ofreció un prototipo en el que los dispositivos móviles se convertirán en una herramienta útil para los expertos en su trabajo, agilizando procesos mediante el acceso a redes neuronales implementadas en la nube. En conclusión, un conjunto de datos sólido fue esencial para el trabajo investigación donde se analizó la neumonía en una etapa temprana para alcanzar el óptimo rendimiento del modelo propuesto. Además, hay que señalar que la presente tesis fue importante para nuestro trabajo de investigación porque emplean conceptos como Deep Learning y la metodología empleada que son de suma importancia en nuestro desarrollo, así como la importancia de tener un robusto conjunto de datos para poder entrenar bien el modelo con lo

cual la red neuronal permite un diagnóstico de alta precisión en enfermedades tales como la neumonía.

En la Universidad Ricardo Palma, (Caya Perez, 2020) desarrolló la tesis titulada “Evaluación de modelos de redes neuronales convolucionales aplicado a radiografías de tórax para apoyar al proceso de diagnóstico de la neumonía asociada al COVID-19”, donde se planteó como objetivo evaluar los modelos de redes neuronales convolucionales aplicado a radiografías de tórax para apoyar al proceso de diagnóstico de neumonía asociada al COVID-19. La investigación llevada a cabo por Caya tuvo como objetivo la evaluación de tres modelos de redes neuronales convolucionales en el análisis de radiografías de tórax con el fin de ayudar en el diagnóstico de neumonía asociada al COVID-19 mediante la clasificación de imágenes. En la implementación del modelo, fue necesario utilizar transfer learning basado en los modelos ResNet50 e Inception V3. Además, se generó nuevas muestras de datos mediante la aplicación de transformaciones aleatorias y controladas a los datos originales (data augmentation) para evaluar su efectividad e impacto en el proceso de entrenamiento. Se empleó un conjunto de datos compuesto por imágenes de radiografías de tórax de casos positivos de COVID-19 y casos normales para entrenar y validar el modelo. Con respecto a los resultados obtenidos, estos fueron presentados en tres secciones distintas. En la primera sección, se exhibieron los procesos de entrenamiento, los cuales fueron representados mediante gráficas que emplearon como parámetros de medición la función de optimización y la métrica de precisión. En la segunda sección, se incluyeron tablas comparativas que contienen información relativa a las métricas de evaluación. En la

tercera sección, se proporcionaron las matrices de confusión, las cuales muestran de forma numérica la cantidad de aciertos y errores de cada uno de los modelos de redes neuronales convolucionales evaluados. Como conclusión el modelo que tuvo mejor desempeño fue cuando se aplicó data augmentation con exactitud igual a 0.9735 y sin la aplicación de esta se obtuvo 0.9635. Finalmente, según los resultados obtenidos el modelo más preciso para la clasificación de radiografías de tórax fue InceptionV3. La tesis en mención se relaciona con nuestro trabajo de investigación debido que se emplean modelos de redes neuronales convolucionales tales como ResNet50 e InceptionV3, contribuyendo a reducir el tiempo de detección de la enfermedad en radiografías de tórax, lo cual nos permitió hacer una comparativa entre ambos modelos y poder obtener el de mayor efectividad y tenerlo en cuenta al momento del desarrollo de nuestro trabajo de investigación.

En la tesis titulada “Sistema inteligente móvil basado en redes neuronales convolucionales para el diagnóstico previo de enfermedades renales”, realizada por (Garcia Cortegano, 2020) en la Universidad Nacional Federico Villareal, se planteó como objetivo la generación de una herramienta que facilite el diagnóstico previo del estado del deterioro del riñón en pacientes sanos y con enfermedades renales utilizando algoritmos de redes neuronales convolucionales desde un aplicativo móvil. Para la implementación del sistema inteligente, se presentaron 11 parámetros para evaluar la presencia de enfermedades, de los cuales se dieron prioridad a 5: Nitritos, Proteína, Ph, Hemoglobina y gravedad específica, que indican la posible existencia de enfermedad renal. Los resultados incluyeron el cálculo de los indicadores de eficacia, sensibilidad y especificidad del algoritmo de red

neuronal convolucional en el sistema inteligente móvil. El experimento abarcó tanto el proceso de entrenamiento como las pruebas de uso. Las conclusiones derivadas del estudio indican la viabilidad de implementar un sistema inteligente móvil para el diagnóstico preliminar de enfermedades renales basado en el reconocimiento de imágenes de pruebas de orina. Finalmente, los resultados obtenidos a través de los índices de eficacia, sensibilidad y especificidad respaldan la hipótesis de la investigación, la cual sugiere que la implementación de un sistema inteligente móvil basado en el procesamiento de imágenes con redes neuronales convolucionales permitirá llevar a cabo diagnósticos preliminares de enfermedades renales. La investigación mencionada resultó relevante para nuestro trabajo, ya que se centra en el empleo de redes neuronales convolucionales para realizar diagnósticos preliminares de enfermedades renales. En particular, se utilizó el algoritmo MobileNetV2, que forma parte del conjunto de algoritmos de redes neuronales convolucionales, y se evaluaron indicadores como la eficacia, sensibilidad y especificidad. Los resultados obtenidos fueron del 97%, 98% y 100% respectivamente en el diagnóstico de enfermedades renales.

La siguiente tesis nacional titulada “Sistema inteligente basado en redes neuronales para la identificación de cáncer de piel de tipo melanoma en imágenes de lesiones cutáneas” elaborada por (Villanueva Alarcón, 2021) tuvo como objetivo elaborar un sistema inteligente que permita detectar a partir de una imagen de lesión cutánea la presencia de cáncer en la piel de tipo Melanoma. En la implementación de este proyecto de investigación Villanueva diseño tres módulos, los cuales fueron : el módulo de preprocesamiento, en el cual empleó la técnica de "Data Augmentation" para poder

manejar un gran volumen de información ; módulo de clasificación de imágenes, donde utilizó la técnica "K-Fold" para poder optimizar el modelo de red neuronal empleado y el módulo de clasificación de metadata, donde se agregó metadatos al modelo lo cual generó un rendimiento positivo en el modelo a comparación de emplear solo el módulo de imágenes. Respecto a los resultados obtenidos en la evaluación del Módulo de imágenes se observó que las mejores métricas de Precisión, Sensibilidad y Especificidad obtenidas fueron a través de la arquitectura EfficientNet B6. En la evaluación del Módulo de Metadata se desarrolló un modelo de métricas con lo cual se observó un buen desempeño en AUC ya que se generalizó de manera óptima. Finalmente se comparó el desempeño de solo considerar las predicciones del módulo de Imágenes con el de Modulo de Metadata siendo el ensamblado de ambos la mejor solución. En conclusión, se logró desarrollar un sistema inteligente al combinar un módulo de clasificación de imágenes y otro de clasificación de metadatos, alcanzando una probabilidad de rendimiento del 92.85% en precisión, 71.50% en sensibilidad y 94.89% en especificidad. La tesis mencionada guarda relación con nuestro trabajo de investigación, ya que en el módulo de preprocesamiento se emplea la técnica de "Data Augmentation" para aumentar la variabilidad entre las imágenes, lo cual ha demostrado mejorar el rendimiento del modelo de clasificación de imágenes. Esta técnica también fue utilizada en nuestro desarrollo, lo que resalta la relevancia y la similitud de los enfoques adoptados en ambos trabajos.

En la investigación titulada "Algoritmo de diagnóstico preliminar de neumonía a partir de imágenes radiográficas del tórax" realizada por (Godoy Francisco, 2020) en la

Universidad Cesar Vallejo, se planteó como objetivo determinar el efecto del algoritmo de transferencia de aprendizaje en la sensibilidad, especificidad, exactitud, precisión y tiempo de diagnóstico preliminar de neumonía a través de imágenes radiográficas del tórax. El tipo de investigación fue cuantitativa, el diseño fue experimental porque se estableció el posible efecto de una causa que se manipula y el tipo de diseño de investigación fue preexperimental porque a un grupo se le aplica una preprueba, después se le administra el tratamiento y finalmente se aplica una posprueba al estímulo. Como resultados de la investigación se observó que al utilizar el algoritmo Resnet50 se obtuvo lo siguiente: un incremento de la sensibilidad en 0.69%, una reducción de la especificidad de 1.83%, una reducción de la exactitud de 0.74%, un incremento de la precisión de 0.02% y una reducción de tiempo de 78.62%. En conclusión, el uso del algoritmo de transferencia de aprendizaje para el diagnóstico preliminar de neumonía a partir de imágenes de radiográficas de tórax incrementó la sensibilidad y la precisión y hubo una reducción de la especificidad, de la exactitud y del tiempo con respecto al algoritmos con técnicas Resnet50. Además, señalar que la presente tesis fue importante para nuestro trabajo de investigación por la comparación de diferentes algoritmos de transferencia tales como: VGG16, VGG19, inception_V3, Xception, DensNet201, MobileNet_V2, Inception_Resnet_V2, Resnet50. Lo cual nos permitió analizar cada uno de los indicadores mencionados como: sensibilidad, especificidad, Precisión y F1 Score para de esta manera poder analizar el algoritmo de transferencia ideal para nuestro desarrollo.

2.2 Bases Teóricas

2.2.1 Inteligencia Artificial

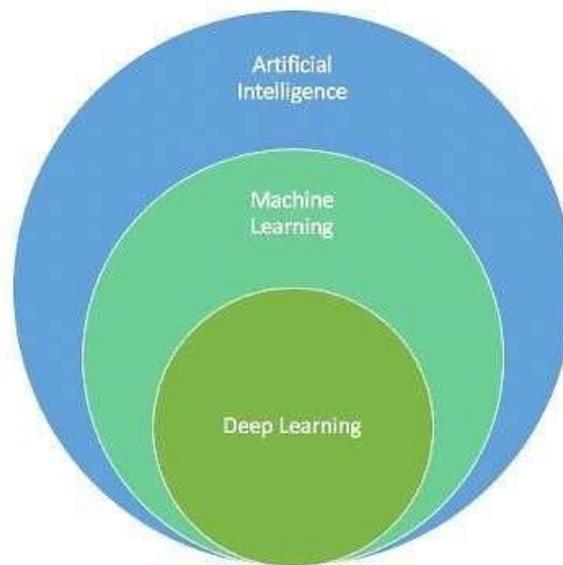
La inteligencia artificial es un campo interdisciplinario dedicado a comprender y replicar la inteligencia humana en sistemas informáticos. Implica desarrollar modelos y algoritmos que puedan aprender de los datos, comprender el lenguaje humano, identificar patrones en datos complejos y tomar decisiones basadas en la información disponible. La inteligencia artificial actual se basa en avances en áreas como el aprendizaje profundo, la representación del conocimiento y el razonamiento automatizado, que han dado lugar a avances significativos en aplicaciones como la medicina, la conducción autónoma y la asistencia virtual (Bengio, y otros, 2015).

La inteligencia artificial es la automatización de la abstracción. Implica el desarrollo de sistemas informáticos capaces de representar conceptos abstractos, aprender de ejemplos y experiencias, y generalizar este conocimiento para realizar tareas nuevas y variadas. La inteligencia artificial abarca una amplia gama de tecnologías, desde algoritmos de aprendizaje automático hasta redes neuronales profundas que permiten a las máquinas simular ciertos aspectos de la inteligencia humana (Domingos, 2012).

La inteligencia artificial es el estudio de cómo hacer que las computadoras realicen tareas que los humanos actualmente hacen mejor. Este campo abarca una amplia gama de subcampos, desde el aprendizaje automático hasta la robótica, y su objetivo principal es diseñar sistemas que puedan razonar, comprender, aprender y operar de forma autónoma. (Russell, y otros, 2016).

La inteligencia artificial se centra en técnicas como el aprendizaje profundo y el aprendizaje por refuerzo, que permiten a las máquinas alcanzar niveles de rendimiento que antes eran impensables en áreas como el reconocimiento de imágenes, el procesamiento del lenguaje natural y la conducción autónoma (Michalski, y otros, 2013).

Figura 6. Machine Learning y Deep Learning como subconjuntos de la IA



2.2.2 Machine Learning

El aprendizaje automático se refiere al campo de estudio que se centra en el desarrollo y la aplicación de algoritmos y modelos que capacitan a las computadoras para mejorar su rendimiento en tareas específicas a medida que adquieren experiencia. En lugar de estar programados de manera estática para cada tarea, estos sistemas tienen la capacidad de aprender de forma automática y adaptarse a partir de los datos disponibles (Michalski, y otros, 2013).

El aprendizaje automático es una disciplina dentro del campo de la inteligencia artificial que se enfoca en crear algoritmos y modelos capaces de aprender patrones a partir de datos, y realizar tareas específicas sin requerir programación directa. Estos modelos utilizan la experiencia adquirida para mejorar su rendimiento en una amplia variedad de aplicaciones, que van desde el reconocimiento de imágenes hasta el procesamiento del lenguaje natural (Bengio, y otros, 2015).

El aprendizaje automático, es una rama de la inteligencia artificial que se centra en desarrollar técnicas que permitan a las computadoras aprender de los datos y mejorar su desempeño en tareas sin programación especial. Estas técnicas incluyen algoritmos de clasificación, regresión, agrupamiento y otras técnicas de análisis de datos (Bishop, 2006).

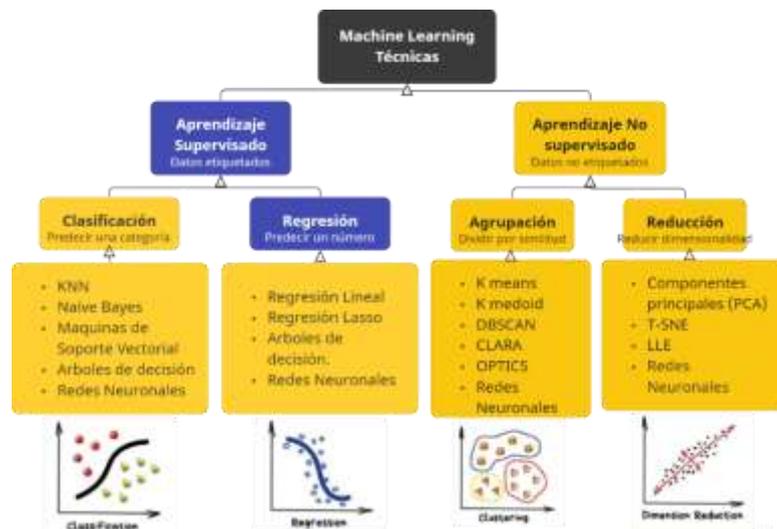
Es una rama de la inteligencia artificial que involucra el uso de algoritmos y modelos estadísticos para que las máquinas aprendan de datos para identificar patrones, analizar e interpretar datos y utilizarlos para realizar predicciones basadas en patrones aprendidos. Se divide en dos tipos:

Aprendizaje supervisado: Tarea de aprendizaje automático que implica inferir una función a partir de datos de entrenamiento que están etiquetados. Para resolver un problema con este tipo de aprendizaje, se siguen varios pasos. Primero, se determina el tipo de ejemplo de entrenamiento. Luego, se reúne un conjunto de entrenamiento que contiene datos etiquetados. Después, se identifican las características de entrada que se utilizarán para predecir la salida. Seguido, se elige la estructura de la función aprendida y el algoritmo de aprendizaje

correspondiente. Luego, se completa el diseño del modelo y, finalmente, se evalúa la precisión de la función aprendida.

Aprendizaje no supervisado: Trata de encontrar una estructura oculta en datos sin etiquetas, no hay señal de error o recompensa para evaluar una solución potencial. Los enfoques para el aprendizaje no supervisado incluyen: agrupamiento, modelos de variables latentes, métodos de momentos y técnicas de separación de señal ciega (Murphy, 2012).

Figura 7. Técnicas del aprendizaje automático



2.3 Marco Conceptual

2.3.1 Neumonía

Es la principal causa de mortalidad en niños según la Organización Mundial de la Salud (WHO), acerca de 2 millones de muertes a causa de la neumonía en niños menores a 5 años, lo que lo convierte en la causa más significativa de mortalidad pediátrica (Le Roux, y otros, 2015). Es un tipo de infección respiratoria aguda que afecta a los pulmones, los cuales están formados por pequeños sacos denominados alveolos, que en las personas sanas se llenan de aire al respirar; mientras que, en las personas con neumonía están ocupados con líquido y pocas células sanguíneas, lo que hace que su respiración sea dolorosa y limita la absorción de oxígeno (Gilani, y otros, 2012).

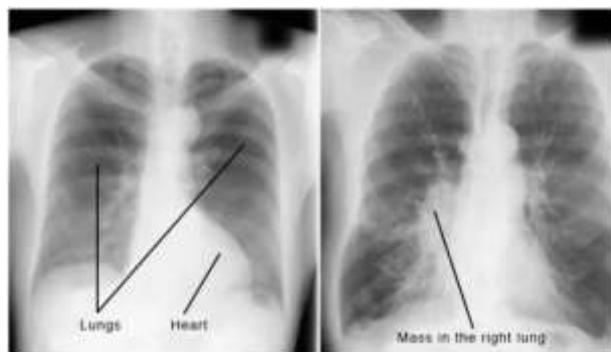
2.3.2 Diagnóstico de la neumonía

Según (Metlay y otros , 2019), el proceso de diagnóstico de la neumonía comienza con un examen físico en el que se examinan los pulmones del paciente utilizando un estetoscopio, con el objetivo de detectar sonidos anómalos que puedan indicar la presencia de neumonía. En caso de sospecha, se realizan diversas pruebas, entre las que se incluye un análisis de sangre para confirmar la presencia de la enfermedad y para identificar el organismo causante específico de la neumonía. Además, se puede llevar a cabo una oximetría de pulso para evaluar el nivel de oxígeno presente en la sangre. A pesar de estas pruebas complementarias, el método principal de diagnóstico sigue siendo la radiografía de tórax.

2.3.3 Radiografía de tórax (RXT)

Según Mayo Clinic (2020), son dosis muy pequeñas de radiación ionizante para producir imágenes del interior del tórax. Se utiliza para evaluar los pulmones, corazón y la pared del pecho, y se puede utilizar para diagnosticar la presencia de líquidos dentro de los pulmones o alrededor de ellos; así como, la presencia de aire en los pulmones (ver figura 8).

Figura 8. Rayos X de tórax señalizadas



Fuente: Mayo Foundation for Medical Education and Research (2020)

2.3.4 Deep learning

Es un subconjunto del aprendizaje automático que implica el uso de redes neuronales artificiales (ANN) con múltiples capas para aprender y extraer características y patrones complejos a partir de datos. Los algoritmos de DL como las redes neuronales convolucionales (CNN) y las redes neuronales artificiales, se han utilizado ampliamente en diversos ámbitos como el reconocimiento de voz, procesamiento del lenguaje natural y el reconocimiento de imágenes (Bengio, y otros, 2015).

2.3.5 Redes neuronales artificiales

Es un modelo computacional basado en la estructura y funcionamiento del cerebro humano. Está compuesto por neuronas interconectadas que pueden aprender de datos y realizar predicciones basados en este aprendizaje. Las ANN se utilizan en diversos campos del conocimiento como el reconocimiento de patrones, predicciones y procesamiento de datos (Mazurowski, y otros, 2019).

2.3.6 Redes neuronales convolucionales

Una red neuronal convolucional es una red neuronal profunda diseñada específicamente para procesar datos estructurados en cuadrícula, como imágenes. Usan capas convolucionales para extraer características jerárquicas de los datos de entrada, luego usan capas de agrupación para reducir la dimensionalidad y, finalmente, usan capas completamente conectadas para clasificación o regresión (Lecun, y otros, 2015).

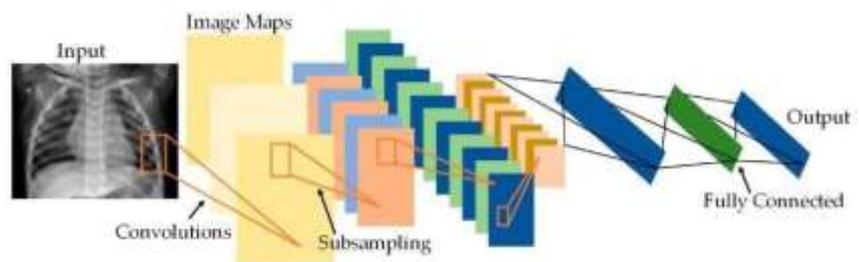
Según Bengio, y otros (2015), las redes neuronales convolucionales son un tipo especial de redes neuronales profundas que han demostrado ser eficaces para procesar datos de cuadrícula, como imágenes y datos de series de tiempo. Usan capas convolucionales para aplicar filtros locales a las regiones de entrada y luego usan capas de activación no lineal para aprender propiedades de materiales complejas y representaciones jerárquicas.

Una red neuronal convolucional es un tipo de red neuronal artificial en la que las conexiones entre neuronas se organizan de forma inspirada en la corteza visual de los animales. Están diseñados específicamente para procesar materiales de malla tales como imágenes, utilizando filtros

de peso distribuido para extraer características locales de la entrada (Chollet, 2017).

Según Géron (2022), define a las CNN como redes neuronales que comparten parámetros a través del espacio, lo que permite que se detecten patrones en diferentes regiones de una imagen, lo que las hace especialmente útiles para el procesamiento de imágenes.

Figura 9. Arquitectura de la red neuronal convolucional



Fuente: Transfer Learning with Deep Convolutional Neural Network for Pneumonia Detection (2020)

2.3.7 Estructura de una Red Neuronal Convolucional

A continuación, se describe la estructura de una red neuronal convolucional:

Capa de entrada:

Esta capa recibe la imagen de entrada. La imagen puede ser en escala de grises o en color, dependiendo de la tarea.

Capas convolucionales:

Estas capas aplican filtros convolucionales a la imagen de entrada para extraer características. Cada filtro convolucional es una matriz pequeña que se desliza sobre la imagen, realizando operaciones de multiplicación y suma para producir un mapa de características. Se pueden tener múltiples capas convolucionales, cada una con sus propios filtros.

Capas de activación:

Después de cada capa convolucional, se aplica una función de activación no lineal, típicamente ReLU (Rectified Linear Unit). Esta función introduce no linealidad en la red y ayuda a aprender características más complejas.

Capas de agrupación:

Estas capas reducen la dimensionalidad de los mapas de características al tomar el valor máximo (MaxPooling) o el promedio (AveragePooling) dentro de regiones específicas. Esto reduce el número de parámetros y ayuda a hacer que la red sea más robusta ante cambios en la posición de las características.

Capas totalmente conectadas:

Después de las capas de convolución y agrupación, se pueden agregar una o más capas totalmente conectadas para la clasificación final. Estas capas toman todas las características aprendidas y las combinan para hacer predicciones sobre las clases de salida.

Capa de salida:

La capa de salida final contiene el número de neuronas igual al número de clases en el problema de clasificación. Para problemas de clasificación binaria, puede haber una sola neurona con una función de activación sigmoide. Para problemas de clasificación múltiple, se pueden usar múltiples neuronas con una función de activación softmax.

2.3.8 Arquitectura de una Red Neuronal Convolucional

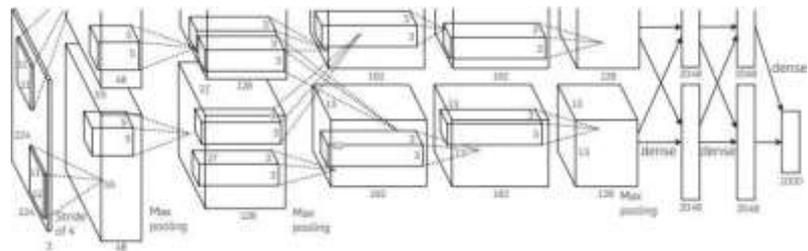
Actualmente existen diferentes tipos de arquitecturas, que se forman por la evolución o combinación de otras, generando nuevas versiones de estas o diseños totalmente

nuevos. Por lo cual se mencionan las arquitecturas más comunes: AlexNet, ResNet e InceptionV3.

Arquitectura AlexNet

Es una arquitectura de Red Neuronal Convolutiva (CNN) el cual consta de 5 capas convolucionales seguidas de capas de agrupación y capas totalmente conectadas, utiliza la función de activación ReLU (Rectified Linear Unit) para introducir no linealidad en la red. También incorpora técnicas como la regularización mediante dropout y el uso de múltiples GPU para acelerar el entrenamiento (Krizhevsky, y otros, 2017).

Figura 10. Arquitectura AlexNet



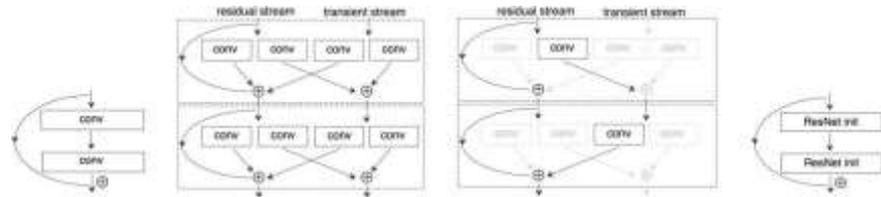
Fuente: ImageNet classification with deep convolutional neural networks (2017)

Arquitectura ResNet

Es una arquitectura de Red Neuronal Convolutiva (CNN). Se caracteriza por la introducción de conexiones residuales, que permiten entrenar redes neuronales extremadamente profundas (con más de 100 capas) con mayor eficacia. En lugar de tratar de aprender directamente la función de mapeo $H(x)$ entre la entrada x y la salida deseada y , ResNet aprende el residuo de esta función $F(x) = H(x) - x$. Esto se logra mediante la adición de la entrada original a la salida de

cada capa, lo que facilita el entrenamiento y la optimización de redes profundas (He, y otros, 2016).

Figura 11. Arquitectura ResNet

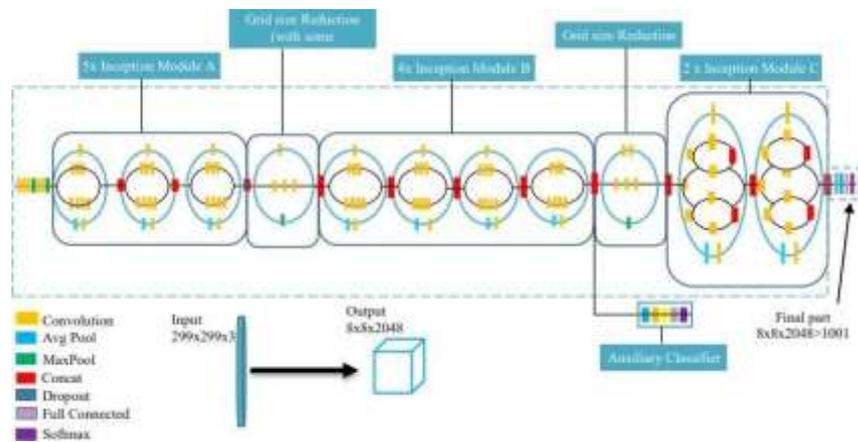


Fuente: Deep residual learning for image recognition (2016)

Arquitectura InceptionV3

Es una versión mejorada de la arquitectura Inception original, diseñada para la clasificación de imágenes en el desafío ImageNet. InceptionV3 utiliza una estructura de módulos Inception, que consisten en múltiples filtros convolucionales de diferentes tamaños y tipos de agrupación, que luego se concatenan en paralelo. Esto permite capturar características de diferentes escalas y orientaciones en una sola capa. Además, InceptionV3 utiliza técnicas como la factorización del kernel y la regularización L2 para mejorar el rendimiento y la generalización del modelo (Szegedy, y otros, 2016).

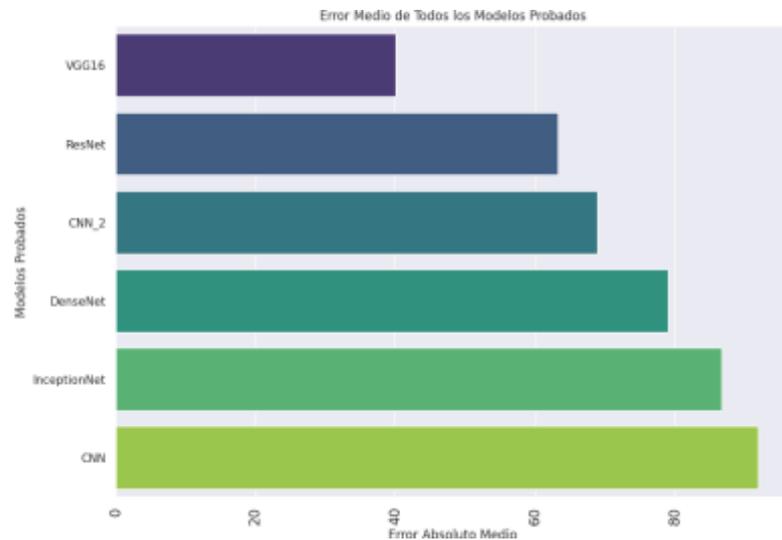
Figura 12. Arquitectura InceptionV3



Fuente: Rethinking the Inception Architecture for Computer Vision (2016)

Evaluando cada modelo relacionado a nuestra línea de investigación; se concluye que, el modelo de red neuronal convolucional es el más eficiente.

Figura 13. Comparación de diferentes modelos



2.3.9 Data Augmentation

Data Augmentation en redes neuronales convolucionales (CNN) es una técnica utilizada para aumentar la cantidad y variedad de datos de entrenamiento mediante la aplicación de transformaciones geométricas y de apariencia a las

imágenes de entrada. Estas transformaciones pueden incluir rotaciones, traslaciones, reflejos, cambios en el contraste y en el brillo, entre otras. El objetivo es mejorar la capacidad de generalización del modelo y reducir el riesgo de sobreajuste al exponerlo a una mayor diversidad de ejemplos durante el entrenamiento (Taylor, y otros, 2017).

2.3.10 **Matriz de Confusión**

Una matriz de confusión es una herramienta fundamental en la evaluación de modelos de clasificación en aprendizaje automático y estadística. Proporciona una visión detallada del rendimiento de un modelo al comparar las predicciones del modelo con las etiquetas verdaderas de los datos.

La matriz de confusión se compone de varias partes clave:

Verdaderos Positivos (TP): Son los casos en los que el modelo predijo correctamente la clase positiva.

Falsos Positivos (FP): Son los casos en los que el modelo predijo incorrectamente la clase positiva cuando en realidad era negativa (error tipo I).

Verdaderos Negativos (TN): Son los casos en los que el modelo predijo correctamente la clase negativa.

Falsos Negativos (FN): Son los casos en los que el modelo predijo incorrectamente la clase negativa cuando en realidad era positiva (error tipo II).

Una vez que se han definido estos términos, se puede construir la matriz de confusión. En una matriz de confusión típica, las clases verdaderas se colocan en las filas y las clases predichas se colocan en las columnas. La disposición de las celdas puede variar dependiendo de la convención utilizada, pero generalmente se presenta de la siguiente manera:

Figura 14. Matriz de Confusión

| | | PREDICTED | |
|--------|----------|----------------|----------------|
| | | Positive | Negative |
| ACTUAL | Positive | TRUE POSITIVE | FALSE NEGATIVE |
| | Negative | FALSE POSITIVE | TRUE NEGATIVE |

Entonces, en la matriz de confusión:

- Los verdaderos positivos (TP) están en la esquina inferior derecha.
- Los verdaderos negativos (TN) están en la esquina superior izquierda.
- Los falsos positivos (FP) están en la parte superior derecha.
- Los falsos negativos (FN) están en la parte inferior izquierda.

Una vez construida la matriz de confusión, se pueden calcular varias métricas de evaluación del modelo, como la precisión, la sensibilidad, la especificidad, etc. Utilizando los valores de TP, TN, FP y FN. Estas métricas proporcionan una comprensión más completa del rendimiento del modelo en la tarea de clasificación.

2.4 Definición de Términos Básicos

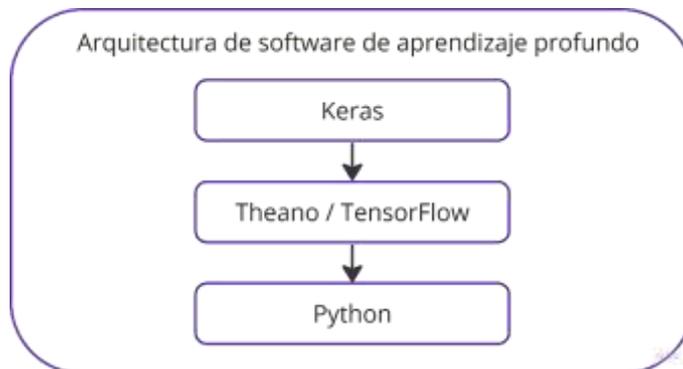
Python

Lenguaje de programación de alto nivel para ordenadores, cuentan con módulos o paquetes para realizar cálculos numéricos, científicos, gráficos y otros. Se caracteriza por ser simple, flexible y por tener poderosas capacidades de manejo de datos, asimismo se utiliza ampliamente para una variabilidad de cosas como es el desarrollo web, análisis de datos, informática científica y scripts. Además de ello, cuenta con una gran comunidad de desarrolladores y usuarios muy activos quienes contribuyen con al desarrollo del lenguaje y su ecosistema de frameworks y bibliotecas (Wilson, 2022).

Keras

Es una biblioteca a nivel de modelo de alto nivel que proporciona componentes básicos para desarrollar modelos de aprendizaje profundo, los modelos de Keras son fáciles de entender y crean prototipos de nuevos conceptos para principiantes. Se basa en una biblioteca de tensores especializada, que actúa como motor de backend de keras, que permite conectar con varios backends diferentes como Theano, Cognitive Toolkit (CNTK) y TensorFlow que se recomienda como predeterminado porque es el más adoptado, escalable y listo para producción (Chollet, 2017).

Figura 15. Deep learning Software Architecture



Tensorflow

Es una librería de código abierto para en ML e IA que se ejecuta sobre Python/C++ se basa en el concepto de tensores, que son matrices multidimensionales de datos que representan la entrada, la salida y los cálculos intermedios de un modelo de aprendizaje automático, proporciona un conjunto de API y bibliotecas que permiten definir y manipular tensores, y aplicarles diversas operaciones y transformaciones matemáticas, como álgebra lineal, cálculo y probabilidad, que posibilita entrenar, evaluar e implementar modelos de redes neuronales a gran escala, para exportarlos a varios formatos y plataformas, como TensorFlow Lite tanto en dispositivos móviles e integrados, y TensorFlow.js para navegadores web. Es la librería más utilizada entre la comunidad de aprendizaje profundo, ya que cuenta con el respaldo de Google, lo utilizan empresas, organización e investigadores de todo el mundo para una amplia gama de tareas como entrenamiento e implementación de modelos de aprendizaje automático, procesamiento de lenguaje natural, análisis y clasificación de imágenes y videos, sistemas de recomendación y pronóstico de series de tiempo y también tiene buenas capacidades de visualización usando TensorBoard (Wilson, 2022).

Pandas

Es una librería muy importante para realizar análisis de datos, tiene dos estructuras de datos principales que son las series y el DataFrame que es una matriz bidimensional de datos con etiquetas de fila y columna, gracias a esta potente herramienta se pueden cargar, preparar, manipular, modelar y analizar una base de datos (Grus, 2019).

NumPy

Del acrónimo de “Numeric Python”, es una librería ideal para realizar funciones matemáticas y numéricas, trabaja con procesamiento de matrices multidimensionales que mejora la eficiencia del análisis y trabaja mejor que vectores y matrices de lista (Grus, 2019).

Matplotlib

Matplotlib, la librería ideal para la visualización de datos en dos dimensiones que sirve para generar diagramas o tablas y sencillas gráficas de barras, líneas y dispersión (Grus, 2019).

Scikit-learn

Scikit-learn, es una popular biblioteca para implementar aprendizaje automático en Python que permite desarrollar análisis predictivo, el cual está basado en Numpy, SciPy y matplotlib. Asimismo, proporciona varios algoritmos para clasificación, regresión y agrupación o clustering (Guzman, 2023).

Jupyter Notebook

Jupyter Notebook, es la aplicación web de código abierto utilizado en ciencia de datos y aprendizaje profundo, que genera cuadernos o notebooks que pueden ser editados dentro del navegador que combina la capacidad de ejecutar código Python con la edición de texto para introducir anotaciones (Chollet, 2017).

Google Colaboratory

Mejor conocido como Google Colab es un entorno de programación colaborativo basado en la nube y está diseñado para escribir y ejecutar código Python en un navegador web con recursos gratuitos como la memoria RAM, tarjetas gráficas, unidades de procesamiento tensorial como GPU y TPU, además Google Colab incluye todas las bibliotecas clave para ciencia de datos y aprendizaje profundo, como numpy, Pandas, Sklearn, Tensorflow, Keras, OpenCV y PyTorch, por lo que no es necesario instalarlas (De la Vega Jiménez, 2021).

III. HIPOTESIS Y VARIABLES

3.1 Hipótesis

3.1.1 Hipótesis General

El diseño de un modelo red neuronal convolucional mejora el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

3.1.2 Hipótesis Específicas

H.E.1. El diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.

H.E.2. El diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.

H.E.3. El diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.

H.E.4. El diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.

3.2 Operacionalización de variables

3.2.1 Definición operacional de las variables

Para operacionalizar las variables, se tomó en cuenta la realización del análisis de las características o aspectos de cadauna de las variables definidas, así como los indicadores asociados a ellas.

Variable Dependiente: Diagnóstico de la Neumonía

Definición conceptual:

En opinión de Metlay, y otros (2019), el diagnóstico de neumonía es el proceso por el cual se identifica la presencia de una infección pulmonar, la que se caracteriza por síntomas clínicos, hallazgos físicos y resultados de pruebas complementarias, como radiografías de tórax y pruebas microbiológicas, con el objetivo de proporcionar un tratamiento adecuado y mejorar los resultados clínicos del paciente.

Dimensiones:

Dimensión Exactitud: La exactitud indica qué tan cerca está el valor medido de un valor conocido. Es el número de predicciones correctas (TP y TN) divididas por el número total de todas las muestras o total de predicciones. Incluye todas las entradas de la matriz de confusión (Muller, y otros, 2016).

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN}$$

Dimensión Precisión: La precisión es utilizada como métrica de rendimiento y tiene como objetivo limitar el número de falsos positivos, mide cuantas de las muestras predichas por el modelo como positivas, son realmente positivas (Muller, y otros, 2016).

$$Precisión = \frac{TP}{TP + FP}$$

Dimensión Sensibilidad: Calcula la cantidad de positivos reales que el modelo pudo capturar después de etiquetarlo como verdadero positivo (Muller, y otros, 2016).

$$\text{Sensibilidad} = \frac{TP}{TP + FN}$$

Dimensión Especificidad: La especificidad es la fracción de instancias negativas que son correctamente identificadas por el modelo (Muller, y otros, 2016).

$$\text{Especificidad} = \frac{VN}{FP + VN}$$

Donde:

TP = Verdadero Positivo o True Positive

TN = Verdadero Negativo o True Negative

FP = Falso positivo o False Positive

FN = Falso Negativo o False Negative

Indicadores:

- **Para la dimensión Exactitud:** Porcentaje de la exactitud del diagnóstico.
- **Para la dimensión Precisión:** Porcentaje de la precisión del diagnóstico.
- **Para la dimensión de Sensibilidad:** Porcentaje de la sensibilidad del diagnóstico.
- **Para la dimensión de Especificidad:** Porcentaje de la especificidad del diagnóstico.

Técnica Estadística:

Método y Técnica: Fichaje

Variable Independiente: Red Neuronal Convolucional

Definición conceptual:

La Red Neuronal Convolucional es un tipo de red neuronal artificial profunda que posee una gran cantidad de capas ocultas y es de aprendizaje supervisado, entre sus aplicaciones tenemos la clasificación de imágenes, reconocimiento de objetos, voz y patrones de lenguaje natural (Li, y otros, 2021).

3.2.2 Operacionalización de las Variables

Tabla 1. Operacionalización de las Variables

| VARIABLES | DEFINICIÓN CONCEPTUAL | DEFINICIÓN OPERACIONAL | DIMENSIÓN | INDICADORES | ÍNDICES/ÍTEMS | MÉTODO Y TÉCNICA |
|--|---|---|---------------|---|--|---|
| Variable independiente: Red Neuronal Convolutacional | “La Red Neuronal Convolutacional es un tipo de red neuronal artificial profunda que posee una gran cantidad de capas ocultas y es de aprendizaje supervisado, entre sus aplicaciones tenemos la clasificación de imágenes, reconocimiento de objetos, voz y patrones de lenguaje natural (Li y otros, 2021)”. | | | | | Tipo de investigación: Aplicada Diseño: Experimental |
| Variable dependiente: Diagnóstico de la Neumonía | “El diagnóstico de neumonía es el proceso por el cual se identifica la presencia de una infección pulmonar, la que se caracteriza por síntomas clínicos, hallazgos físicos y resultados de pruebas complementarias, como radiografías de tórax y pruebas microbiológicas, con el objetivo de proporcionar un tratamiento adecuado y mejorar los resultados clínicos del paciente (Metlay y otros, 2019).” | La exactitud es el número de predicciones positivas correctas. | Exactitud | Porcentaje de Exactitud del diagnóstico | $\% \text{Exactitud} = \left(\frac{VP + VN}{VP + FP + FN + VN} \right) * 100$ | Enfoque: Cuantitativo |
| | | Indica qué tan preciso es el modelo en términos de aquellos que se predijeron como positivos. | Precisión | Porcentaje de Precisión del Diagnóstico | $\% \text{Precisión} = \left(\frac{VP}{VP + FP} \right) * 100$ | Técnica: Fichaje |
| | | Representa la fracción de los verdaderos positivos. | Sensibilidad | Porcentaje de Sensibilidad del diagnóstico | $\% \text{Sensibilidad} = \left(\frac{VP}{VP + FN} \right) * 100$ | Instrumento: Ficha de Registro |
| | | Representa la fracción de los verdaderos negativos. | Especificidad | Porcentaje de Especificidad del diagnóstico | $\% \text{Especificidad} = \left(\frac{VN}{FP + VN} \right) * 100$ | |

IV. METODOLOGÍA DEL PROYECTO

4.1 Diseño Metodológico

El tipo de Investigación es aplicado con un enfoque cuantitativo. Según Sampieri, y otros (2010), la investigación aplicada se basa en la generación de conocimientos con el propósito de resolver problemas prácticos y específicos, con un enfoque en la aplicación directa de esos conocimientos en la solución de situaciones concretas en la vida real.

Por otro lado, la investigación cuantitativa tiene un enfoque sistemático empleado para recolectar, analizar e interpretar datos numéricos con el fin de comprender fenómenos sociales, naturales o científicos. Utiliza métodos y técnicas estadísticas para medir variables y establecer relaciones entre ellas. Este enfoque se basa en la objetividad y la generalización de los resultados obtenidos a partir de muestras representativas de una población (Babbie, 2020).

Diseño Experimental

El diseño experimental se caracteriza por la manipulación controlada de una o más variables independientes para evaluar su efecto sobre una variable dependiente. Este enfoque permite establecer relaciones de causa y efecto entre las variables y proporciona un marco riguroso para la recolección y análisis de datos (Rosenthal, y otros, 2008).

4.2 Método de Investigación

Según el propósito, esta investigación es aplicada. La investigación aplicada implica la utilización de conocimientos científicos para abordar desafíos reales en la práctica, con el objetivo de mejorar la calidad de vida, resolver problemas sociales y contribuir al desarrollo de políticas y prácticas efectivas (Patton, 2023).

Según el enfoque, esta investigación es cuantitativa, porque implica la recolección y análisis de datos numéricos para describir, explicar

o predecir fenómenos, utilizando procedimientos sistemáticos y técnicas estadísticas para garantizar la validez y confiabilidad de los resultados (Paul, y otros, 2014).

4.3 Población y Muestra

La población para el trabajo de investigación estuvo constituida por 624 radiografías de pacientes entre 1 y 5 años pertenecientes al Hospital Gustavo Lanatta Luján de Bagua. Es preciso mencionar que, se tomaron radiografías de personas sanas y pacientes con neumonía y la muestra seleccionada refleja esta misma cantidad.

4.4 Lugar de Estudio

El estudio se realizó en el área de Imagenología del Hospital Gustavo Lanatta Luján de Bagua.

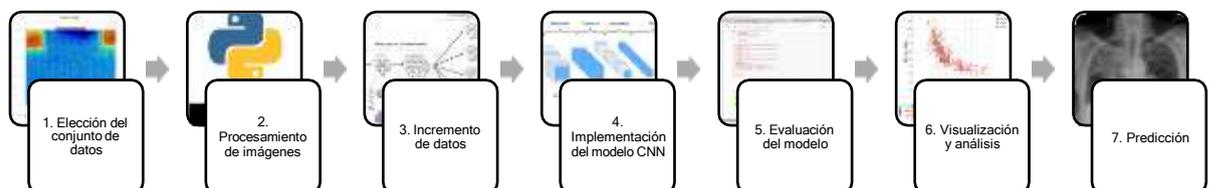
4.5 Técnicas e instrumentos para la recolección de la información.

Instrumentos: Fichaje.

4.6 Metodología Propuesta de la Solución

Considerando la investigación propuesta, se planteó una metodología compuesta por 7 etapas: Elección del conjunto de datos, procesamiento previo de las imágenes del conjunto de datos, incremento de datos, implementación del modelo, evaluación del modelo, visualización y análisis, finalmente predicción.

Figura 16. Etapas de la Metodología Propuesta



Elección del conjunto de Datos

Durante esta etapa de la metodología propuesta, es esencial obtener un conjunto de datos que incluya las imágenes radiográficas y los atributos requeridos para su análisis y procesamiento, con el objetivo de identificar si un paciente tiene neumonía o no. En este conjunto de datos, las imágenes deben pertenecer a dos categorías distintas: pacientes diagnosticados con neumonía y pacientes normales.

Dentro del conjunto de datos seleccionado para el desarrollo de esta investigación, se incluyen un total de 5876 radiografías, de las cuales 4283 imágenes presentan neumonía y 1593 imágenes muestran condiciones normales. De esta manera se distribuye las imágenes y se puede obtener un conjunto de datos de entrenamiento, validación y pruebas para el diseño del modelo predictivo.

Tabla 2. Distribución de las radiografías

| Ítem | Normal | Neumonía |
|---------------|---------------|-----------------|
| Entrenamiento | 1351 | 3885 |
| Validación | 8 | 8 |
| Pruebas | 234 | 390 |
| Total | 1593 | 4283 |

Procesamiento previo de las imágenes del conjunto de datos

Después de obtener el conjunto de datos de entrenamiento, validación y pruebas, la segunda fase de la metodología propuesta consiste en el preprocesamiento de imágenes, que implica la preparación de los datos para el entrenamiento del modelo predictivo. Realiza un preprocesamiento para redimensionar las imágenes a un tamaño uniforme (224x224 píxeles) y la normalización visual de las mismas, las cuales deben aplicarse a todos los conjuntos de datos.

Incremento de Datos

Se aplicó el método de aumento de datos, el cual consiste en generar nuevas muestras de entrenamiento a partir de las imágenes originales. Se emplearon diversos métodos de aumento, como el desplazamiento, zoom, la inversión y la rotación de ángulos de 10 grados, para enriquecer el conjunto de datos y mejorar la capacidad del modelo para generalizar patrones.

Desarrollo del Modelo CNN

Después de obtener el conjunto de entrenamiento con aumento de datos, así como los conjuntos de validación y pruebas, el siguiente paso consiste en la clasificación conjunta utilizando el modelo. Para ello, se empleará la arquitectura de Redes Neuronales Convolucionales (CNN), aprovechando su capacidad para extraer características básicas de las imágenes. Se configurará el modelo para realizar la clasificación binaria entre imágenes radiográficas de neumonía e imágenes normales. Posterior a ello se realiza la compilación y entrenamiento del modelo realizando un total de 100 épocas (se refiere al número de veces que el modelo de red neuronal ve todo el conjunto de datos de entrenamiento durante el proceso de entrenamiento) en la que cada época consta de una pasada completa a través de todos los ejemplos de entrenamiento.

Figura 17. Construcción del Modelo

```
1 #Construcción del Modelo CNN
2
3 cnn_model = Sequential()
4
5 # Primer Bloque de CNN
6 cnn_model.add(Conv2D(16, (3, 3), padding='same', input_shape=(224, 224, 3), activation='relu'))
7 cnn_model.add(Conv2D(16, (3, 3), padding='same', activation='relu'))
8 cnn_model.add(MaxPooling2D((2, 2)))
9
10 # Segundo Bloque de CNN
11 cnn_model.add(SeparableConv2D(32, (3, 3), padding='same', activation='relu'))
12 cnn_model.add(SeparableConv2D(32, (3, 3), padding='same', activation='relu'))
13 cnn_model.add(BatchNormalization())
14 cnn_model.add(MaxPooling2D((2, 2)))
15
```

Figura 18. Épocas

```
history = cnn_model.fit(training_dataset,
                        steps_per_epoch=len(training_dataset),
                        validation_data=test_dataset,
                        validation_steps=len(test_dataset),
                        epochs=EPOCHS,
                        callbacks=[early_stop, checkpoint],
                        verbose=1)

Epoch 1/100
163/163 [#####] - 249s 2s/step - loss: 0.4760 - accuracy: 0.7838 - val_loss:
1.0436 - val_accuracy: 0.6250
Epoch 2/100
163/163 [#####] - 255s 2s/step - loss: 0.3065 - accuracy: 0.8530 - val_loss:
0.7193 - val_accuracy: 0.6250
Epoch 3/100
163/163 [#####] - 242s 1s/step - loss: 0.2699 - accuracy: 0.8828 - val_loss:
1.5362 - val_accuracy: 0.6250
Epoch 4/100
```

Evaluación del Modelo

Después del desarrollo y entrenamiento del Modelo de Red Neuronal Convolutiva se evalúa el modelo en el conjunto de datos Test. Posteriormente a ello se calculan las métricas correspondientes como lo son: Exactitud, Precisión, Sensibilidad y Especificidad.

Figura 19. Matriz de Confusión Dataset Test

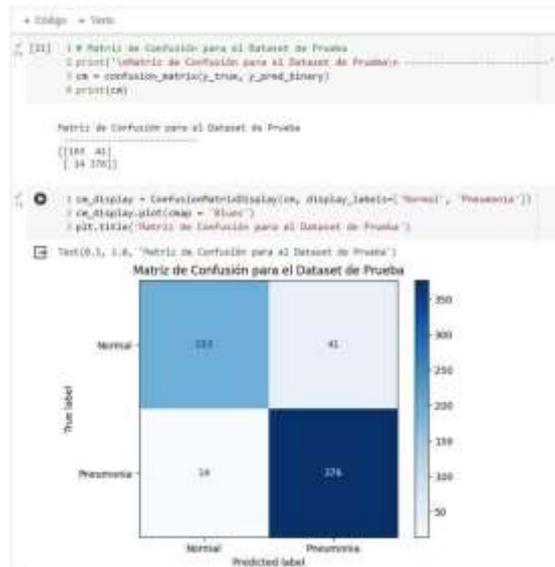
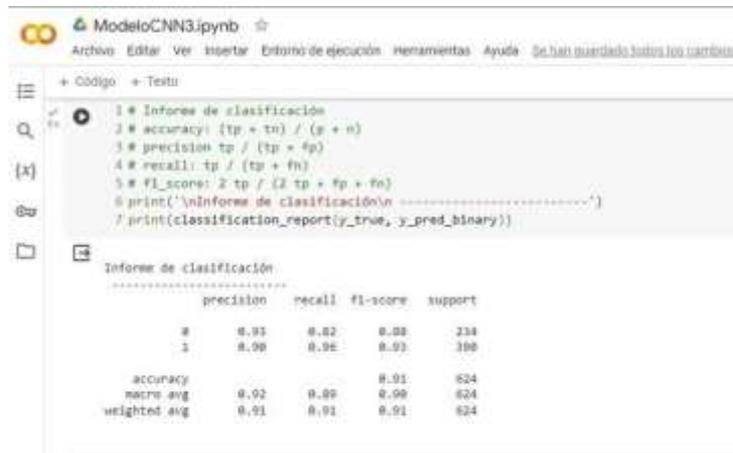


Figura 20. Métricas del Modelo



```
1 # Informe de clasificación
2 # accuracy: (tp + tn) / (p + n)
3 # precision: tp / (tp + fp)
4 # recall: tp / (tp + fn)
5 # f1_score: 2 * tp / (2 * tp + fp + fn)
6 print('\nInforme de clasificación\n-----')
7 print(classification_report(y_true, y_pred_binary))
```

Informe de clasificación

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0 | 0.91 | 0.92 | 0.92 | 234 |
| 1 | 0.90 | 0.90 | 0.90 | 100 |
| accuracy | | | 0.91 | 624 |
| macro avg | 0.92 | 0.90 | 0.90 | 624 |
| weighted avg | 0.91 | 0.91 | 0.91 | 624 |

Visualización y Análisis

Después de evaluar el modelo, se procede a visualizar y analizar los resultados. En este proceso, se utilizó la biblioteca Gradio para predecir una imagen, empleando una interfaz de usuario que recibe la predicción de neumonía como entrada y devuelve una clase de neumonía o normal, según el porcentaje presentado.

Figura 21. Interfaz de la Detección de la Neumonía



Predicción

Se utiliza el modelo entrenado para predecir si una imagen de radiografía muestra neumonía o no.

Figura 22. Predicción de un paciente con neumonía



Figura 23. Predicción de un paciente sin neumonía



V. RESULTADOS

5.1 Resultados Descriptivos

Durante el desarrollo de la presente investigación, se empleó un modelo de red neuronal convolucional con el objetivo de contar con un diagnóstico temprano de neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua. En este sentido, previamente al diseño, se llevó a cabo un estudio preliminar relacionados a la recolección de datos para cada indicador. Posteriormente, se procedió a diseñar el modelo de red neuronal, seguido de la repetición del proceso de estudio para evaluar el impacto y las mejoras obtenidas con el diseño de diagnóstico implementado para mejorar el proceso de diagnóstico de neumonía.

5.1.1 Hipótesis General

H.G: El diseño de un modelo red neuronal convolucional mejora el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Tabla 3. Estadísticos descriptivos de la hipótesis general

| | | Estadísticos | |
|-----------------------------|----------|--------------------------------|---------------------------------|
| | | Diagnóstico de Neumonía Pre | Diagnóstico de Neumonía Post |
| N | Válido | 12 | 12 |
| | Perdidos | 0 | 0 |
| Media | | 91,2635 | 96,4073 |
| Mediana | | 93,2813 | 97,2750 |
| Moda | | 82,81 ^a | 100,00 |
| Desv. Desviación | | 4,34556 | 2,92684 |
| Varianza | | 18,884 | 8,566 |
| Asimetría | | -,816 | -,462 |
| Error estándar de asimetría | | ,637 | ,637 |
| Curtosis | | -,435 | -1,146 |
| Error estándar de curtosis | | 1,232 | 1,232 |
| Rango | | 13,32 | 8,24 |
| Mínimo | | 82,81 | 91,76 |
| Máximo | | 96,13 | 100,00 |
| Percentiles | 25 | 88,3944 | 93,2181 |
| | 50 | 93,2813 | 97,2750 |
| | 75 | 94,4388 | 98,8044 |

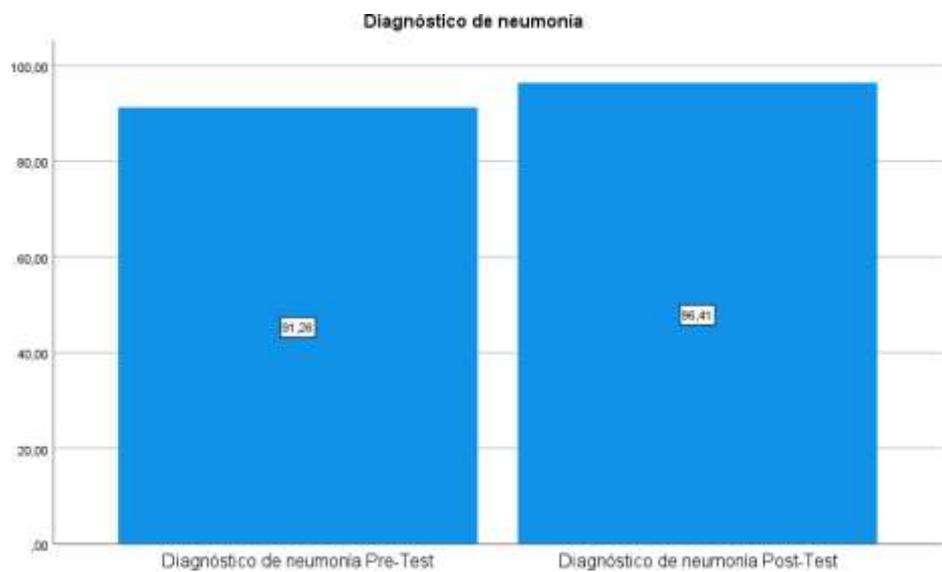
a. Existen múltiples modos. Se muestra el valor más pequeño.

En los resultados de los estadísticos obtenidos, se observa un cambio significativo en diversas medidas estadísticas. Por ejemplo, la media inicial fue de 91.26, incrementándose a 96.41 después del evento, reflejando una diferencia de 5.15. La mediana, que inicialmente fue de 93.28, experimentó un aumento considerable hasta alcanzar el valor de 97.28, luego de emplear el diseño de un modelo de red neuronal para el diagnóstico de neumonía. Con respecto a la moda, se mostró un cambio significativo de 82.81 a 100.

En cuanto a la distribución de datos, se observa un cambio en la asimetría, el cual pasó de -0.816 antes del evento a -0.462 después del mismo. Este cambio aduce a una

inclinación hacia valores más altos en la distribución. Adicionalmente, la curtosis mostró una ligera disminución, pasando de -0.435 a -1.146, mostrando una leve modificación en la concentración de los datos con respecto a la media.

Figura 24. Gráfico de barras de diagnóstico de neumonía pre y post test



En el gráfico mostrado, se puede observar que la diferencia de medias del pre y post test es significativa. Por lo que, se concluye que, el diseño de un modelo de red neuronal convolucional mejora significativamente el proceso de diagnóstico de neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Figura 25. Histograma de curva normal de diagnóstico de neumonía Pre-Test

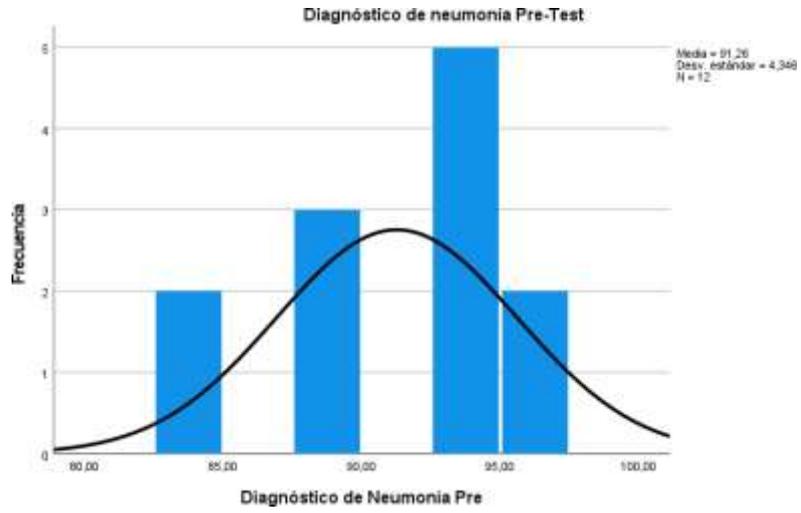
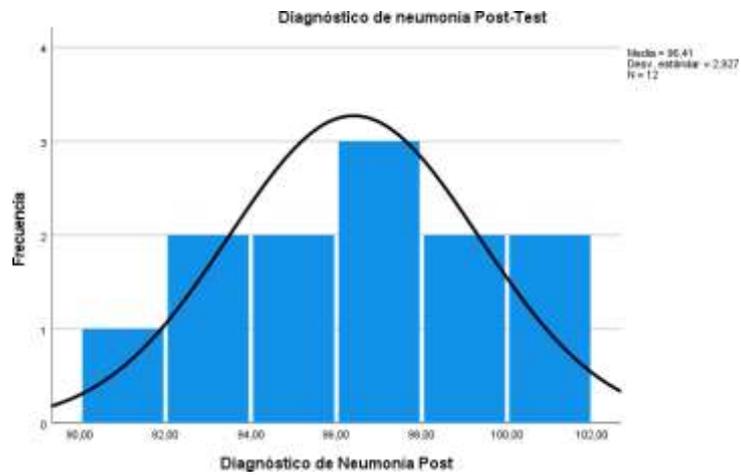


Figura 26. Histograma de curva normal de diagnóstico de neumonía Post-Test



5.1.2 Hipótesis Específicas

H.E.1. El diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Tabla 4. Estadísticos descriptivos de la hipótesis específica 1

| | | Estadísticos | |
|-----------------------------|----------|------------------------------|-------------------------------|
| | | Exactitud de diagnóstico Pre | Exactitud de diagnóstico Post |
| N | Válido | 12 | 12 |
| | Perdidos | 0 | 0 |
| Media | | 91,6067 | 96,2825 |
| Error estándar de la media | | 1,34718 | ,89718 |
| Mediana | | 93,1700 | 97,6450 |
| Moda | | 83,33 ^a | 100,00 |
| Desv. Desviación | | 4,66676 | 3,10793 |
| Varianza | | 21,779 | 9,659 |
| Asimetría | | -,735 | -,554 |
| Error estándar de asimetría | | ,637 | ,637 |
| Curtosis | | -,596 | -1,096 |
| Error estándar de curtosis | | 1,232 | 1,232 |
| Rango | | 13,64 | 8,93 |
| Mínimo | | 83,33 | 91,07 |
| Máximo | | 96,97 | 100,00 |
| Percentiles | 25 | 88,4150 | 93,4350 |
| | 50 | 93,1700 | 97,6450 |
| | 75 | 95,4825 | 98,3100 |

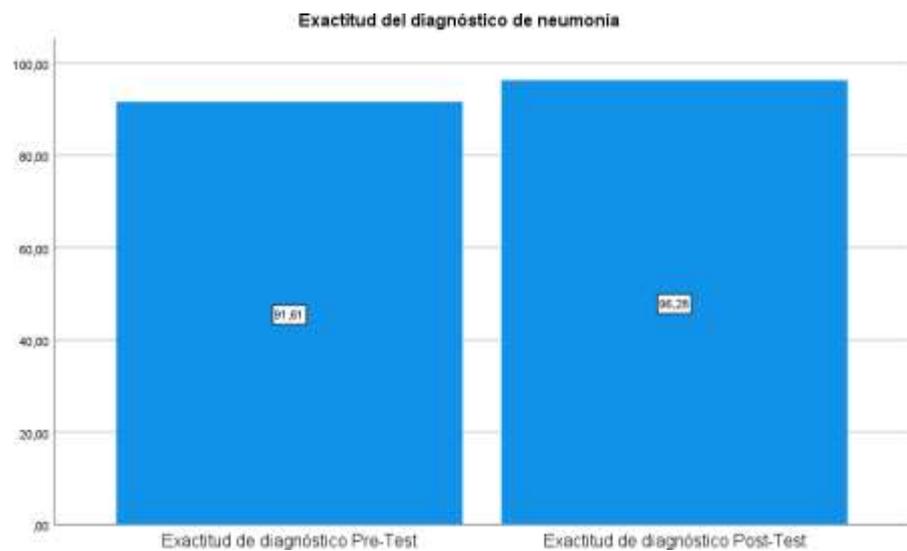
a. Existen múltiples modos. Se muestra el valor más pequeño.

Los resultados correspondientes a los estadísticos descriptivos muestran un cambio significativo en varias medidas de tendencia central. Por ejemplo, la media inicial fue de 91.61, incrementándose a 96.28 después del diseño del modelo de red neuronal convolucional. La mediana que inicialmente fue de 93.17, experimentó un aumento al

alcanzar 97.65 en la fase posterior a la implementación del software. Respecto a la moda, esta registró un cambio significativo de 83.33 hasta 100.

En cuanto a la distribución de los datos, se observa un cambio en la asimetría, que pasó -0.735 antes del evento a -0.554 después del mismo. Además, la curtosis mostró una ligera disminución, pasando de -0.596 hasta -1.096, indicando un cambio en la concentración de datos hacia las colas de distribución.

Figura 27. Gráfico de barras de exactitud del diagnóstico de neumonía pre y post test



En el gráfico mostrado, se puede observar que la diferencia de medias del pre y post test es significativa, variando de un 91.61 a un valor de 96.28. Por lo que, se concluye que, el diseño de modelo de red neuronal convolucional mejora la exactitud del proceso de diagnóstico de neumonía de los pacientes de los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Figura 28. Histograma de la curva normal de la exactitud del proceso de diagnóstico Pre-Test

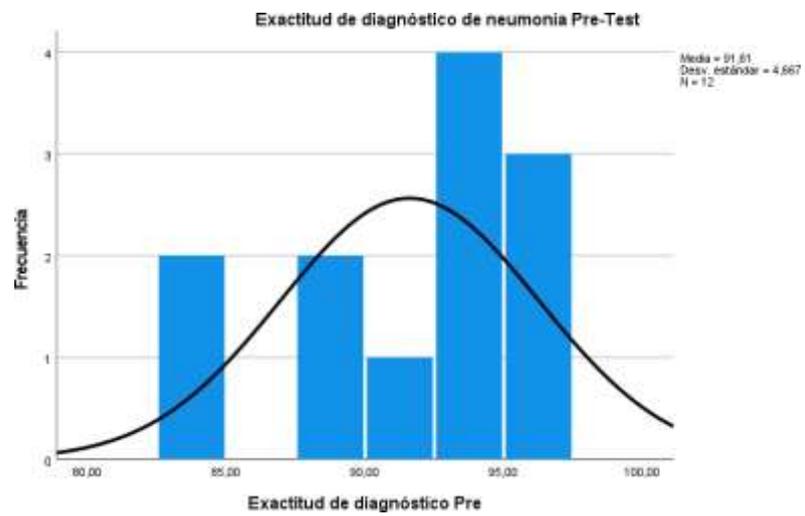
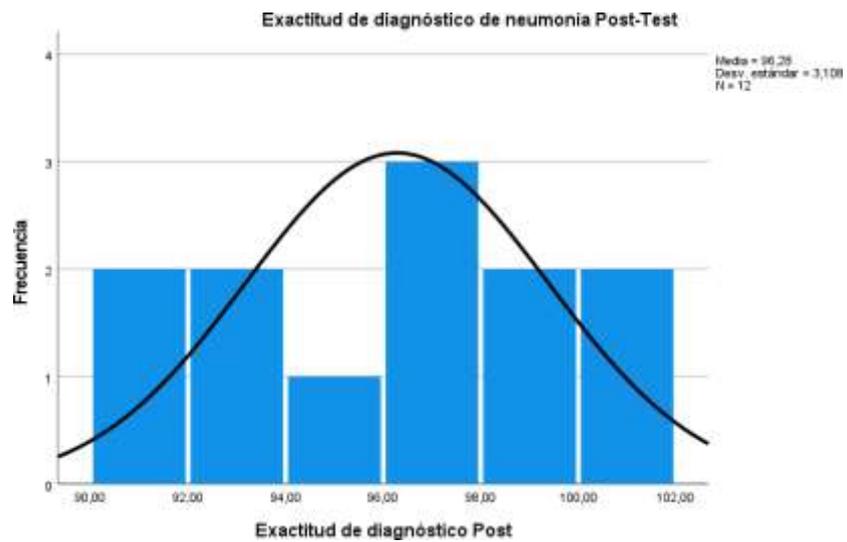


Figura 29. Histograma de la curva normal de exactitud de diagnóstico Post-Test



H.E.2. El diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Tabla 5. Estadísticos descriptivos de la hipótesis específica 2

| | | Estadísticos | |
|-----------------------------|----------|------------------------------|-------------------------------|
| | | Precisión de diagnóstico Pre | Precisión de diagnóstico Post |
| N | Válido | 12 | 12 |
| | Perdidos | 0 | 0 |
| Media | | 91,0125 | 97,2575 |
| Error estándar de la media | | 1,36251 | ,68463 |
| Mediana | | 91,4300 | 97,0900 |
| Moda | | 88,24 ^a | 100,00 |
| Desv. Desviación | | 4,71986 | 2,37162 |
| Varianza | | 22,277 | 5,625 |
| Asimetría | | -,205 | -,173 |
| Error estándar de asimetría | | ,637 | ,637 |
| Curtosis | | 1,114 | -1,130 |
| Error estándar de curtosis | | 1,232 | 1,232 |
| Rango | | 18,75 | 6,67 |
| Mínimo | | 81,25 | 93,33 |
| Máximo | | 100,00 | 100,00 |
| Percentiles | 25 | 88,2400 | 95,1300 |
| | 50 | 91,4300 | 97,0900 |
| | 75 | 94,0275 | 100,0000 |

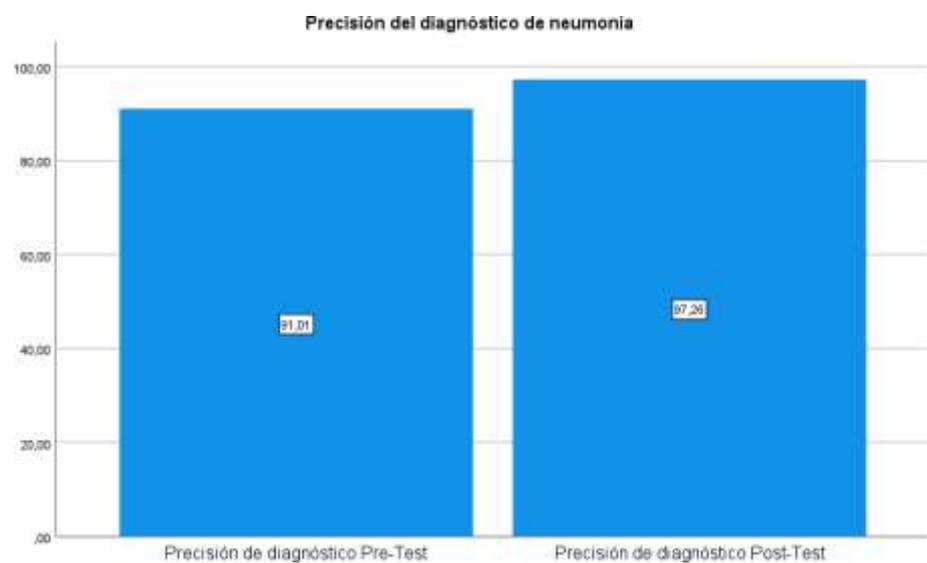
a. Existen múltiples modos. Se muestra el valor más pequeño.

Los resultados correspondientes a los estadísticos descriptivos muestran un cambio significativo en varias medidas de tendencia central. Por ejemplo, la media inicial fue de 91.01, incrementándose a 97.26 después del diseño del modelo de red neuronal convolucional. La mediana que inicialmente fue de 91.43, experimentó un aumento al alcanzar 97.09 en la fase posterior a la implementación del

software. Respecto a la moda, esta registró un cambio significativo de 88.24 hasta 100.

En cuanto a la distribución de los datos, se puede observar un cambio en la asimetría, que cambió de -0.205 antes del evento a -0.173. Finalmente, la curtosis mostró una ligera disminución, variando de 1.114 a -1.130.

Figura 30. Gráfico de barras de precisión del diagnóstico de neumonía pre y post test



En el gráfico de barras mostrado, se puede observar que la diferencia de medias del pre y post test es significativa, variando de un 91.01 a un valor de 97.26. Por lo que, se concluye que, el diseño de un modelo de red neuronal convolucional mejora la precisión del proceso de diagnóstico de neumonía de los pacientes de los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Figura 31. Histograma de la curva normal de la precisión del proceso de diagnóstico Pre-Test

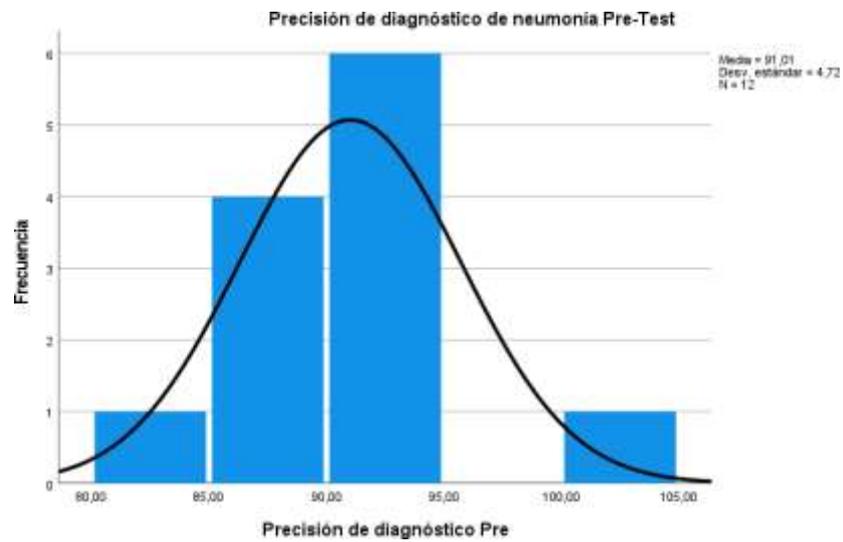
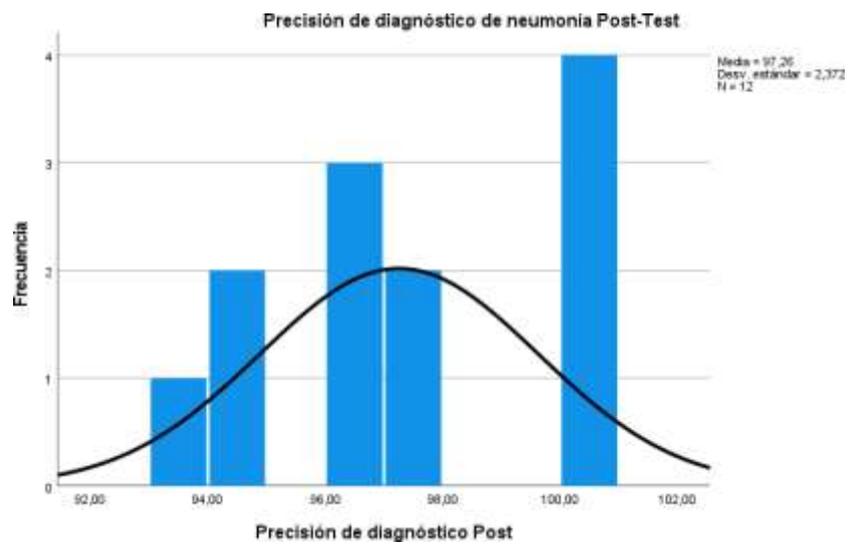


Figura 32. Histograma de la curva normal de la precisión del proceso de diagnóstico Post-Test



H.E.3. El diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Figura 33. Estadísticos descriptivos de la hipótesis específica 3

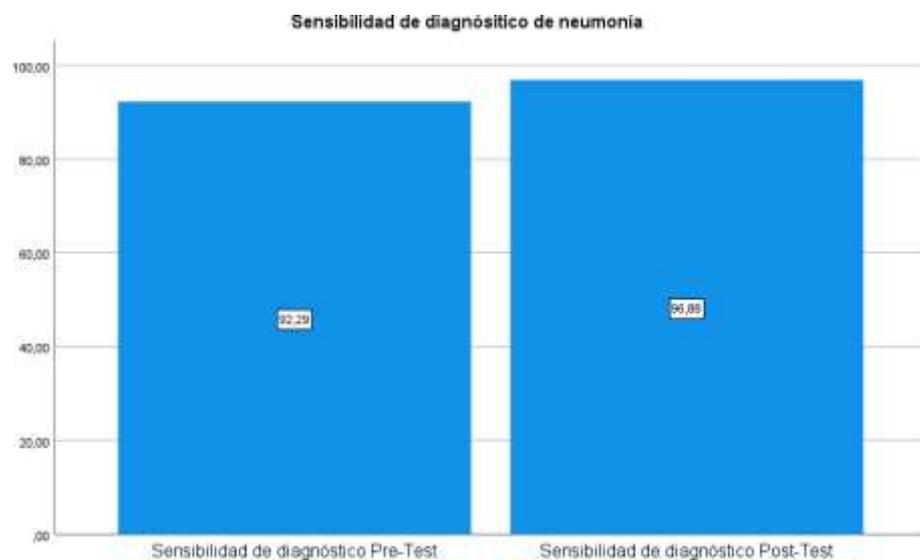
| | | Estadísticos | |
|-----------------------------|----------|---------------------------------|----------------------------------|
| | | Sensibilidad de diagnóstico Pre | Sensibilidad de diagnóstico Post |
| N | Válido | 12 | 12 |
| | Perdidos | 0 | 0 |
| Media | | 92,2908 | 96,8775 |
| Error estándar de la media | | 1,69506 | ,95186 |
| Mediana | | 93,7500 | 97,0550 |
| Moda | | 93,75 | 100,00 |
| Desv. Desviación | | 5,87186 | 3,29733 |
| Varianza | | 34,479 | 10,872 |
| Asimetría | | -,725 | -,550 |
| Error estándar de asimetría | | ,637 | ,637 |
| Curtosis | | -,062 | -1,257 |
| Error estándar de curtosis | | 1,232 | 1,232 |
| Rango | | 18,18 | 8,33 |
| Mínimo | | 81,82 | 91,67 |
| Máximo | | 100,00 | 100,00 |
| Percentiles | 25 | 88,2175 | 93,1900 |
| | 50 | 93,7500 | 97,0550 |
| | 75 | 95,0400 | 100,0000 |

Los resultados correspondientes a los estadísticos descriptivos muestran un cambio significativo en varias medidas de tendencia central. Por ejemplo, la media inicial fue de 92.29, incrementándose a 96.88 después del diseño del modelo de red neuronal convolucional. La mediana que inicialmente fue de 93.75, experimentó un aumento al alcanzar 97.06 en la fase posterior a la implementación del

software. Respecto a la moda, esta registró un cambio significativo de 93.75 hasta 100.

En cuanto a la distribución de los datos, se puede observar un cambio en la asimetría, que cambió de -0.725 antes del evento a -0.550. Finalmente, la curtosis mostró una ligera disminución, variando de -0.062 a -1.257.

Figura 34. Gráfico de barras de sensibilidad de diagnóstico de neumonía pre y post test



En el gráfico de barras mostrado, se puede observar que la diferencia de medias del pre y post test es significativa, variando de un 92.29 a un valor de 96.88. Por lo que, se concluye que, el diseño de un modelo de red neuronal convolucional mejora la sensibilidad del proceso de diagnóstico de neumonía de los pacientes de los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Figura 35. Histograma de la curva normal de sensibilidad de proceso de diagnóstico Pre-Test

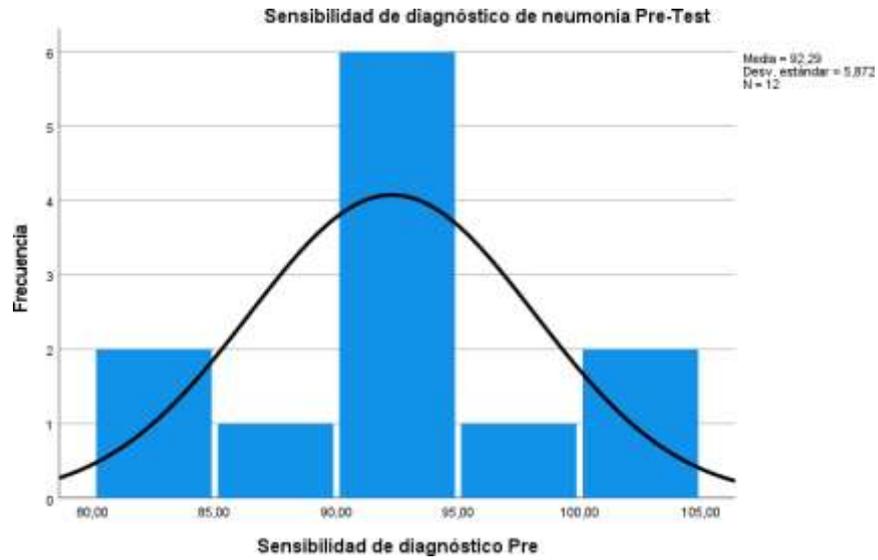
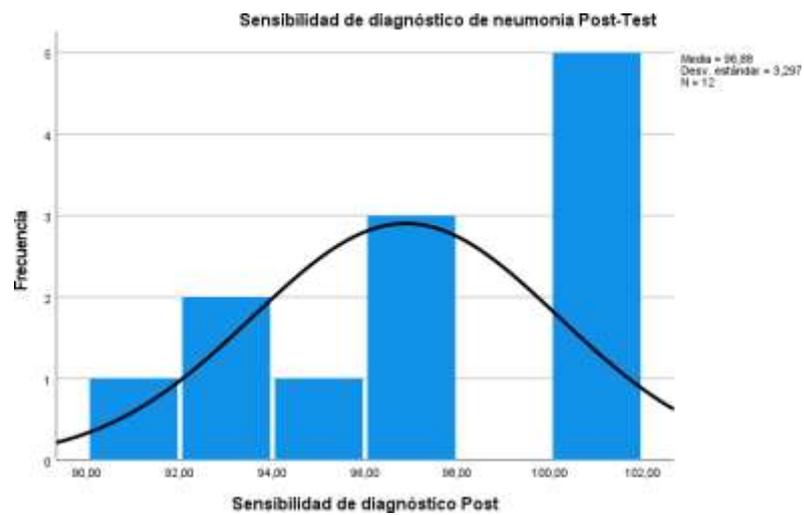


Figura 36. Histograma de la curva normal de sensibilidad de proceso de diagnóstico Post-Test



H.E.4. El diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Figura 37. Estadísticos descriptivos de la hipótesis específica 4

| | | Estadísticos | |
|-----------------------------|----------|----------------------------------|-----------------------------------|
| | | Especificidad de diagnóstico Pre | Especificidad de diagnóstico Post |
| N | Válido | 12 | 12 |
| | Perdidos | 0 | 0 |
| Media | | 90,1442 | 95,2117 |
| Error estándar de la media | | 1,41578 | 1,24082 |
| Mediana | | 92,3100 | 95,0000 |
| Moda | | 85,71 ^a | 100,00 |
| Desv. Desviación | | 4,90441 | 4,29832 |
| Varianza | | 24,053 | 18,476 |
| Asimetría | | -,922 | -,368 |
| Error estándar de asimetría | | ,637 | ,637 |
| Curtosis | | -,198 | -,857 |
| Error estándar de curtosis | | 1,232 | 1,232 |
| Rango | | 15,45 | 12,50 |
| Mínimo | | 80,00 | 87,50 |
| Máximo | | 95,45 | 100,00 |
| Percentiles | 25 | 85,7100 | 91,3900 |
| | 50 | 92,3100 | 95,0000 |
| | 75 | 93,5275 | 100,0000 |

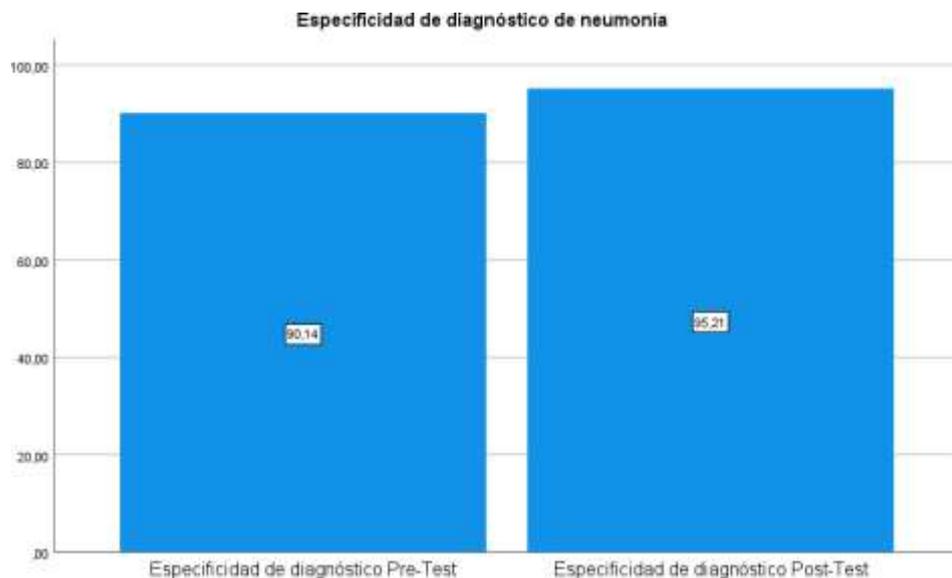
a. Existen múltiples modos. Se muestra el valor más pequeño.

Los resultados correspondientes a los estadísticos descriptivos muestran un cambio significativo en varias medidas de tendencia central. Por ejemplo, la media inicial fue de 90.14, incrementándose a 95.21 después del diseño del modelo de red neuronal convolucional. La mediana que inicialmente fue de 92.31, experimentó un aumento al

alcanzar 95.00 en la fase posterior a la implementación del software. Respecto a la moda, esta registró un cambio significativo de 85.71 hasta 100.

En cuanto a la distribución de los datos, se puede observar un cambio en la asimetría, que cambió de -0.922 antes del evento a -0.368, después del mismo. Finalmente, la curtosis mostró una ligera disminución, variando de -0.198 a -0.857.

Figura 38. Gráfico de barras de especificidad de diagnóstico de neumonía pre y post test



En el gráfico de barras mostrado, se puede observar que la diferencia de medias del pre y post test es significativa, variando de un 90.14 a un valor de 95.21. Por lo que, se concluye que, el diseño de un modelo de red neuronal convolucional mejora la especificidad del proceso de diagnóstico de neumonía de los pacientes de los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Figura 39. Histograma de la curva normal de especificidad de proceso de diagnóstico Pre-Test

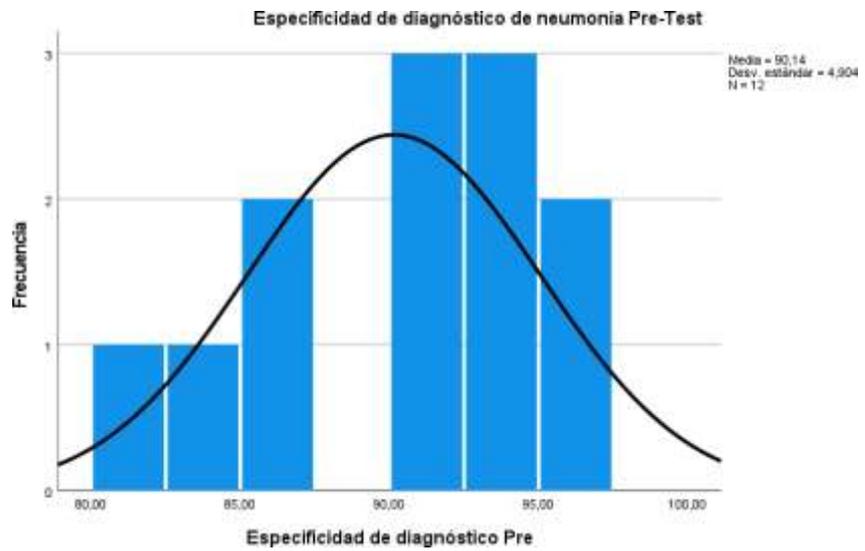
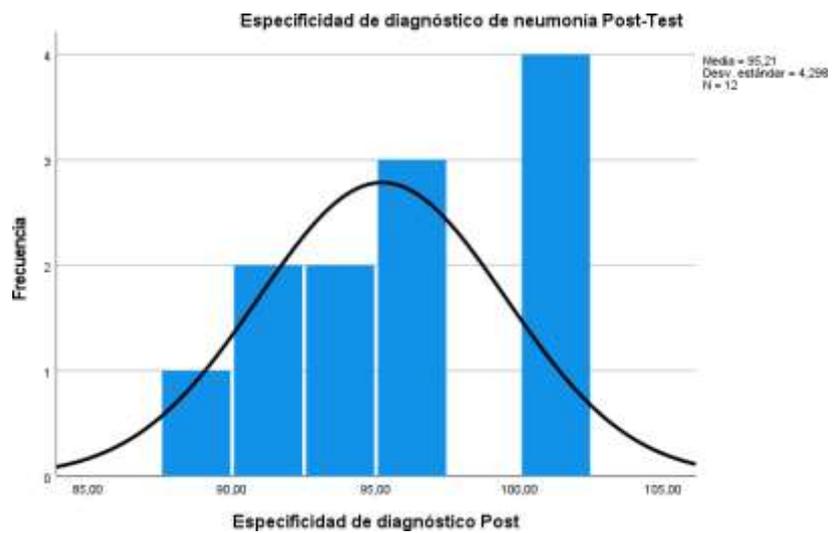


Figura 40. Histograma de la curva normal de especificidad de proceso de diagnóstico Post-Test



5.2 Resultados Inferenciales

5.2.1 Hipótesis General

Prueba de Normalidad

Planteo de las hipótesis de normalidad

H₀: Los datos siguen una distribución normal. $X = N(\mu, \sigma^2)$

H₁: Los datos no siguen una distribución normal. $X \neq N(\mu, \sigma^2)$

Regla de decisión

Si p-valor $\leq \alpha$, se rechaza la hipótesis nula. Si p-valor $> \alpha$ no se rechaza la hipótesis nula.

Decisión estadística

Dado el análisis de normalidad de los datos, el p-valor obtenido fue de $0.401 > 0.05$; por lo que, no existe suficiente evidencia estadística para rechazar la hipótesis nula. En conclusión, se confirma que los datos siguen una distribución normal.

Figura 41. Prueba de normalidad del pre y post test de los datos

| | Pruebas de normalidad | | | | | |
|------------------------------|---------------------------------|----|-------|--------------|----|------|
| | Kolmogorov-Smirnov ^a | | | Shapiro-Wilk | | |
| | Estadístico | gl | Sig. | Estadístico | gl | Sig. |
| DIF_DXPNEUMONIA_POST _PRE | ,150 | 12 | ,200* | ,932 | 12 | ,401 |

*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors

Prueba de T-Student

Planteo de las hipótesis de muestras relacionadas

H.G: El diseño de un modelo red neuronal convolucional mejora el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Procedimiento de contraste de la hipótesis general

Formulación de hipótesis

H_0 : El diseño de un modelo de red neuronal convolucional no mejora el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

H_1 : El diseño de un modelo de red neuronal convolucional mejora el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

Establecimiento del nivel de significancia

Nivel de significancia: $\alpha = 0.05$

Nivel de significancia: Si $p\text{-valor} \leq 0.05$, se acepta la H_1 y se rechaza la H_0 .

Criterios de decisión

Si $p\text{-valor} \leq \alpha$, se rechaza la H_0 .

Si $p\text{-valor} > \alpha$, se acepta la H_0 y se rechaza la H_1 .

Decisión estadística

Con un nivel de significancia del 5%, existe evidencia estadística para rechazar la H_0 , debido a que el $p\text{-valor} = 0.001 < 0.05$, por lo que se rechaza la H_0 y se acepta la H_1 . En conclusión, existe diferencia significativa entre el antes y después del diseño del modelo de red neuronal para el

diagnóstico de neumonía. Por lo tanto, el diseño de un modelo de red neuronal convolucional mejora el proceso de diagnóstico de neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Tabla 6. Prueba de muestras relacionadas del diagnóstico de neumonía

| | | Prueba de muestras emparejadas | | | | | | | |
|-------|--|--------------------------------|---------------------|-------------------------|--|----------|--------|----|------------------|
| | | Diferencias emparejadas | | | | | t | gl | Sig. (bilateral) |
| | | Media | Desviación estándar | Media de error estándar | 95% de intervalo de confianza de la diferencia | | | | |
| | | | | | Inferior | Superior | | | |
| Par 1 | Diagnóstico de Neumonía Pre - Diagnóstico de Neumonía Post | -5,14375 | 2,78119 | ,80286 | -6,91083 | -3,37667 | -6,407 | 11 | <.001 |

Tabla 7. Estadísticos de muestras relacionadas del diagnóstico de neumonía

| | | Estadísticas de muestras emparejadas | | | |
|-------|------------------------------|--------------------------------------|----|---------------------|-------------------------|
| | | Media | N | Desviación estándar | Media de error estándar |
| Par 1 | Diagnóstico de Neumonía Pre | 91,2635 | 12 | 4,34556 | 1,25445 |
| | Diagnóstico de Neumonía Post | 96,4073 | 12 | 2,92684 | ,84490 |

Tabla 8. Correlaciones de muestras relacionadas del diagnóstico de neumonía

| | | Correlaciones de muestras emparejadas | | |
|-------|--|---------------------------------------|-------------|------|
| | | N | Correlación | Sig. |
| Par 1 | Diagnóstico de Neumonía Pre & Diagnóstico de Neumonía Post | 12 | ,775 | ,003 |

5.2.2 Hipótesis Específicas

H.E.1. El diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.

Prueba de normalidad

Planteo de las hipótesis de normalidad

H₀: Los datos siguen una distribución normal. $X = N(\mu, \sigma^2)$

H₁: Los datos no siguen una distribución normal. $X \neq N(\mu, \sigma^2)$

Regla de decisión

Si p-valor $\leq \alpha$, se rechaza la hipótesis nula. Si p-valor $> \alpha$, nose rechaza la hipótesis nula.

Decisión estadística

Dado el análisis de normalidad de los datos, el p-valor obtenido fue de $0.886 > 0.05$; por lo que, no existe suficiente evidencia estadística para rechazar la hipótesis nula. En conclusión, se confirma que los datos siguen una distribución normal.

Tabla 9. Prueba de normalidad de la exactitud pre y post test de los datos

| | Kolmogorov-Smirnov ^a | | | Shapiro-Wilk | | |
|-------------------|---------------------------------|----|-------|--------------|----|------|
| | Estadístico | gl | Sig. | Estadístico | gl | Sig. |
| DIF_EXAC_POST_PRE | ,116 | 12 | ,200* | ,968 | 12 | ,886 |

*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors

Prueba de T-Student

Planteo de las hipótesis de muestras relacionadas

H.E.1: El diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Procedimiento de contraste de la hipótesis específica 1

Formulación de hipótesis

H_0 : El diseño de un modelo de red neuronal convolucional no mejora la exactitud del proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

H_1 : El diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

Establecimiento del nivel de significancia

Nivel de significancia: $\alpha = 0.05$

Nivel de significancia: Si $p\text{-valor} \leq 0.05$, se acepta la H_1 y se rechaza la H_0 .

Criterios de decisión

Si $p\text{-valor} \leq \alpha$, se rechaza la H_0 .

Si $p\text{-valor} > \alpha$, se acepta la H_0 y se rechaza la H_1 .

Decisión estadística

Con un nivel de significancia del 5%, existe evidencia estadística para rechazar la H_0 , debido a que el $p\text{-valor} = 0.001 < 0.05$, por lo que se rechaza la H_0 y se acepta la H_1 . En conclusión, existe diferencia significativa entre el antes y después del diseño del modelo de red neuronal para el

diagnóstico de neumonía. Por lo tanto, el diseño de un modelo de red neuronal convolucional mejora la exactitud del proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Tabla 10. Prueba de muestras relacionadas de la exactitud del diagnóstico de neumonía

| Prueba de muestras emparejadas | | | | | | | | | |
|---------------------------------------|--|----------|---------------------|-------------------------|--|----------|--------|----|------------------|
| Diferencias emparejadas | | | | | | | | | |
| | | Media | Desviación estándar | Media de error estándar | 95% de intervalo de confianza de la diferencia | | 1 | gl | Sig. (bilateral) |
| | | | | | Inferior | Superior | | | |
| Par 1 | Exactitud de diagnóstico Pre - Exactitud de diagnóstico Post | -4,67583 | 3,00684 | ,86800 | -6,58629 | -2,76538 | -5,367 | 11 | <.001 |

Tabla 11. Estadísticos de muestras relacionadas de la exactitud diagnóstico de neumonía

| Estadísticas de muestras emparejadas | | | | | |
|---|-------------------------------|---------|----|---------------------|-------------------------|
| | | Media | N | Desviación estándar | Media de error estándar |
| Par 1 | Exactitud de diagnóstico Pre | 91,6067 | 12 | 4,66676 | 1,34718 |
| | Exactitud de diagnóstico Post | 96,2825 | 12 | 3,10793 | ,89718 |

Tabla 12. Correlación de muestras relacionadas de la exactitud de diagnóstico de neumonía

| Correlaciones de muestras emparejadas | | | | |
|--|--|----|-------------|------|
| | | N | Correlación | Sig. |
| Par 1 | Exactitud de diagnóstico Pre & Exactitud de diagnóstico Post | 12 | ,772 | ,003 |

H.E.2. El diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Prueba de normalidad

Planteo de las hipótesis de normalidad

H₀: Los datos siguen una distribución normal. $X = N(\mu, \sigma^2)$

H₁: Los datos no siguen una distribución normal. $X \neq N(\mu, \sigma^2)$

Regla de decisión

Si p-valor $\leq \alpha$, se rechaza la hipótesis nula. Si p-valor $> \alpha$, no se rechaza la hipótesis nula.

Decisión estadística

Dado el análisis de normalidad de los datos, el p-valor obtenido fue de $0.507 > 0.05$; por lo que, no existe suficiente evidencia estadística para rechazar la hipótesis nula. En conclusión, se confirma que los datos siguen una distribución normal.

Tabla 13. Prueba de normalidad de la precisión pre y post test de los datos

| | Pruebas de normalidad | | | | | |
|--------------------|---------------------------------|----|-------|--------------|----|------|
| | Kolmogorov-Smirnov ^a | | | Shapiro-Wilk | | |
| | Estadístico | gl | Sig. | Estadístico | gl | Sig. |
| DIF_PRECI_POST_PRE | ,167 | 12 | ,200* | ,941 | 12 | ,507 |

*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors

Prueba de T-Student

Planteo de las hipótesis de muestras relacionadas

H.E.2: El diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Procedimiento de contraste de la hipótesis específica 2

Formulación de hipótesis

H₀: El diseño de un modelo de red neuronal convolucional no mejora la precisión en el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

H₁: El diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

Establecimiento del nivel de significancia

Nivel de significancia: $\alpha = 0.05$

Nivel de significancia: Si $p\text{-valor} \leq 0.05$, se acepta la H₁ y se rechaza la H₀.

Criterios de decisión

Si $p\text{-valor} \leq \alpha$, se rechaza la H₀.

Si $p\text{-valor} > \alpha$, se acepta la H₀ y se rechaza la H₁.

Decisión estadística

Con un nivel de significancia del 5%, existe evidencia estadística para rechazar la H₀, debido a que el $p\text{-valor} = 0.001 < 0.05$, por lo que se rechaza la H₀ y se acepta la H₁. En conclusión, existe diferencia significativa entre el antes y después del diseño del modelo de red neuronal para el

diagnóstico de neumonía. Por lo tanto, el diseño de un modelo de red neuronal convolucional mejora la precisión del proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Tabla 14. Prueba de muestras relacionadas de la precisión del diagnóstico de neumonía

| | | Prueba de muestras emparejadas | | | | | | | |
|-------|--|--------------------------------|---------------------|-------------------------|--|----------|--------|----|------------------|
| | | Diferencias emparejadas | | | | | | | |
| | | Media | Desviación estándar | Media de error estándar | 95% de intervalo de confianza de la diferencia | | t | gl | Sig. (bilateral) |
| | | | | | Inferior | Superior | | | |
| Par 1 | Precisión de diagnóstico Pre - Precisión de diagnóstico Post | -6,24500 | 4,04332 | 1,16721 | -8,81400 | -3,67600 | -5,350 | 11 | <.001 |

Tabla 15. Estadísticos de muestras relacionadas de la precisión del diagnóstico de neumonía

| | | Estadísticas de muestras emparejadas | | | |
|-------|-------------------------------|--------------------------------------|----|---------------------|-------------------------|
| | | Media | N | Desviación estándar | Media de error estándar |
| Par 1 | Precisión de diagnóstico Pre | 91,0125 | 12 | 4,71986 | 1,36251 |
| | Precisión de diagnóstico Post | 97,2575 | 12 | 2,37162 | ,68463 |

Tabla 16. Correlación de muestras relacionadas de la precisión de diagnóstico de neumonía

| | | Correlaciones de muestras emparejadas | | |
|-------|--|---------------------------------------|-------------|------|
| | | N | Correlación | Sig. |
| Par 1 | Precisión de diagnóstico Pre & Precisión de diagnóstico Post | 12 | ,516 | ,086 |

H.E.3. El diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Prueba de normalidad

Planteo de las hipótesis de normalidad

H₀: Los datos siguen una distribución normal. $X = N(\mu, \sigma^2)$

H₁: Los datos no siguen una distribución normal. $X \neq N(\mu, \sigma^2)$

Regla de decisión

Si p-valor $\leq \alpha$, se rechaza la hipótesis nula. Si p-valor $> \alpha$, no se rechaza la hipótesis nula.

Decisión estadística

Dado el análisis de normalidad de los datos, el p-valor obtenido fue de $0.265 > 0.05$; por lo que, no existe suficiente evidencia estadística para rechazar la hipótesis nula. En conclusión, se confirma que los datos siguen una distribución normal.

Tabla 17. Prueba de normalidad de la sensibilidad pre y post test de los datos

| | Pruebas de normalidad | | | | | |
|--------------------|---------------------------------|----|-------|--------------|----|------|
| | Kolmogorov-Smirnov ^a | | | Shapiro-Wilk | | |
| | Estadístico | gl | Sig. | Estadístico | gl | Sig. |
| DIF_SENSI_POST_PRE | ,160 | 12 | ,200* | ,917 | 12 | ,265 |

*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors

Prueba de T-Student

Planteo de las hipótesis de muestras relacionadas

H.E.3: El diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Procedimiento de contraste de la hipótesis específica 3

Formulación de hipótesis

H₀: El diseño de un modelo de red neuronal convolucional no mejora la sensibilidad en el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

H₁: El diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

Establecimiento del nivel de significancia

Nivel de significancia: $\alpha = 0.05$

Nivel de significancia: Si $p\text{-valor} \leq 0.05$, se acepta la H₁ y se rechaza la H₀.

Criterios de decisión

Si $p\text{-valor} \leq \alpha$, se rechaza la H₀.

Si $p\text{-valor} > \alpha$, se acepta la H₀ y se rechaza la H₁.

Decisión estadística

Con un nivel de significancia del 5%, existe evidencia estadística para rechazar la H₀, debido a que el $p\text{-valor} = 0.017 < 0.05$, por lo que se rechaza la H₀ y se acepta la H₁. En conclusión, existe diferencia significativa entre el antes y después del diseño del modelo de red neuronal para el

diagnóstico de neumonía. Por lo tanto, el diseño de un modelo de red neuronal convolucional mejora la sensibilidad del proceso de diagnóstico de la neumonía en los pacientes Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Tabla 18. Prueba de muestras relacionadas de la sensibilidad del diagnóstico de neumonía

| | | Prueba de muestras emparejadas | | | | | | | |
|----------|--|--------------------------------|---------------------|-------------------------|--|---------|--------|----|------------------|
| | | Media | Desviación estándar | Media de error estándar | 95% de intervalo de confianza de la diferencia | | t | gl | Sig. (bilateral) |
| Inferior | Superior | | | | | | | | |
| Par 1 | Sensibilidad de diagnóstico Pre - Sensibilidad de diagnóstico Post | -4,58667 | 5,68922 | 1,64234 | -8,20143 | -,97191 | -2,793 | 11 | ,017 |

Tabla 19. Estadísticos de muestras relacionadas de la sensibilidad del diagnóstico de neumonía

| | | Estadísticas de muestras emparejadas | | | |
|-------|----------------------------------|--------------------------------------|----|---------------------|-------------------------|
| | | Media | N | Desviación estándar | Media de error estándar |
| Par 1 | Sensibilidad de diagnóstico Pre | 92,2908 | 12 | 5,87186 | 1,69506 |
| | Sensibilidad de diagnóstico Post | 96,8775 | 12 | 3,29733 | ,95186 |

Tabla 20. Correlación de muestras relacionadas de la sensibilidad de diagnóstico de neumonía

| | | N | Correlación | Sig. |
|-------|--|----|-------------|------|
| Par 1 | Sensibilidad de diagnóstico Pre & Sensibilidad de diagnóstico Post | 12 | ,335 | ,287 |

H.E.4. El diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Prueba de normalidad

Planteo de las hipótesis de normalidad

H₀: Los datos siguen una distribución normal. $X = N(\mu, \sigma^2)$

H₁: Los datos no siguen una distribución normal. $X \neq N(\mu, \sigma^2)$

Regla de decisión

Si p-valor $\leq \alpha$, se rechaza la hipótesis nula. Si p-valor $> \alpha$, nose rechaza la hipótesis nula.

Decisión estadística

Dado el análisis de normalidad de los datos, el p-valor obtenido fue de $0.153 > 0.05$; por lo que, no existe suficiente evidencia estadística para rechazar la hipótesis nula. En conclusión, se confirma que los datos siguen una distribución normal.

Tabla 21. Prueba de normalidad de la especificidad pre y post test de los datos

| | Pruebas de normalidad | | | | | |
|-------------------|---------------------------------|----|------|--------------|----|------|
| | Kolmogorov-Smirnov ^a | | | Shapiro-Wilk | | |
| | Estadístico | gl | Sig. | Estadístico | gl | Sig. |
| DIF_ESPE_POST_PRE | ,206 | 12 | ,168 | ,899 | 12 | ,153 |

a. Corrección de significación de Lilliefors

Prueba de T-Student

Planteo de las hipótesis de muestras relacionadas

H.E.4: El diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Procedimiento de contraste de la hipótesis específica 4

Formulación de hipótesis

H_0 : El diseño de un modelo de red neuronal convolucional no mejora la especificidad en el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

H_1 : El diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de neumonía en los pacientes de un hospital de Bagua.

Establecimiento del nivel de significancia

Nivel de significancia: $\alpha = 0.05$

Nivel de significancia: Si $p\text{-valor} \leq 0.05$, se acepta la H_1 y se rechaza la H_0 .

Criterios de decisión

Si $p\text{-valor} \leq \alpha$, se rechaza la H_0 .

Si $p\text{-valor} > \alpha$, se acepta la H_0 y se rechaza la H_1 .

Decisión estadística

Con un nivel de significancia del 5%, existe evidencia estadística para rechazar la H_0 , debido a que el $p\text{-valor} = 0.001 < 0.05$, por lo que se rechaza la H_0 y se acepta la H_1 . En conclusión, existe diferencia significativa entre el antes y después del diseño del modelo de red neuronal para el

diagnóstico de neumonía. Por lo tanto, el diseño de un modelo de red neuronal convolucional mejora la especificidad del proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Tabla 22. Prueba de muestras relacionadas de la especificidad del diagnóstico de neumonía

| | | Prueba de muestras emparejadas | | | | | | | |
|-------|--|--------------------------------|---------------------|-------------------------|--|----------|--------|----|------------------|
| | | Diferencias emparejadas | | | | | t | gl | Sig. (bilateral) |
| | | Media | Desviación estándar | Media de error estándar | 95% de intervalo de confianza de la diferencia | | | | |
| | | | | | Inferior | Superior | | | |
| Par 1 | Especificidad de diagnóstico Pre - Especificidad de diagnóstico Post | -5,06750 | 2,97669 | ,85930 | -6,95880 | -3,17620 | -5,897 | 11 | < ,001 |

Tabla 23. Estadísticos de muestras relacionadas de la especificidad del diagnóstico de neumonía

| | | Estadísticas de muestras emparejadas | | | |
|-------|-----------------------------------|--------------------------------------|----|---------------------|-------------------------|
| | | Media | N | Desviación estándar | Media de error estándar |
| Par 1 | Especificidad de diagnóstico Pre | 90,1442 | 12 | 4,90441 | 1,41578 |
| | Especificidad de diagnóstico Post | 95,2117 | 12 | 4,29832 | 1,24082 |

Tabla 24. Correlación de muestras relacionadas de la especificidad de diagnóstico de neumonía

| | | N | Correlación | Sig. |
|-------|--|----|-------------|------|
| Par 1 | Especificidad de diagnóstico Pre & Especificidad de diagnóstico Post | 12 | ,799 | ,002 |

VI. DISCUSIÓN DE RESULTADOS

6.1 Contrastación y demostración de la hipótesis con los resultados

Hipótesis General

H.G: El diseño de un modelo de red neuronal convolucional mejora el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Los resultados descriptivos y las pruebas correspondientes a la estadística inferencial coinciden en que el diseño de un modelo de red neuronal convolucional mejora significativamente el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas. Estos hallazgos no solo resaltan la eficacia del diseño basado en Inteligencia Artificial, sino que proporcionan una base sólida para la toma de decisiones basadas en datos y la mejorar continua de los procesos operativos relacionados al diagnóstico temprano de la neumonía.

Resultados Descriptivos

El proceso de diagnóstico de neumonía experimentó una mejora significativa, la cual se evidencia en la comparación de medias del pre y post test. En el presente estudio, la variable dependiente del pretest tuvo una media de 91.26, mientras que en el post test mostró un incremento, mostrando una media de 96.41, lo que indica un impacto positivo del diseño de red neuronal convolucional para el proceso de diagnóstico de neumonía.

Por otro lado, la reducción en la desviación típica del diagnóstico de neumonía de 4.35 (pretest) a 2.93 (post test), lo que sugiere una mayor consistencia en el diagnóstico de la neumonía luego del diseño de modelo de red neuronal convolucional. Finalmente, la mediana y la moda también reflejan un cambio hacia valores más altos en el diagnóstico de la neumonía del post test, respaldando la

tendencia de mejora durante el proceso de diagnóstico de la enfermedad.

Pruebas inferenciales

Prueba de normalidad

Las pruebas de normalidad realizadas indicaron que los datos del proceso de diagnóstico de neumonía pre y post test siguen una distribución normal. Este resultado es crucial para el uso de pruebas paramétricas, como la prueba T-Student utilizada en el presente proyecto de investigación, donde se requiere que los datos sigan una distribución normal.

Pruebas de muestras relacionadas

La hipótesis nula (H_0), que afirmaba que el diseño de un modelo de red neuronal convolucional no mejoraba positivamente el proceso de diagnóstico de neumonía fue rechazada con un p-valor de 0.001 ($p\text{-valor} \leq \alpha = 0,05$). Esto indica directamente que, el diseño de un modelo de red neuronal convolucional, mejora significativamente el proceso de diagnóstico de neumonía.

La prueba de muestras relacionadas confirma la diferencia significativa entre el diagnóstico de neumonía del pre y post test. La media de las diferencias (-5.14) y el intervalo de confianza respaldan la afirmación de que el diseño de un modelo de red neuronal convolucional ha tenido un impacto significativo, directo y positivo en el proceso de diagnóstico de neumonía.

Hipótesis específicas

Hipótesis específica 1

H.E.1: El diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Los resultados descriptivos y las pruebas de estadística inferencial convergen en la conclusión que el diseño de un modelo de red neuronal convolucional ha tenido un impacto positivo, directo y significativo en la exactitud del proceso de diagnóstico de neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Resultados descriptivos

La mejora de la exactitud del proceso de diagnóstico de neumonía es evidente al realizar la comparación de las medias. Tal es así, que la exactitud correspondiente al pretest registró una media de 91.61, mientras que la exactitud del post test mostró un aumento, mostrando una media de 96.28, lo que indica un impacto positivo del diseño del modelo de red neuronal convolucional en la exactitud del proceso de diagnóstico de neumonía.

La reducción de la desviación típica que se evidencia en la exactitud del post y pretest, variando de un 3.11 a 4.67 respectivamente; esto refleja una mayor consistencia en la exactitud luego del diseño de un modelo de red neuronal convolucional.

Las medidas como la moda y la mediana también reflejan el cambio positivo de la tendencia central de los datos, mostrando los valores más altos después del diseño del modelo de red neuronal convolucional implementado.

Pruebas inferenciales

Prueba de normalidad

Para el presente estudio, se utilizó la prueba de Shapiro-Wilk ($n \leq 50$) para determinar si el conjunto de datos sigue una distribución normal. Como resultado, se obtuvo que los datos se asemejan significativamente a la distribución normal. Este hallazgo es de vital

importancia, ya que confirma la validez de las pruebas estadísticas paramétricas realizadas posteriormente.

Pruebas de muestras relacionadas

La hipótesis nula (H_0), que afirmaba que el diseño de un modelo de red neuronal convolucional no mejoraba positivamente la exactitud del proceso de diagnóstico de neumonía fue rechazada con un p-valor de 0.001 ($p\text{-valor} \leq \alpha = 0,05$). Esto indica directamente que, el diseño de un modelo de red neuronal convolucional, mejora significativamente la exactitud del proceso de diagnóstico de neumonía. Los resultados obtenidos respaldan de manera contundente la hipótesis específica 1 en el contexto de una tesis preexperimental. El diseño de un modelo de red neuronal convolucional se encuentra asociado con mejoras significativas en la exactitud del proceso de diagnóstico, lo que fortalece la validez de la intervención en este contexto de diagnóstico de esta enfermedad.

La prueba de muestras relacionadas confirma la diferencia significativa entre la exactitud del diagnóstico de neumonía del pre y post test. La media de las diferencias (-4.68) y el intervalo de confianza respaldan la afirmación de que el diseño de un modelo de red neuronal convolucional ha tenido un impacto significativo, directo y positivo en la exactitud del proceso de diagnóstico de neumonía.

Hipótesis específica 2

H.E.2: El diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Los resultados descriptivos y las pruebas de estadística inferencial respaldan la conclusión de que el diseño de un modelo de red neuronal convolucional ha tenido un impacto positivo, directo y significativo en la precisión del proceso de diagnóstico de neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.

Resultados descriptivos

La mejora de la precisión del proceso de diagnóstico de neumonía es evidente al realizar la comparación de las medias. Tal es así, que la precisión correspondiente al pretest registró una media de 91.01, mientras que la precisión del post test mostró un aumento, mostrando una media de 97.26, lo que indica un impacto positivo del diseño del modelo de red neuronal convolucional en la precisión del proceso de diagnóstico de neumonía.

La reducción de la desviación típica que se evidencia en la precisión del post y pretest, variando de un 2.37 a 4.72 respectivamente; esto refleja una mayor consistencia en la precisión luego del diseño de un modelo de red neuronal convolucional.

Las medidas como la moda y la mediana también reflejan el cambio positivo de la tendencia central de los datos, mostrando los valores más altos después del diseño del modelo de red neuronal convolucional implementado.

Pruebas inferenciales

Prueba de normalidad

Para el presente estudio, se utilizó la prueba de Shapiro-Wilk ($n \leq 50$) para determinar si el conjunto de datos sigue una distribución normal. Como resultado, se obtuvo que los datos se asemejan significativamente a la distribución normal. Este hallazgo es de vital

importancia, ya que confirma la validez de las pruebas estadísticas paramétricas realizadas posteriormente.

Pruebas de muestras relacionadas

La hipótesis nula (H_0), que afirmaba que, el diseño de un modelo de red neuronal convolucional no mejoraba positivamente la precisión del proceso de diagnóstico de neumonía fue rechazada con un p-valor de 0.001 ($p\text{-valor} \leq \alpha = 0,05$). Esto indica directamente que, el diseño de un modelo de red neuronal convolucional, mejora significativamente la precisión del proceso de diagnóstico de neumonía. Los resultados obtenidos respaldan de manera contundente la hipótesis específica 2 en el contexto de una tesis preexperimental. El diseño de un modelo de red neuronal convolucional se encuentra asociado con mejoras significativas en la precisión del proceso de diagnóstico, lo que fortalece la validez de la intervención en este contexto de diagnóstico de esta enfermedad.

La prueba de muestras relacionadas confirma la diferencia significativa entre la precisión del diagnóstico de neumonía del pre y post test. La media de las diferencias (-6.25) y el intervalo de confianza respaldan la afirmación de que el diseño de un modelo de red neuronal convolucional ha tenido un impacto significativo, directo y positivo en la precisión del proceso de diagnóstico de neumonía.

Hipótesis específica 3

H.E.3: El diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas.

Los resultados descriptivos y las pruebas de estadística inferencial respaldan la conclusión de que el diseño de un modelo de red neuronal convolucional ha tenido un impacto positivo, directo y significativo en la sensibilidad del proceso de diagnóstico de neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.

Resultados descriptivos

La mejora de la sensibilidad del proceso de diagnóstico de neumonía es evidente al realizar la comparación de las medias. Tal es así, que la sensibilidad correspondiente al pretest registró una media de 92.29, mientras que la precisión del post test mostró un aumento, mostrando una media de 96.88, lo que indica un impacto positivo del diseño del modelo de red neuronal convolucional en la sensibilidad del proceso de diagnóstico de neumonía.

La reducción de la desviación típica que se evidencia en la precisión del post y pretest, variando de un 0.95 a 1.70 respectivamente; esto refleja una mayor consistencia en la sensibilidad luego del diseño de un modelo de red neuronal convolucional.

Las medidas como la moda y la mediana también reflejan el cambio positivo de la tendencia central de los datos, mostrando los valores más altos después del diseño del modelo de red neuronal convolucional implementado.

Pruebas inferenciales

Prueba de normalidad

Para el presente estudio, se utilizó la prueba de Shapiro-Wilk ($n \leq 50$) para determinar si el conjunto de datos sigue una distribución normal. Como resultado, se obtuvo que los datos se asemejan significativamente a la distribución normal. Este hallazgo es de vital

importancia, ya que confirma la validez de las pruebas estadísticas paramétricas realizadas posteriormente.

Pruebas de muestras relacionadas

La hipótesis nula (H_0), que afirmaba que, el diseño de un modelo de red neuronal convolucional no mejoraba positivamente la precisión del proceso de diagnóstico de neumonía fue rechazada con un p-valor de 0.017 ($p\text{-valor} \leq \alpha = 0,05$). Esto indica directamente que, el diseño de un modelo de red neuronal convolucional, mejora significativamente la sensibilidad del proceso de diagnóstico de neumonía. Los resultados obtenidos respaldan de manera contundente la hipótesis específica 3 en el contexto de una tesis preexperimental. El diseño de un modelo de red neuronal convolucional se encuentra asociado con mejoras significativas en la sensibilidad del proceso de diagnóstico, lo que fortalece la validez de la intervención en este contexto de diagnóstico de esta enfermedad.

La prueba de muestras relacionadas confirma la diferencia significativa entre la sensibilidad del diagnóstico de neumonía del pre y post test. La media de las diferencias (-4.59) y el intervalo de confianza respaldan la afirmación de que el diseño de un modelo de red neuronal convolucional ha tenido un impacto significativo, directo y positivo en la sensibilidad del proceso de diagnóstico de neumonía.

Hipótesis específica 4

H.E.4: El diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.

Los resultados descriptivos y las pruebas de estadística inferencial respaldan la conclusión de que el diseño de un modelo de red neuronal convolucional ha tenido un impacto positivo, directo y significativo en la especificidad del proceso de diagnóstico de neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.

Resultados descriptivos

La mejora de la especificidad del proceso de diagnóstico de neumonía es evidente al realizar la comparación de las medias. Tal es así, que la especificidad correspondiente al pretest registró una media de 90.14, mientras que la precisión del post test mostró un aumento, mostrando una media de 95.21, lo que indica un impacto positivo del diseño del modelo de red neuronal convolucional en la especificidad del proceso de diagnóstico de neumonía.

La reducción de la desviación típica que se evidencia en la precisión del post y pretest, variando de un 1.24 a 1.42 respectivamente; esto refleja una mayor consistencia en la especificidad luego del diseño de un modelo de red neuronal convolucional.

Las medidas como la moda y la mediana también reflejan el cambio positivo de la tendencia central de los datos, mostrando los valores más altos después del diseño del modelo de red neuronal convolucional implementado.

Pruebas inferenciales

Prueba de normalidad

Para el presente estudio, se utilizó la prueba de Shapiro-Wilk ($n \leq 50$) para determinar si el conjunto de datos sigue una distribución normal. Como resultado, se obtuvo que los datos se asemejan significativamente a la distribución normal. Este hallazgo es de vital

importancia, ya que confirma la validez de las pruebas estadísticas paramétricas realizadas posteriormente.

Pruebas de muestras relacionadas

La hipótesis nula (H_0), que afirmaba que, el diseño de un modelo de red neuronal convolucional no mejoraba positivamente la precisión del proceso de diagnóstico de neumonía fue rechazada con un p-valor de 0.001 ($p\text{-valor} \leq \alpha = 0,05$). Esto indica directamente que, el diseño de un modelo de red neuronal convolucional, mejora significativamente la especificidad del proceso de diagnóstico de neumonía. Los resultados obtenidos respaldan de manera contundente la hipótesis específica 4 en el contexto de una tesis preexperimental. El diseño de un modelo de red neuronal convolucional se encuentra asociado con mejoras significativas en la especificidad del proceso de diagnóstico, lo que fortalece la validez de la intervención en este contexto de diagnóstico de esta enfermedad.

La prueba de muestras relacionadas confirma la diferencia significativa entre la especificidad del diagnóstico de neumonía del pre y post test. La media de las diferencias (-5.07) y el intervalo de confianza respaldan la afirmación de que el diseño de un modelo de red neuronal convolucional ha tenido un impacto significativo, directo y positivo en la especificidad del proceso de diagnóstico de neumonía.

6.2 Contrastación de los resultados con otros estudios similares

En la presente investigación, los resultados obtenidos ponen de manifiesto que la exactitud del proceso de diagnóstico, previa al diseño de un modelo de red neuronal convolucional, se ubicaba en un 91.61%. Posterior a la implementación del diseño de diagnóstico de neumonía, se observó una mejora sustancial, alcanzando un destacado 96.28%. En referencia a la precisión del proceso de diagnóstico, el índice previo a la implementación del diseño se

situaba en un 91.01%, experimentando un aumento hasta alcanzar un 97.26% tras la implementación del diseño. Respecto a la sensibilidad del proceso de diagnóstico, el indicador previo al diseño era del 92.29%, experimentando un aumento hasta alcanzar un 96.88%. En lo que se refiere a la especificidad del proceso de diagnóstico, el índice previo al diseño de un modelo de red neuronal era del 90.14%, posterior a la aplicación del diseño se mostró una mejora, alcanzando un destacado 95.21%. Finalmente, respecto al proceso de diagnóstico de neumonía, el indicador previo al diseño era de 91.26% y tras la implementación, este experimentó un aumento, alcanzando un valor de 96.41%.

En la investigación “Aplicación de redes neuronales convolucionales profundas al diagnóstico asistido de la enfermedad de Alzheimer” realizada por De la Vega Jiménez (2021), estudio presentado en la Universidad de Granada de España se llega a la conclusión que el indicador exactitud experimenta una mejora significativa para mejorar el diagnóstico de la enfermedad de Alzheimer. La exactitud varía de un 80% a un 90%, después de la aplicación de las redes neuronales convolucionales. En cuanto a la sensibilidad, el modelo usado alcanza un 57.14%, el cual indica una cantidad considerable de diagnósticos correctos. Finalmente, la especificidad, llegó a un 88.88%, lo que indica que el modelo diagnostica de manera correcta aquellos pacientes que no presentan la enfermedad.

Por otro lado, en la investigación titulada Sistema Inteligente Móvil Basado en Redes Neuronales Convolucionales para el Diagnóstico previo de Enfermedades Renales, realizada por (García Cortegano, 2020) en la Universidad Nacional Federico Villareal los resultados de los indicadores obtenidos han experimentado mejoras en la eficacia, sensibilidad y especificidad, a partir de la implementación del algoritmo de red neuronal convolucional. Tal es así, que se obtuvo un índice de eficacia del 100%, lo que determina un valor excelente. En cuanto a la sensibilidad y especificidad, se obtuvieron

índices promedio del 100% y 99% respectivamente; lo que indica, un valor excelente para ambos casos.

Asimismo, en la investigación “Sistema inteligente basado en redes neuronales para la identificación de cáncer de piel de tipo melanoma en imágenes de lesiones cutáneas” realizada por (Villanueva Alarcón, 2021) relacionada a la implementación de un sistema inteligente basado en redes neuronales para la identificación de cáncer de piel de tipo melanoma, se obtuvo mejoras significativas en las métricas de desempeño tales como precisión, sensibilidad y especificidad. En este sentido, se mostró un 92.85% de precisión, 71.50% de sensibilidad y 94.89% de especificidad, lo que demuestra una mejora de 0.06% en precisión y 0.06% en especificidad antes de la implementación del sistema. Así que, la evaluación de la propuesta mejora el desempeño del sistema inteligente implementado de manera significativa.

6.3 Responsabilidad ética de acuerdo con los reglamentos vigentes

Se respetó las normas éticas y legales del hospital Gustavo Lanatta Luján de Bagua-Amazonas, donde se guardó el anonimato de cada radiografía proporcionada por el Hospital. Además de ello el presente estudio, tomó como referencia las pautas éticas en la orientación del compromiso ético como investigador, acorde con las normas y lineamientos del Código de Ética en investigación de la UNAC, aprobadas por Consejo Universitario el día 06 de julio de 2017, mediante resolución N° 210-2017-CU. Estos principios abarcan aspectos de profesionalismo, objetividad, transparencia, honestidad, equidad, confidencialidad y compromiso.

VII. CONCLUSIONES

Luego de analizar los datos, llegamos a la conclusión y podemos afirmar, que el Diseño de una red Neuronal Convolucional mejora la exactitud en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas y esto queda demostrado estadísticamente porque el nivel de significancia es de 0.001, ver tabla 10, además se registró una media de 91.61% en el pretest mientras que el post-test 96.28%, ver figura 28, mostrando de esta manera un impacto positivo. Por lo tanto, se acepta la primera Hipótesis Especifica.

Luego de analizar los datos, llegamos a la conclusión y podemos afirmar, que el Diseño de una red Neuronal Convolucional mejora la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas y esto queda demostrado estadísticamente porque el nivel de significancia es de 0.001, ver tabla 14, además se registró una media de 91.01% en el pre-test mientras que el post-test 97.26%, ver figura 31, mostrando de esta manera un impacto positivo. Por lo tanto, se acepta la segunda Hipótesis Especifica.

Luego de analizar los datos, llegamos a la conclusión y podemos afirmar, que el Diseño de una red Neuronal Convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas y esto queda demostrado estadísticamente porque el nivel de significancia es de 0.017, ver tabla 18, además se registró una media de 92.29% en el pre-test mientras que el post-test 96.88%, ver figura 35, mostrando de esta manera un impacto positivo. Por lo tanto, se acepta la tercera Hipótesis Especifica.

Luego de analizar los datos, llegamos a la conclusión y podemos afirmar, que el Diseño de una red Neuronal Convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas y esto queda demostrado estadísticamente porque el nivel de significancia es de 0.001, ver tabla 22, además se registró una media de 90.14% en el pre-test mientras que el

post-test 95.21%, ver figura 39, mostrando de esta manera un impacto positivo. Por lo tanto, se acepta la cuarta Hipótesis Específica.

Luego de analizar los datos, llegamos a la conclusión y podemos afirmar, que el Diseño de una red Neuronal Convolutiva mejora el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua-Amazonas y esto queda demostrado estadísticamente porque el nivel de significancia es de 0.001, ver tabla 6, además se registró una media de 91.26% en el pre-test mientras que el post-test 96.41%, ver figura 25, mostrando de esta manera un impacto positivo. Por lo tanto, se acepta la Hipótesis General.

VIII. RECOMENDACIONES

Se recomienda implementar un programa de capacitación continúa dirigido al personal encargado de utilizar el modelo de red neuronal convolucional, con la finalidad de garantizar el uso efectivo del diseño, asegurando mantener altos niveles de competencia y eficiencia en el uso del modelo, lo que se traducirá en diagnósticos más precisos y oportunidades de tratamiento temprano.

Se recomienda la participación de especialistas pediátricos y radiólogos de manera activa para validar el funcionamiento del modelo de red neuronal convolucional, lo que permitirá otorgar un mayor peso a la validación, asegurando las métricas de rendimiento del modelo tales como la exactitud, precisión, sensibilidad y especificidad; así como, la claridad en la interpretación de los resultados obtenidos para el proceso de diagnóstico de neumonía en pacientes pediátricos.

Se recomienda establecer un programa de monitoreo y actualización periódica del modelo de red neuronal convolucional, el cual garantizará la funcionalidad del modelo a lo largo el tiempo, permitiendo la identificación de mejoras, corrección de posibles errores y la adaptación del modelo a las necesidades cambiantes del área de Imagenología del Hospital Gustavo Lanatta Luján de Bagua.

IX. REFERENCIAS

- AGUILAR GUIZADO, J. y SOTELO HERRERA, C., 2020. *Diseño de un modelo predictivo para la detección temprana de la Neumonía utilizando Deep Learning y Visión Computacional* [en línea]. S.l.: s.n. [Consulta: 5 mayo 2024]. Disponible en: <https://repositorio.utp.edu.pe/handle/20.500.12867/3970>.
- BABBIE, Earl R. *The practice of social research*. Cengage AU, 2020.
- BENGIO, Y., GOODFELLOW, I. y COURVILLE, A., 2015. *Deep Learning*. Primera. S.l.: MIT Press. ISBN 9780262337373.
- BENIGUI, Y.; LOPEZ, F.; SCHMUNIS, G.; YUNES, J., 2015. *Infecciones respiratorias en niños* [en línea]. S.l.: s.n. Disponible en: <http://iris.paho.org/xmlui/handle/123456789/3093>.
- BISHOP, Christopher M. *Pattern recognition and machine learning*. Springer google schola, 2006, vol. 2, p. 645-678.
- BUSTOS JIMÉNEZ, J.J., 2022. *Método de apoyo para el diagnóstico en imágenes radiológicas de neumonía pediátrica mediante técnicas de inteligencia artificial*. S.l.: Universidad El Bosque.
- CAYA PÉREZ, J.C., 2020. *Evaluación de Modelos de Redes Neuronales Convolucionales Aplicado a Radiografías de Tórax, Para Apoyar al Proceso de Diagnóstico de Neumonía Asociada al COVID-19* [en línea]. S.l.: Universidad Ricardo Palma. [Consulta: 5 mayo 2024]. Disponible en: <https://hdl.handle.net/20.500.14138/3523>.
- CENTRO NACIONAL DE EPIDEMIOLOGÍA, P. y C. de E., MUNAYCO, C.V. y ULLOA, G., 2019. *Análisis de Situación de Salud del Perú, 2019* [en línea]. Perú: s.n. [Consulta: 8 octubre 2021]. Disponible en: www.vitalstrategies.org.
- CHOLLET, F., 2017. *Deep learning with Python*. Primera. S.l.: Manning Publications Co. ISBN 9781617294433.
- Clinic, M. (05 de Mayo de 2020). Mayo Clinic. Recuperado el 05 de Febrero de 2024, de Mayo Clinic Web Site: <https://www.mayoclinic.org/es/diseases-conditions/pneumonia/symptoms-causes/syc-20354204>
- CONSEJO GENERAL DE COLEGIOS FARMACÉUTICOS, 2019. *Neumonía: Punto Farmacológico*. S.l.: s.n.

- Dadonaite, Bernadeta; Roser, Max;. 2019. Our World in Data. Our World in Data Web Site. [En línea] Noviembre de 2019. <https://ourworldindata.org/pneumonia>.
- DE LA VEGA, A., 2021. *Aplicacion de redes neuronales convolucionales profundas al diagnóstico asistido de la enfermedad de Alzheimer* [en línea]. S.I.: Universidad de Granada. Disponible en: <http://arxiv.org/abs/2210.08330>.
- DOMINGOS, P., 2012. *A few useful things to know about machine learning*. 2012. S.I.: s.n.
- FANG, W., LOVE, P.E.D., LUO, H. y DING, L., 2020. Computer vision for behaviour-based safety in construction: A review and future directions. *Advanced Engineering Informatics* [en línea], vol. 43, no. February 2019, pp. 100980. ISSN 14740346. DOI 10.1016/j.aei.2019.100980. Disponible en: <https://doi.org/10.1016/j.aei.2019.100980>.
- Fows, Jacqueline. 2018. *El Pais*. *El Pais web site*. [En línea] 8 de Julio de 2018. [Citado el: 20 de Septiembre de 2021.] https://elpais.com/internacional/2018/07/08/america/1531010611_270923.html.
- GARCÍA CORTEGANO, C.A., 2020. *Sistema Inteligente Móvil Basado En Redes Neuronales Convolucionales Para El Diagnóstico Previo De Enfermedades Renales*. S.I.: Universidad Nacional Federico Villareal.
- GÉRON, A., 2022. *Hands-On-Machine-Learning with Scikit-Learn, Keras y TensorFlow*. Tercera. S.I.: O'Reilly Media, Inc. ISBN 9781492032649.
- GILANI, Z., KWONG, Y.D., LEVINE, O.S., DELORIA-KNOLL, M., SCOTT, J.A.G., O'BRIEN, K.L. y FEIKIN, D.R., 2012. *A literature review and survey of childhood pneumonia etiology studies: 2000-2010*. 1 abril 2012. S.I.: s.n.
- GODOY FRANCISCO, V.L., 2020. *Algoritmo de diagnóstico preliminar de neumonía a partir de imágenes radiográficas del tórax* [en línea]. S.I.: Universidad César Vallejo. [Consulta: 5 mayo 2024]. Disponible en: <https://hdl.handle.net/20500.12692/66465>.
- GOODFELLOW, I., BENGIO, Y. y COURVILLE, A., 2016. *Deep Learning*. S.I.: MIT Press. ISBN 9780262337373.
- GRUS, J., 2019. *Data Science from Scratch: First Principles with Python*. Segunda. S.I.: O'Reilly Media Inc. ISBN 978-1-492-04113-9.
- GU, J., WANG, Z., KUEN, J., MA, L., SHAHROUDY, A., SHUAI, B., LIU, T., WANG, X., WANG, G., CAI, J. y CHEN, T., 2018. Recent advances in convolutional neural networks. *Pattern Recognition* [en línea], vol. 77, pp.

354-377. ISSN 00313203. DOI 10.1016/j.patcog.2017.10.013. Disponible en: <https://doi.org/10.1016/j.patcog.2017.10.013>.

GUZMAN, 2023. *Python is Easy - Learn to program with python in 24 hours* [en línea]. Primera. S.l.: Independently published. ISBN 979-8373597869. Disponible en: https://www.amazon.com.mx/Python-Easy-Learn-Program-Hours/dp/B0BS95NFP3/ref=sr_1_1?__mk_es_MX=ÁMÁŽŃ&crd=12TD0OHU8IPQY&dib=eyJ2ljojMSJ9.INMpfY0LGpfK5rcc1-Yxrw.sjUkXYbfF7ztS3ZL2Qm-QqPLgToh_StmM0_HOEgYQnM&dib_tag=se&keywords=979-83.

HE, Kaiming, et al. Deep residual learning for image recognition. En Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. p. 770-778.

HERNÁNDEZ SAMPIERI, R., FERNÁNDEZ, C. y BAPTISTA, M. del P., 2017. *Metodología de la Investigación Científica*. Sexta. Mexico: s.n. ISBN 9781456223960.

Infancia, Fondo de las Naciones Unidas para la. 2023. UNICEF.org. UNICEF.org Web Site. [En línea] 10 de Noviembre de 2023. [Citado el: 15 de Febrero de 2024.] <https://www.unicef.org/es/historias/neumonia-infantil-lo-que-debes-saber>.

KRIZHEVSKY, A., SUTSKEVER, I. y HINTON, G.E., 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, vol. 60, no. 6, pp. 84-90. ISSN 15577317. DOI 10.1145/3065386.

LE ROUX, D.M., MYER, L., NICOL, M.P. y ZAR, H.J., 2015. Incidence and severity of childhood pneumonia in the first year of life in a South African birth cohort: The Drakenstein Child Health Study. *The Lancet Global Health*[en línea], vol. 3, no. 2, pp. e95-e103. ISSN 2214109X. DOI 10.1016/S2214-109X(14)70360-2. Disponible en: [http://dx.doi.org/10.1016/S2214-109X\(14\)70360-2](http://dx.doi.org/10.1016/S2214-109X(14)70360-2).

LECUN, Y., BENGIO, Y. y HINTON, G., 2015. Deep learning. *Nature* [en línea], vol. 521, no. 7553, pp. 436-444. [Consulta: 5 mayo 2024]. DOI 10.1038/nature14539i. Disponible en: <https://hal.science/hal-04206682>.

LI, H.C., DENG, Z.Y. y CHIANG, H.H., 2020. Lightweight and resource-constrained learning network for face recognition with performance optimization. *Sensors (Switzerland)*, vol. 20, no. 21, pp. 1-20. ISSN 14248220. DOI 10.3390/s20216114.

LI, Zewen, et al. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*, 2021, vol. 33, no 12, p. 6999-7019.

- MARTINEZ TARAZONA, S.J., 2021. *Prototipo de herramienta de software con aprendizaje de máquinas para la diferenciación de neumonía bacteriana o viral con el uso de radiografías de tórax* [en línea]. S.l.: Universidad Autónoma de Bucaramanga. Disponible en: https://repository.unab.edu.co/bitstream/handle/20.500.12749/16509/2022_Tesis_Santiago_Andres_Martinez%281%29.pdf?sequence=1&isAllowed=y
- MAZUROWSKI, M.A., BUDA, M., SAHA, A. y BASHIR, M.R., 2019. Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *Journal of Magnetic Resonance Imaging*, vol. 49, no. 4, pp. 939-954. ISSN 15222586. DOI 10.1002/jmri.26534.
- METLAY, J.P., WATERER, G.W., LONG, A.C., ANZUETO, A., BROZEK, J., CROTHERS, K., COOLEY, L.A., DEAN, N.C., FINE, M.J., FLANDERS, S.A., GRIFFIN, M.R., METERSKY, M.L., MUSER, D.M., RESTREPO, M.I. y WHITNEY, C.G., 2019. Diagnosis and treatment of adults with community-acquired pneumonia. *American Journal of Respiratory and Critical Care Medicine*, vol. 200, no. 7, pp. E45-E67. ISSN 15354970. DOI 10.1164/rccm.201908-1581ST.
- MICHALSKI, Ryszard Stanislaw; CARBONELL, Jaime Guillermo; MITCHELL, Tom M. (ed.). *Machine learning: An artificial intelligence approach*. Springer Science & Business Media, 2013.
- MINISTERIO NACIONAL DE SALUD, 2020. Boletín Epidemiológico del Perú. *Lima: Boletín Epidemiológico del Ministerio de salud del Perú*. [en línea]. S.l.: s.n., pp. 32-59. Disponible en: <http://www.dge.gob.pe/portal/docs/vigilancia/boletines/2020/02.pdf>.
- MULLER, A.C. y GUIDO, S., 2016. *Introduction to Machine Learning with Python*. Primera. S.l.: O'Reilly Media Inc. ISBN 9781449369415.
- MURPHY, K.P., 2012. *Machine Learning A Probabilistic Perspective*. S.l.: MIT Press. ISBN 9780262018029.
- MURPHY, Kevin P. *Machine learning: a probabilistic perspective*. MIT press, 2012.
- ORGANIZACIÓN PANAMERICANA DE LA SALUD, 2017. *Salud en las Américas* [en línea]. Resumen:Pa. Washington D.C.: s.n. ISBN 9789275319666. Disponible en: <https://www.paho.org/salud-en-las-americas-2017/wp-content/uploads/2017/09/Print-Version-Spanish.pdf>.
- PALAZ, D., MAGIMAI-DOSS, M. y COLLOBERT, R., 2019. End-to-end acoustic modeling using convolutional neural networks for HMM-based automatic speech recognition. *Speech Communication* [en línea], vol. 108, no.

January, pp. 15-32. ISSN 01676393. DOI 10.1016/j.specom.2019.01.004.
Disponibile en: <https://doi.org/10.1016/j.specom.2019.01.004>.

PATTON, Michael Quinn. *Qualitative research & evaluation methods: Integrating theory and practice*. Sage publications, 2023.

PAUL D.. LEEDY; ORMROD, Jeanne Ellis; JOHNSON, Laura Ruth. *Practical research: Planning and design*. Pearson Education, 2014.

RAHMAN, Tawsifur, et al. Transfer learning with deep convolutional neural network (CNN) for pneumonia detection using chest X-ray. *Applied Sciences*, 2020, vol. 10, no 9, p. 3233.

RAJARAMAN, S., CANDEMIR, S., KIM, I., THOMA, G. y ANTANI, S., 2018. Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. *Applied Sciences (Switzerland)*, vol. 8, no. 10. ISSN 20763417. DOI 10.3390/app8101715.

ROSENTHAL, Robert; ROSNOW, Ralph L. *Essentials of behavioral research: Methods and data analysis*. 2008.

RUSSELL, S. y NORVIG, P., 2016. *Artificial Intelligence A Modern Approach* [en línea]. Tercera. S.I.: Pearson. [Consulta: 5 mayo 2024]. Disponible en: <https://doi.org/10.1609/aimag.v16i3.1153>.

Salud, O. M. (11 de Noviembre de 2021). World Health Organization. Obtenido de World Health Organization Web Site: <https://www.who.int/es/news-room/fact-sheets/detail/pneumonia>

SETHI, R., MEHROTRA, M. y SETHI, D., 2020. Deep Learning based Diagnosis Recommendation for COVID-19 using Chest X-Rays Images. *Proceedings of the 2nd International Conference on Inventive Research in Computing Applications, ICIRCA 2020*, pp. 1-4. DOI 10.1109/ICIRCA48905.2020.9183278.

SZEGEDY, C., VANHOUCHE, V., IOFFE, S. y SHLENS, J., 2016. Rethinking the Inception Architecture for Computer Vision. *Computer Vision Foundation*, pp. 9.

TAYLOR, L. y NITSCHKE, G., 2017. Improving Deep Learning using Generic Data Augmentation. [en línea], Disponible en: <http://arxiv.org/abs/1708.06020>.

UNICEF. 2020. UNICEF.org. UNICEF.org Web Site. [En línea] 29 de Enero de 2020. [Citado el: 15 de Enero de 2024.] <https://www.unicef.org/peru/notas-de-prensa/9-millones-ninos-podrian-morir-proxima-decada-mundo-contra-neumonia>.

VILLANUEVA ALARCÓN, R.A., 2021. *Sistema inteligente basado en redes neuronales para la identificación de cáncer de piel de tipo melanoma en imágenes de lesiones cutáneas* [en línea]. S.l.: Universidad Nacional Mayor de San Marcos. [Consulta: 5 mayo 2024]. Disponible en: <https://hdl.handle.net/20.500.12672/17574>.

WILSON, N., 2022. *Academy of Python: From Complete Beginner to Python Expert*. S.l.: Forzen Academy. ISBN 979-8370804847.

X. ANEXOS

ANEXO 01: Matriz de consistencia.

Tabla 25. Matriz de Consistencia

| TÍTULO: DISEÑO DE UN MODELO DE RED NEURONAL CONVOLUCIONAL PARA MEJORAR EL PROCESO DE DIAGNÓSTICO DE NEUMONÍA EN LOS PACIENTES DEL HOSPITAL GUSTAVO LANATTA LUJÁN DE BAGUA, 2024 | | | | |
|--|---|--|--|--|
| PROBLEMA GENERAL | OBJETIVO GENERAL | HIPÓTESIS GENERAL | VARIABLES | DISEÑO METODOLÓGICO |
| <p>Problema general:</p> <p>¿De qué manera el diseño de un modelo de red neuronal convolucional mejora el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?</p> | <p>Objetivo general:</p> <p>Diseñar un modelo de red neuronal convolucional para mejorar el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.</p> | <p>Hipótesis general:</p> <p>El diseño y aplicación de un modelo de red neuronal mejora el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.</p> | <p>Variable Dependiente</p> <p>Diagnóstico de la Neumonía</p> | <p>TIPO DE INVESTIGACIÓN La investigación será de tipo aplicada, explicativa y cuantitativa.</p> <p>DISEÑO DE LA INVESTIGACIÓN El diseño de la investigación será de tipo experimental que será útil para evaluar las causas y efectos entre el modelo predictivo y la mejora en el diagnóstico.</p> |
| <p>Problema específico:</p> <p>PE1. ¿De qué manera el diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?</p> | <p>Objetivo específico:</p> <p>OE1. Diseñar un modelo de red neuronal convolucional para mejorar la exactitud en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján de Bagua- Amazonas.</p> | <p>Hipótesis específica:</p> <p>HE1. El diseño de un modelo de red neuronal convolucional mejora la exactitud en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas</p> | <p>Variable Independiente</p> <p>Red Neuronal Convolucional</p> | <p>TÉCNICAS E INSTRUMENTOS PARA LA RECOLECCIÓN DE LA INFORMACIÓN Se utilizará la técnica de fichaje y análisis.</p> |

| | | | |
|--|---|---|--|
| <p>PE2. ¿De qué manera el diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?</p> <p>PE3. ¿De qué manera el diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?</p> <p>PE4. ¿De qué manera el diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas?</p> | <p>OE2. Diseñar un modelo de red neuronal convolucional para mejorar la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.</p> <p>OE3. Diseñar un modelo de red neuronal convolucional para mejorar sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.</p> <p>OE4. Diseñar un modelo de red neuronal convolucional para mejorar especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas.</p> | <p>HE2. El diseño de un modelo de red neuronal convolucional mejora la precisión en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas</p> <p>HE3. El diseño de un modelo de red neuronal convolucional mejora la sensibilidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas</p> <p>HE4. El diseño de un modelo de red neuronal convolucional mejora la especificidad en el proceso de diagnóstico de la neumonía en los pacientes del Hospital Gustavo Lanatta Luján De Bagua- Amazonas</p> | <p>POBLACIÓN Y MUESTRA</p> <p>Población.</p> <p>Estará constituida por 624 radiografías de pacientes entre 1 y 5 años pertenecientes a un Hospital de Bagua, Amazonas.</p> <p>Muestra.</p> <p>Para efecto de la muestra se ha seleccionado un conjunto de datos de 624 X-Ray imágenes (JPEG), correspondientes a pacientes pediátricos de 1 a 5 años.</p> |
|--|---|---|--|

ANEXO 02: Ficha de Registro: Exactitud Pre Test

Tabla 26. Ficha de Registro de Exactitud Pre Test

| Ficha Registro | | | | | | | |
|--------------------------------|---|-------------------------------|--|---------------------------|-----------------------|-----------------------|----------------------------------|
| Investigadores | Alva Ita Junior Ederson Asunción Ruiz Dantya Mirielli Huamán Llanos Alex Alfredo | | Tipo Prueba | Pre Test | | | |
| Empresa Investigada | Hospital Gustavo Lanatta Luján de Bagua | | | | | | |
| Motivo de Investigación | Índice de entrega a tiempo de Diagnóstico | | | | | | |
| Fecha Inicio | Ene-2022 | | Fecha Fin | Diciembre | | | |
| Variable | Indicador | Medida | Fórmula | | | | |
| Diagnóstico de la Neumonía | Exactitud del Diagnóstico de Neumonía | Porcentaje | $\% \text{ Índice de Exactitud} = (VP+VN / (VP+VN+FP+FN)) * 100$ | | | | |
| Ítem | Fecha | Número de diagnósticos | Verdadero Positivo | Verdadero Negativo | Falso Negativo | Falso Positivo | Exactitud del Diagnostico |
| 1 | ENERO | 25 | 9 | 13 | 2 | 1 | 88.00 |
| 2 | FEBRERO | 24 | 8 | 15 | 0 | 1 | 95.83 |
| 3 | MARZO | 35 | 13 | 20 | 1 | 1 | 94.29 |
| 4 | ABRIL | 36 | 13 | 21 | 1 | 1 | 94.44 |
| 5 | MAYO | 29 | 15 | 11 | 1 | 2 | 89.66 |
| 6 | JUNIO | 30 | 15 | 12 | 1 | 2 | 90.00 |
| 7 | JULIO | 30 | 13 | 12 | 2 | 3 | 83.33 |
| 8 | AGOSTO | 31 | 14 | 12 | 3 | 2 | 83.87 |
| 9 | SETIEMBRE | 27 | 15 | 10 | 1 | 1 | 92.59 |
| 10 | OCTUBRE | 32 | 17 | 13 | 1 | 1 | 93.75 |
| 11 | NOVIEMBRE | 29 | 16 | 12 | 0 | 1 | 96.55 |
| 12 | DICIEMBRE | 32 | 20 | 12 | 1 | 0 | 96.97 |

ANEXO 03: Ficha de Registro: Exactitud Post Test

Tabla 27. Ficha de Registro de Exactitud Post Test

| Ficha Registro | | | | | | | |
|----------------------------|--|------------------------|--|--------------------|----------------|----------------|---------------------------|
| Investigadores | Alva Ita Junior Ederson Asunción Ruiz Dantya Mirielli Huamán Llanos Alex Alfredo | | Tipo Prueba | Post Test | | | |
| Empresa Investigada | Hospital Gustavo Lanatta Luján de Bagua | | | | | | |
| Motivo de Investigación | Índice de entrega a tiempo de Diagnóstico | | | | | | |
| Fecha Inicio | Ene-2023 | | Fecha Fin | Diciembre | | | |
| Variable | Indicador | Medida | Fórmula | | | | |
| Diagnóstico de la Neumonía | Exactitud del Diagnóstico de Neumonía | Porcentaje | $\% \text{ Índice de Exactitud} = (VP+VN / (VP+VN+FP+FN)) * 100$ | | | | |
| Ítem | Fecha | Número de diagnósticos | Verdadero Positivo | Verdadero Negativo | Falso Negativo | Falso Positivo | Exactitud del Diagnóstico |
| 1 | ENERO | 48 | 31 | 16 | 0 | 1 | 97.92 |
| 2 | FEBRERO | 60 | 40 | 19 | 1 | 0 | 98.33 |
| 3 | MARZO | 52 | 30 | 22 | 0 | 0 | 100.00 |
| 4 | ABRIL | 48 | 26 | 22 | 0 | 0 | 100.00 |
| 5 | MAYO | 45 | 28 | 14 | 1 | 2 | 93.33 |
| 6 | JUNIO | 47 | 26 | 19 | 1 | 1 | 95.74 |
| 7 | JULIO | 56 | 33 | 18 | 3 | 2 | 91.07 |
| 8 | AGOSTO | 60 | 36 | 19 | 3 | 2 | 91.67 |
| 9 | SETIEMBRE | 38 | 23 | 14 | 1 | 0 | 97.37 |
| 10 | OCTUBRE | 64 | 36 | 24 | 3 | 1 | 93.75 |
| 11 | NOVIEMBRE | 49 | 31 | 17 | 0 | 1 | 97.96 |
| 12 | DICIEMBRE | 57 | 37 | 19 | 0 | 1 | 98.25 |

ANEXO 04: Ficha de Registro: Precisión Pre Test

Tabla 28. Ficha de Registro de Precisión Pre Test

| Ficha Registro | | | | | | | |
|----------------------------|--|------------------------|--|--------------------|----------------|----------------|---------------------------|
| Investigadores | Alva Ita Junior Ederson Asunción Ruiz Dantya Mirielli Huamán Llanos Alex Alfredo | | Tipo Prueba | Pre Test | | | |
| Empresa Investigada | Hospital Gustavo Lanatta Luján de Bagua | | | | | | |
| Motivo de Investigación | Índice de entrega a tiempo de Diagnóstico | | | | | | |
| Fecha Inicio | Ene-2022 | | Fecha Fin | Diciembre | | | |
| Variable | Indicador | Medida | Fórmula | | | | |
| Diagnóstico de la Neumonía | Precisión del Diagnóstico de Neumonía | Porcentaje | $\% \text{ Índice de Precisión} = ((VP) / (VP+FP)) \times 100$ | | | | |
| Ítem | Fecha | Número de diagnósticos | Verdadero Positivo | Verdadero Negativo | Falso Negativo | Falso Positivo | Precisión del Diagnóstico |
| 1 | ENERO | 25 | 9 | 13 | 2 | 1 | 90.00 |
| 2 | FEBRERO | 24 | 8 | 15 | 0 | 1 | 88.89 |
| 3 | MARZO | 35 | 13 | 20 | 1 | 1 | 92.86 |
| 4 | ABRIL | 36 | 13 | 21 | 1 | 1 | 92.86 |
| 5 | MAYO | 29 | 15 | 11 | 1 | 2 | 88.24 |
| 6 | JUNIO | 30 | 15 | 12 | 1 | 2 | 88.24 |
| 7 | JULIO | 30 | 13 | 12 | 2 | 3 | 81.25 |
| 8 | AGOSTO | 31 | 14 | 12 | 3 | 2 | 87.50 |
| 9 | SETIEMBRE | 27 | 15 | 10 | 1 | 1 | 93.75 |
| 10 | OCTUBRE | 32 | 17 | 13 | 1 | 1 | 94.44 |
| 11 | NOVIEMBRE | 29 | 16 | 12 | 0 | 1 | 94.12 |
| 12 | DICIEMBRE | 32 | 20 | 12 | 1 | 0 | 100.00 |

ANEXO 05: Ficha de Registro: Precisión Post Test

Tabla 29. Ficha de Registro de Precisión Post Test

| Ficha Registro | | | | | | | |
|--------------------------------|--|-------------------------------|--|---------------------------|-----------------------|-----------------------|----------------------------------|
| Investigadores | Alva Ita Junior Ederson Asunción Ruiz Dantya Mirielli Huamán Llanos Alex Alfredo | | Tipo Prueba | Post Test | | | |
| Empresa Investigada | Hospital Gustavo Lanatta Luján de Bagua | | | | | | |
| Motivo de Investigación | Índice de entrega a tiempo de Diagnóstico | | | | | | |
| Fecha Inicio | Ene-2023 | | Fecha Fin | Diciembre | | | |
| Variable | Indicador | Medida | Fórmula | | | | |
| Diagnóstico de la Neumonía | Precisión del Diagnóstico de Neumonía | Porcentaje | $\% \text{ Índice de Precisión} = ((VP)/(VP+FP)) \times 100$ | | | | |
| Ítem | Fecha | Número de diagnósticos | Verdadero Positivo | Verdadero Negativo | Falso Negativo | Falso Positivo | Precisión del Diagnóstico |
| 1 | ENERO | 48 | 31 | 16 | 0 | 1 | 96.88 |
| 2 | FEBRERO | 60 | 40 | 19 | 1 | 0 | 100.00 |
| 3 | MARZO | 52 | 30 | 22 | 0 | 0 | 100.00 |
| 4 | ABRIL | 48 | 26 | 22 | 0 | 0 | 100.00 |
| 5 | MAYO | 45 | 28 | 14 | 1 | 2 | 93.33 |
| 6 | JUNIO | 47 | 26 | 19 | 1 | 1 | 96.30 |
| 7 | JULIO | 56 | 33 | 18 | 3 | 2 | 94.29 |
| 8 | AGOSTO | 60 | 36 | 19 | 3 | 2 | 94.74 |
| 9 | SETIEMBRE | 38 | 23 | 14 | 1 | 0 | 100.00 |
| 10 | OCTUBRE | 64 | 36 | 24 | 3 | 1 | 97.30 |
| 11 | NOVIEMBRE | 49 | 31 | 17 | 0 | 1 | 96.88 |
| 12 | DICIEMBRE | 57 | 37 | 19 | 0 | 1 | 97.37 |

ANEXO 06: Ficha de Registro: Sensibilidad Pre Test

Tabla 30. Ficha de Registro de Sensibilidad Pre Test

| Ficha Registro | | | | | | | |
|--------------------------------|--|------------------------|---|--------------------|----------------|----------------|------------------------------|
| Investigadores | Alva Ita Junior Ederson Asunción Ruiz Dantya Mirielli Huamán Llanos Alex Alfredo | | Tipo Prueba | Pre Test | | | |
| Empresa Investigada | Hospital Gustavo Lanatta Luján de Bagua | | | | | | |
| Motivo de Investigación | Índice de entrega a tiempo de Diagnóstico | | | | | | |
| Fecha Inicio | Ene-2022 | | Fecha Fin | Diciembre | | | |
| Variable | Indicador | Medida | Fórmula | | | | |
| Diagnóstico de la Neumonía | Sensibilidad del Diagnóstico de Neumonía | Porcentaje | $\% \text{ Índice de Sensibilidad} = (VP / (VP + FN)) \times 100$ | | | | |
| Ítem | Fecha | Número de diagnósticos | Verdadero Positivo | Verdadero Negativo | Falso Negativo | Falso Positivo | Sensibilidad del Diagnostico |
| 1 | ENERO | 25 | 9 | 13 | 2 | 1 | 81.82 |
| 2 | FEBRERO | 24 | 8 | 15 | 0 | 1 | 100.00 |
| 3 | MARZO | 35 | 13 | 20 | 1 | 1 | 92.86 |
| 4 | ABRIL | 36 | 13 | 21 | 1 | 1 | 92.86 |
| 5 | MAYO | 29 | 15 | 11 | 1 | 2 | 93.75 |
| 6 | JUNIO | 30 | 15 | 12 | 1 | 2 | 93.75 |
| 7 | JULIO | 30 | 13 | 12 | 2 | 3 | 86.67 |
| 8 | AGOSTO | 31 | 14 | 12 | 3 | 2 | 82.35 |
| 9 | SETIEMBRE | 27 | 15 | 10 | 1 | 1 | 93.75 |
| 10 | OCTUBRE | 32 | 17 | 13 | 1 | 1 | 94.44 |
| 11 | NOVIEMBRE | 29 | 16 | 12 | 0 | 1 | 100.00 |
| 12 | DICIEMBRE | 32 | 20 | 12 | 1 | 0 | 95.24 |

ANEXO 07: Ficha de Registro: Sensibilidad Post Test

Tabla 31. Ficha de Registro de Sensibilidad Post Test

| Ficha Registro | | | | | | | | |
|--------------------------------|--|--|------------------------|---|--------------------|----------------|----------------|------------------------------|
| Investigadores | Alva Ita Junior Ederson Asunción Ruiz Dantya Mirielli Huamán Llanos Alex Alfredo | | Tipo Prueba | Post Test | | | | |
| Empresa Investigada | Hospital Gustavo Lanatta Luján de Bagua | | | | | | | |
| Motivo de Investigación | Índice de entrega a tiempo de Diagnóstico | | | | | | | |
| Fecha Inicio | Ene-2023 | | Fecha Fin | Diciembre | | | | |
| Variable | Indicador | | Medida | Fórmula | | | | |
| Diagnóstico de la Neumonía | Sensibilidad del Diagnóstico de Neumonía | | Porcentaje | $\% \text{ Índice de Sensibilidad} = (VP / (VP+FN)) \times 100$ | | | | |
| Ítem | Fecha | | Número de diagnósticos | Verdadero Positivo | Verdadero Negativo | Falso Negativo | Falso Positivo | Sensibilidad del Diagnostico |
| 1 | ENERO | | 48 | 31 | 16 | 0 | 1 | 100.00 |
| 2 | FEBRERO | | 60 | 40 | 19 | 1 | 0 | 97.56 |
| 3 | MARZO | | 52 | 30 | 22 | 0 | 0 | 100.00 |
| 4 | ABRIL | | 48 | 26 | 22 | 0 | 0 | 100.00 |
| 5 | MAYO | | 45 | 28 | 14 | 1 | 2 | 96.55 |
| 6 | JUNIO | | 47 | 26 | 19 | 1 | 1 | 96.30 |
| 7 | JULIO | | 56 | 33 | 18 | 3 | 2 | 91.67 |
| 8 | AGOSTO | | 60 | 36 | 19 | 3 | 2 | 92.31 |
| 9 | SETIEMBRE | | 38 | 23 | 14 | 1 | 0 | 95.83 |
| 10 | OCTUBRE | | 64 | 36 | 24 | 3 | 1 | 92.31 |
| 11 | NOVIEMBRE | | 49 | 31 | 17 | 0 | 1 | 100.00 |
| 12 | DICIEMBRE | | 57 | 37 | 19 | 0 | 1 | 100.00 |

ANEXO 08: Ficha de Registro: Especificidad Pre Test

Tabla 32. Ficha de Registro de Especificidad Pre Test

| Ficha Registro | | | | | | | |
|--------------------------------|--|-------------------------------|--|---------------------------|-----------------------|-----------------------|--------------------------------------|
| Investigadores | Alva Ita Junior Ederson Asunción Ruiz Dantya Mirielli Huamán Llanos Alex Alfredo | | Tipo Prueba | Pre Test | | | |
| Empresa Investigada | Hospital Gustavo Lanatta Luján de Bagua | | | | | | |
| Motivo de Investigación | Índice de entrega a tiempo de Diagnóstico | | | | | | |
| Fecha Inicio | Ene-2022 | | Fecha Fin | Diciembre | | | |
| Variable | Indicador | Medida | Fórmula | | | | |
| Diagnóstico de la Neumonía | Especificidad del Diagnóstico de Neumonía | Porcentaje | $\% \text{ Índice de Especificidad} = (VN / (VN+FP)) \times 100$ | | | | |
| Ítem | Fecha | Número de diagnósticos | Verdadero Positivo | Verdadero Negativo | Falso Negativo | Falso Positivo | Especificidad del Diagnostico |
| 1 | ENERO | 25 | 9 | 13 | 2 | 1 | 92.86 |
| 2 | FEBRERO | 24 | 8 | 15 | 0 | 1 | 93.75 |
| 3 | MARZO | 35 | 13 | 20 | 1 | 1 | 95.24 |
| 4 | ABRIL | 36 | 13 | 21 | 1 | 1 | 95.45 |
| 5 | MAYO | 29 | 15 | 11 | 1 | 2 | 84.62 |
| 6 | JUNIO | 30 | 15 | 12 | 1 | 2 | 85.71 |
| 7 | JULIO | 30 | 13 | 12 | 2 | 3 | 80.00 |
| 8 | AGOSTO | 31 | 14 | 12 | 3 | 2 | 85.71 |
| 9 | SETIEMBRE | 27 | 15 | 10 | 1 | 1 | 90.91 |
| 10 | OCTUBRE | 32 | 17 | 13 | 1 | 1 | 92.86 |
| 11 | NOVIEMBRE | 29 | 16 | 12 | 0 | 1 | 92.31 |
| 12 | DICIEMBRE | 32 | 18 | 12 | 1 | 1 | 92.31 |

ANEXO 09: Ficha de Registro: Especificidad Post Test

Tabla 33. Ficha de Registro de Especificidad Post Test

| Ficha Registro | | | | | | | |
|--------------------------------|--|-------------------------------|--|---------------------------|-----------------------|-----------------------|--------------------------------------|
| Investigadores | Alva Ita Junior Ederson Asunción Ruiz Dantya Mirielli Huamán Llanos Alex Alfredo | | Tipo Prueba | Post Test | | | |
| Empresa Investigada | Hospital Gustavo Lanatta Luján de Bagua | | | | | | |
| Motivo de Investigación | Índice de entrega a tiempo de Diagnóstico | | | | | | |
| Fecha Inicio | Ene-2023 | | Fecha Fin | Diciembre | | | |
| Variable | Indicador | Medida | Fórmula | | | | |
| Diagnóstico de la Neumonía | Especificidad del Diagnóstico de Neumonía | Porcentaje | $\% \text{ Índice de Especificidad} = (VN / (VN+FP)) \times 100$ | | | | |
| Ítem | Fecha | Número de diagnósticos | Verdadero Positivo | Verdadero Negativo | Falso Negativo | Falso Positivo | Especificidad del Diagnóstico |
| 1 | ENERO | 48 | 31 | 16 | 0 | 1 | 94.12 |
| 2 | FEBRERO | 60 | 40 | 19 | 1 | 0 | 100.00 |
| 3 | MARZO | 52 | 30 | 22 | 0 | 0 | 100.00 |
| 4 | ABRIL | 48 | 26 | 22 | 0 | 0 | 100.00 |
| 5 | MAYO | 45 | 28 | 14 | 1 | 2 | 87.50 |
| 6 | JUNIO | 47 | 26 | 19 | 1 | 1 | 95.00 |
| 7 | JULIO | 56 | 33 | 18 | 3 | 2 | 90.00 |
| 8 | AGOSTO | 60 | 36 | 19 | 3 | 2 | 90.48 |
| 9 | SETIEMBRE | 38 | 23 | 14 | 1 | 0 | 100.00 |
| 10 | OCTUBRE | 64 | 36 | 24 | 3 | 1 | 96.00 |
| 11 | NOVIEMBRE | 49 | 31 | 17 | 0 | 1 | 94.44 |
| 12 | DICIEMBRE | 57 | 37 | 19 | 0 | 1 | 95.00 |

ANEXO 10: Consentimiento Informado



GOBIERNO REGIONAL
AMAZONAS

GOBERNACION REGIONAL

DIRECCION EJECUTIVA
HOSPITAL APOYO BAGUA



Firmado digitalmente por SARAVIA
DIAZ YESPER FIDELIS
Cargo: Director Ejecutivo
Módulo: Sire el Sire del Documento
Fecha: 16.01.2024 10:28:21 -05:00

"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"

Bagua, 16 de Enero del 2024

CARTA N° 000002-2024-G.R.AMAZONAS/DE

Señor:

HUAMAN LLANOS ALEX ALFREDO
psj. seis 132 morro solar alto - jaen, CAJAMARCA-JAEN-JAEN

Presente.-

Asunto : RESPUESTA A SOLICITUD.

Referencia : SOLICITUD DE FECHA 15 DE ENERO DEL 2024.

De mi consideración

Tengo a bien dirigirme a Usted, para hacerle llegar mi cordial saludo y a la vez, visto el documento de la referencia se hace de conocimiento que el jefe del Servicio de Diagnóstico por imágenes AUTORIZO el estudio científico planteado para su Servicio.

Sin otro particular quedo de usted.

Documento firmado digitalmente

YESPER SARAVIA DIAZ
DIRECTOR EJECUTIVO
001101 - DIRECCION EJECUTIVA HOSPITAL APOYO BAGUA

YSD/DE
Dfc/sec.
CC.: cc.:

Esta es una copia auténtica imprimible de un documento electrónico archivado en el Gobierno Regional Amazonas, 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://sgd.regionamazonas.gob.pe/verificadoc/inicio.do> e ingresando la siguiente clave:

www.gob.pe/regionamazonas

Jr. Ortiz Arleta N° 12
Chachapoyas - Amazonas

ANEXO 11: Instrumentos Validados

FICHA DE VALIDEZ POR JUECES EXPERTOS (II)
ESCALA DE CALIFICACIÓN

Estimado (a):

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

| CRITERIOS | 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 del instrumento responden a la operacionalización de las variables. | X | | |
| 5. La secuencia presentada facilita el desarrollo del instrumento. | X | | |
| 6. Los ítems son claros y entendibles. | X | | |
| 7. El número de ítems es adecuado para su aplicación. | X | | |

Opinión de aplicabilidad: Aplicable Aplicable después de corregir

No aplicable

SUGERENCIAS:

Apellidos y nombres del juez validador, Dr/ Mg:
Dra. Beatriz García Díaz

DNI: 0.858.62.03..... Especialidad del validador: metodólogo temático
estadístico

29 de Abril del 2024

Beatriz Díaz

Firma y sello del Experto Informante.

**FICHA DE VALIDEZ POR JUECES EXPERTOS (II)
ESCALA DE CALIFICACIÓN**

Estimado (a):

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

| CRITERIOS | 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 del instrumento responden a la operacionalización de las variables. | X | | |
| 5. La secuencia presentada facilita el desarrollo del instrumento. | X | | |
| 6. Los ítems son claros y entendibles. | X | | |
| 7. El número de ítems es adecuado para su aplicación. | X | | |

Opinión de aplicabilidad: Aplicable Aplicable después de corregir

No aplicable

SUGERENCIAS:

.....
.....

Apellidos y nombres del juez validador. Dr/ Mg:

..... DR. I.M. IVO WILFREDO MARIANZ JIMÓNEZ

DNI: 08532214....., Especialidad del validador: metodólogo temático

estadístico

..... 02 de MAYO del 2022



Firma y sello del Experto Informante.

**FICHA DE VALIDEZ POR JUECES EXPERTOS (II)
ESCALA DE CALIFICACIÓN**

Estimado (a):

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

| CRITERIOS | SI | NO | OBSERVACIÓN |
|--|----|----|-------------|
| 1. El instrumento recoge información que permite dar respuesta al problema de investigación. | / | | |
| 2. El instrumento propuesto responde a los objetivos del estudio. | / | | |
| 3. La estructura del instrumento es adecuada. | / | | |
| 4. Los ítems del instrumento responden a la operacionalización de las variables. | / | | |
| 5. La secuencia presentada facilita el desarrollo del instrumento. | / | | |
| 6. Los ítems son claros y entendibles. | / | | |
| 7. El número de ítems es adecuado para su aplicación. | / | | |

Opinión de aplicabilidad: Aplicable Aplicable después de corregir

No aplicable

SUGERENCIAS:

.....
.....

Apellidos y nombres del juez validador. Dr/ Mg:
Yasni Kalia Ortega Rojas

DNI: 06798112 Especialidad del validador: metodólogo | temático

estadístico

03 de Mayo del 2024



Firma y sello del Experto Informante.

FICHA DE VALIDEZ POR JUECES EXPERTOS (II)
ESCALA DE CALIFICACIÓN

Estimado (a):

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

| CRITERIOS | 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 del instrumento responden a la operacionalización de las variables. | X | | |
| 5. La secuencia presentada facilita el desarrollo del instrumento. | X | | |
| 6. Los ítems son claros y entendibles. | X | | |
| 7. El número de ítems es adecuado para su aplicación. | X | | |

Opinión de aplicabilidad: Aplicable Aplicable después de corregir

No aplicable

SUGERENCIAS:

.....
.....

Apellidos y nombres del juez validador. Dr/ Mg/Tm:

..... *Guevara Albuja Ivan*

DNI:..... *16698821*, Especialidad del validador: metodólogo temático

estadístico

..... *25* de *enero* del 202*4*

Firma y sello del Experto Informante.

FICHA DE VALIDEZ POR JUECES EXPERTOS (II)
ESCALA DE CALIFICACIÓN

Estimado (a):

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

| CRITERIOS | SI | NO | OBSERVACIÓN |
|--|----|----|-------------|
| 1. El instrumento recoge información que permite dar respuesta al problema de investigación. | / | | |
| 2. El instrumento propuesto responde a los objetivos del estudio. | / | | |
| 3. La estructura del instrumento es adecuada. | / | | |
| 4. Los ítems del instrumento responden a la operacionalización de las variables. | / | | |
| 5. La secuencia presentada facilita el desarrollo del instrumento. | / | | |
| 6. Los ítems son claros y entendibles. | / | | |
| 7. El número de ítems es adecuado para su aplicación. | / | | |

Opinión de aplicabilidad: Aplicable / No aplicable Aplicable después de corregir

No aplicable

SUGERENCIAS:

.....
.....

Apellidos y nombres del juez validador. Dr/ Mg:

..... Villanueva Tarán Alvaro

DNI: 46619140 Especialidad del validador: metodólogo / temático

estadístico

..... 6 de Febrero del 2024


 Dr. Alvaro Villanueva Tarán
 MÉDICO CIRUJANO
 N.º 084480

Firma y sello del Experto Informante.

ANEXO 12: Base de Datos SPSS

Active Editar Ver Datos Transformar Análisis Gráficos Utilidades Ampliaciones Ventanas Ayuda

Mostrar: 16 de 16 variables

| | NRO | DIAGPRE_EXAC | DIAGPO_ST_EXAC | DF_EXAC_POST_PRE | DIAGPRE_PRECI | DIAGPO_ST_PRE_C | DF_PREQ_POST_PRE | DIAGPRE_SERVI | DIAGPO_ST_SERV | DF_SERVI_POST_PRE | DIAGPRE_ESPEC | DIAGPO_ST_ESP | DF_ESPE_POST | |
|----|-----|--------------|----------------|------------------|---------------|-----------------|------------------|---------------|----------------|-------------------|---------------|---------------|--------------|--------|
| 1 | 1 | 90.00 | 97.50 | | 5.50 | 90.00 | 96.60 | | 5.90 | 91.00 | 100.00 | 10.10 | 92.90 | 94.10 |
| 2 | 2 | 90.50 | 98.00 | | 2.50 | 80.00 | 100.00 | | 11.10 | 100.00 | 97.00 | 2.40 | 93.70 | 100.00 |
| 3 | 3 | 94.20 | 100.00 | | 6.70 | 92.90 | 100.00 | | 7.10 | 92.90 | 100.00 | 7.10 | 95.20 | 100.00 |
| 4 | 4 | 94.40 | 100.00 | | 5.50 | 92.90 | 100.00 | | 7.10 | 92.90 | 100.00 | 7.10 | 95.40 | 100.00 |
| 5 | 5 | 95.00 | 93.00 | | 3.60 | 85.20 | 93.30 | | 5.90 | 93.70 | 96.50 | 2.90 | 94.80 | 97.90 |
| 6 | 6 | 96.00 | 95.70 | | 6.70 | 85.20 | 96.30 | | 8.90 | 93.70 | 96.30 | 2.90 | 95.70 | 96.00 |
| 7 | 7 | 93.20 | 91.90 | | 7.70 | 91.20 | 94.20 | | 12.60 | 96.60 | 91.00 | 5.00 | 99.00 | 90.00 |
| 8 | 8 | 93.00 | 91.60 | | 7.80 | 87.00 | 94.70 | | 7.20 | 82.30 | 92.30 | 5.90 | 95.70 | 90.40 |
| 9 | 9 | 92.50 | 97.30 | | 4.70 | 93.70 | 100.00 | | 6.20 | 93.70 | 95.80 | 2.00 | 99.90 | 100.00 |
| 10 | 10 | 93.70 | 93.70 | | 6.0 | 94.40 | 97.30 | | 2.80 | 94.40 | 92.70 | 2.10 | 92.90 | 96.00 |
| 11 | 11 | 96.50 | 97.90 | | 1.40 | 94.10 | 96.60 | | 2.70 | 100.00 | 100.00 | 0.0 | 92.30 | 94.40 |
| 12 | 12 | 96.90 | 98.20 | | 1.20 | 100.00 | 97.30 | | 2.90 | 98.20 | 100.00 | 4.70 | 92.30 | 95.00 |
| 13 | | | | | | | | | | | | | | |
| 14 | | | | | | | | | | | | | | |
| 15 | | | | | | | | | | | | | | |
| 16 | | | | | | | | | | | | | | |
| 17 | | | | | | | | | | | | | | |
| 18 | | | | | | | | | | | | | | |
| 19 | | | | | | | | | | | | | | |
| 20 | | | | | | | | | | | | | | |
| 21 | | | | | | | | | | | | | | |
| 22 | | | | | | | | | | | | | | |
| 23 | | | | | | | | | | | | | | |
| 24 | | | | | | | | | | | | | | |
| 25 | | | | | | | | | | | | | | |
| 26 | | | | | | | | | | | | | | |
| 27 | | | | | | | | | | | | | | |
| 28 | | | | | | | | | | | | | | |
| 29 | | | | | | | | | | | | | | |
| 30 | | | | | | | | | | | | | | |

Ver datos Ver de variables

IBM SPSS Statistics Processor está lista. Estado:ACTIVADO

Active Editar Ver Datos Transformar Análisis Gráficos Utilidades Ampliaciones Ventanas Ayuda

| Número | Nombre | Tipo | Anchos | Decimales | Etiquetas | Valores | Perfiles | Columnas | Alineación | Modelo | Rot |
|--------|----------------------|--------|--------|-----------|-----------------------------------|-------------|----------|----------|------------|--------|--------|
| 1 | NRO | Número | 8 | 0 | | | | | Centrado | Número | Entero |
| 2 | DIAGPRE_EXAC | Número | 8 | 2 | Exactitud de diagnóstico Pre | | | | Derecha | Entero | Entero |
| 3 | DIAGPO_EXAC | Número | 8 | 2 | Exactitud de diagnóstico Post | | | | Derecha | Entero | Entero |
| 4 | DF_EXAC_POST_PRE | Número | 8 | 2 | | | | | Derecha | Entero | Entero |
| 5 | DIAGPRE_PRECI | Número | 8 | 2 | Precisión de diagnóstico Pre | | | | Derecha | Entero | Entero |
| 6 | DIAGPO_PRECI | Número | 8 | 2 | Precisión de diagnóstico Post | | | | Derecha | Entero | Entero |
| 7 | DF_PREQ_POST_PRE | Número | 8 | 2 | | | | | Derecha | Entero | Entero |
| 8 | DIAGPRE_SERVI | Número | 8 | 2 | Sensibilidad de diagnóstico Pre | | | | Derecha | Entero | Entero |
| 9 | DIAGPO_SERVI | Número | 8 | 2 | Sensibilidad de diagnóstico Post | | | | Derecha | Entero | Entero |
| 10 | DF_SERVI_POST_PRE | Número | 8 | 2 | | | | | Derecha | Entero | Entero |
| 11 | DIAGPRE_ESPEC | Número | 8 | 2 | Especificidad de diagnóstico Pre | | | | Derecha | Entero | Entero |
| 12 | DIAGPO_ESPEC | Número | 8 | 2 | Especificidad de diagnóstico Post | | | | Derecha | Entero | Entero |
| 13 | DF_ESPE_POST_PRE | Número | 8 | 2 | | | | | Derecha | Entero | Entero |
| 14 | DIMENSIONAL_PRE | Número | 8 | 2 | Diagnóstico de Neumonia Pre | 00 01 02 03 | | | Derecha | Entero | Entero |
| 15 | DIMENSIONAL_POST | Número | 8 | 2 | Diagnóstico de Neumonia Post | | | | Derecha | Entero | Entero |
| 16 | DIAPREMONIA_POST_PRE | Número | 8 | 2 | | | | | Derecha | Entero | Entero |
| 17 | | | | | | | | | | | |
| 18 | | | | | | | | | | | |
| 19 | | | | | | | | | | | |
| 20 | | | | | | | | | | | |
| 21 | | | | | | | | | | | |
| 22 | | | | | | | | | | | |
| 23 | | | | | | | | | | | |
| 24 | | | | | | | | | | | |
| 25 | | | | | | | | | | | |
| 26 | | | | | | | | | | | |
| 27 | | | | | | | | | | | |
| 28 | | | | | | | | | | | |
| 29 | | | | | | | | | | | |
| 30 | | | | | | | | | | | |

Ver datos Ver de variables

IBM SPSS Statistics Processor está lista. Estado:ACTIVADO

ANEXO 13: Modelo de Red Neuronal Convolutacional

ModeloCNN3.ipynb ☆

Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda

+ Código + Texto

17% [1] Collecting texttable
 Downloading texttable-1.7.0-py2.py3-none-any.whl (10 kB)
 Installing collected packages: texttable
 Successfully installed texttable-1.7.0

```

1 import os
2 import matplotlib.pyplot as plt
3 %matplotlib inline
4 from texttable import Texttable
5 from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
6 from tensorflow.keras.layers import Conv2D, MaxPooling2D, SeparableConv2D, \
7     Dense, Flatten, BatchNormalization, Dropout
8 from tensorflow.keras.models import Sequential, load_model
9 from tensorflow.keras.preprocessing.image import ImageDataGenerator
  
```

27% [3] 1 # Importando Google drive para lectura de los datos
 2 from google.colab import drive
 3 drive.mount('/content/drive')

Mounted at /content/drive

```

1 MODEL_LOC = '/content/drive/MyDrive/Models/pneumonia_detection_cnn_model.h5'
2 DATA_DIR = '/content/drive/MyDrive/DeepL/'
3 TRAINING_DATA_DIR = DATA_DIR + '/train/'
4 TEST_DATA_DIR = DATA_DIR + '/test/'
5 VAL_DATA_DIR = DATA_DIR + '/val/'
6 DETECTION_CLASSES = ('NORMAL', 'PNEUMONIA')
7 BATCH_SIZE = 32
8 EPOCHS = 100
  
```

ModeloCNN3.ipynb

Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda

+ Código + Texto

```

1 # Creando el número de imágenes para cada conjunto de datos (dataset) y las dos clases asociadas (normal y neumonía)
2 def count_images(directory_name, detection_class):
3     return len(os.listdir(directory_name + detection_class))
4
5
6 t = texttable()
7
8 t.add_rows([Dataset, Type, Normal, Pneumonia])
9
10 t.add_rows([Training, count_images(TRAINING_DATA_DIR, 'NORMAL'), count_images(TRAINING_DATA_DIR, 'PNEUMONIA')])
11
12 t.add_rows([Validation, count_images(VAL_DATA_DIR, 'NORMAL'), count_images(VAL_DATA_DIR, 'PNEUMONIA')])
13
14 t.print_text()
  
```

| Dataset | Type | Normal | Pneumonia |
|------------|------|--------|-----------|
| Training | | 2000 | 5000 |
| test | | 200 | 500 |
| validation | | 0 | 0 |

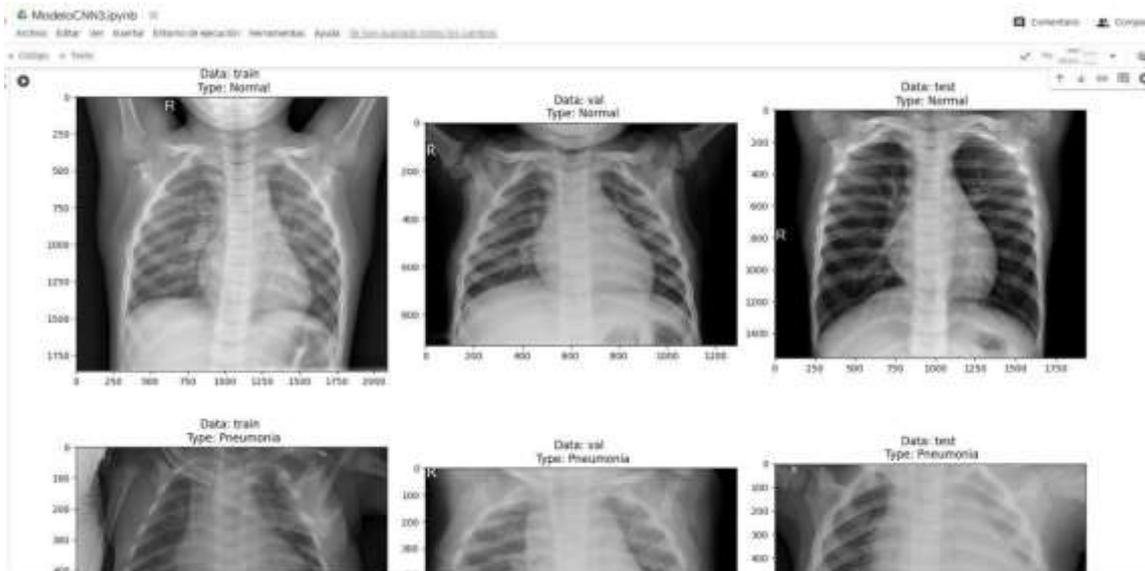
```

1 # Muestra las imágenes por clase, en cada tipo de conjunto de datos (dataset)
2 fig, ax = plt.subplots(3, 1, figsize=(10, 30))
3 ax = ax.ravel()
4 plt.tight_layout()
5
6 for i, subset in enumerate(['train', 'val', 'test']):
7     image_path = DATA_DIR + subset
8     ax[i].imshow(plt.imread(image_path + '/normal' + os.listdir(image_path + '/normal')[0].split('.')[0] + '.png'))
9     ax[i].set_title('Data: {} ({} Type: Normal) (format:subdir), resolution = 128'
10     ax[i+1].imshow(plt.imread(image_path + '/PNEUMONIA' + os.listdir(image_path + '/PNEUMONIA')[0].split('.')[0] + '.png'))
11     ax[i+1].set_title('Data: {} ({} Type: Pneumonia) (format:subdir), resolution = 128'
  
```

Data: train
Type: Normal

Data: val
Type: Normal

Data: test
Type: Normal



ModeloCNN3.ipynb ☆

Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda [Se han guardado todos los cambios](#)

+ Código + Texto

```

1 # Generador de datos en el dataset de entrenamiento, aumento de datos aplicado
2 train_datagen = ImageDataGenerator(rescale=1.0 / 255.0,
3                                   shear_range=0.2,
4                                   vertical_flip=True,
5                                   rotation_range=10,
6                                   zoom_range=0.3)
7
8 # Preprocesamiento del conjunto de datos de entrenamiento
9 training_dataset = train_datagen.flow_from_directory(TRAINING_DATA_DIR,
10                                                    classes=DETECTION_CLASSES,
11                                                    shuffle=True,
12                                                    batch_size=BATCH_SIZE,
13                                                    target_size=(224, 224))
14
15 # Generador de datos en el dataset de prueba, no se aplica el aumento de datos
16 # Utilizado como dataset de validación ya que el directorio val contiene 16 imagenes
17 test_datagen = ImageDataGenerator(rescale=1.0 / 255.0)
18
19 # Preprocesamiento del dataset de prueba (usado como validacion)
20 test_dataset = test_datagen.flow_from_directory(TEST_DATA_DIR,
21                                               classes=DETECTION_CLASSES,
22                                               shuffle=False,
23                                               batch_size=BATCH_SIZE,
24                                               target_size=(224, 224))
25
26 # Generador de datos en el dataset de validación, aumento de datos no aplciado
27 val_datagen = ImageDataGenerator(rescale=1.0 / 255.0)
28
29 # Preprocesamiento del dataset de validación
30 val_dataset = test_datagen.flow_from_directory(VAL_DATA_DIR,
31                                              classes=DETECTION_CLASSES,
32                                              shuffle=False,
33                                              batch_size=BATCH_SIZE,
34                                              target_size=(224, 224))

```

Found 5236 images belonging to 2 classes.
Found 624 images belonging to 2 classes.
Found 16 images belonging to 2 classes.



```
+ Código + Texto

[10] 1 #Imprimiendo los indices asignados para el control de juicio.
      2 print(f'class indices: {training_dataset.class_indices}')

      class indices: {'NORMAL': 0, 'PNEUMONIA': 1}

1 #Contrucción del Modelo CNN
2
3 cnn_model = Sequential()
4
5 # Primer Bloque de CNN
6 cnn_model.add(Conv2D(16, (3, 3), padding='same', input_shape=(224, 224, 3), activation='relu'))
7 cnn_model.add(Conv2D(16, (3, 3), padding='same', activation='relu'))
8 cnn_model.add(MaxPooling2D((2, 2)))
9
10 # Segundo Bloque de CNN
11 cnn_model.add(SeparableConv2D(32, (3, 3), padding='same', activation='relu'))
12 cnn_model.add(SeparableConv2D(32, (3, 3), padding='same', activation='relu'))
13 cnn_model.add(BatchNormalization())
14 cnn_model.add(MaxPooling2D((2, 2)))
15
16 # Tercer Bloque de CNN
17 cnn_model.add(SeparableConv2D(64, (3, 3), padding='same', activation='relu'))
18 cnn_model.add(SeparableConv2D(64, (3, 3), padding='same', activation='relu'))
19 cnn_model.add(BatchNormalization())
20 cnn_model.add(MaxPooling2D((2, 2)))
21
22 # Cuarto Bloque de CNN
23 cnn_model.add(SeparableConv2D(128, (3, 3), padding='same', activation='relu'))
24 cnn_model.add(SeparableConv2D(128, (3, 3), padding='same', activation='relu'))
25 cnn_model.add(BatchNormalization())
26 cnn_model.add(MaxPooling2D((2, 2)))
27 cnn_model.add(Dropout(rate=0.2))
28
29 # Quinto Bloque de CNN
30 cnn_model.add(SeparableConv2D(256, (3, 3), padding='same', activation='relu'))
31 cnn_model.add(SeparableConv2D(256, (3, 3), padding='same', activation='relu'))
32 cnn_model.add(BatchNormalization())
33 cnn_model.add(MaxPooling2D((2, 2)))
34 cnn_model.add(Dropout(rate=0.2))
35
```



+ Código + Texto



```
36 # Capa aplanada y completamente conectada
37 cnn_model.add(Flatten())
38 cnn_model.add(Dense(units=512, activation='relu'))
39 cnn_model.add(Dropout(rate=0.7))
40 cnn_model.add(Dense(units=128, activation='relu'))
41 cnn_model.add(Dropout(rate=0.5))
42 cnn_model.add(Dense(units=64, activation='relu'))
43 cnn_model.add(Dropout(rate=0.3))
44
45 # Clasificador Softmax
46 cnn_model.add(Dense(units=2, activation='softmax'))
47
48 # Mostrar modelo
49 cnn_model.summary()
50
51 # Compilar modelo
52 cnn_model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
```



Model: "sequential"

| Layer (type) | Output Shape | Param # |
|---|----------------------|---------|
| conv2d (Conv2D) | (None, 224, 224, 16) | 448 |
| conv2d_1 (Conv2D) | (None, 224, 224, 16) | 2320 |
| max_pooling2d (MaxPooling2D) | (None, 112, 112, 16) | 0 |
| separable_conv2d (Separable Conv2D) | (None, 112, 112, 32) | 688 |
| separable_conv2d_1 (Separable Conv2D) | (None, 112, 112, 32) | 1344 |
| batch_normalization (Batch Normalization) | (None, 112, 112, 32) | 128 |
| max_pooling2d_1 (MaxPooling2D) | (None, 56, 56, 32) | 0 |
| separable_conv2d_2 (Separable Conv2D) | (None, 56, 56, 64) | 2400 |





+ Código + Texto



| | | | |
|--------|---|---------------------|---------|
| ✓ [11] | batch_normalization_3 (Batch Normalization) | (None, 14, 14, 256) | 1024 |
| | max_pooling2d_4 (MaxPooling2D) | (None, 7, 7, 256) | 0 |
| | dropout_1 (Dropout) | (None, 7, 7, 256) | 0 |
| | flatten (Flatten) | (None, 12544) | 0 |
| | dense (Dense) | (None, 512) | 6423040 |
| | dropout_2 (Dropout) | (None, 512) | 0 |
| | dense_1 (Dense) | (None, 128) | 65664 |
| | dropout_3 (Dropout) | (None, 128) | 0 |
| | dense_2 (Dense) | (None, 64) | 8256 |
| | dropout_4 (Dropout) | (None, 64) | 0 |
| | dense_3 (Dense) | (None, 2) | 130 |

```

=====
Total params: 6,639,778
Trainable params: 6,638,818
Non-trainable params: 960
=====

```



```

1 #Entrenamiento del Modelo CNN
2 # Presentamos devoluciones de llamada (callbacks)
3 early_stop = EarlyStopping(monitor='val_loss',
4                             patience=10,
5                             mode='min',
6                             min_delta=0.001,
7                             restore_best_weights=True)
8
9 checkpoint = ModelCheckpoint(filepath=MODEL_LOC, # Guardar el 'Mejor' modelo
10                             monitor='val_loss',
11                             save_best_only=True,
12                             mode='min')

```

```

history = cnn_model.fit(training_dataset,
                        steps_per_epoch=len(training_dataset),
                        validation_data=test_dataset,
                        validation_steps=len(test_dataset),
                        epochs=EPOCHS,
                        callbacks=[early_stop, checkpoint],
                        verbose=1)

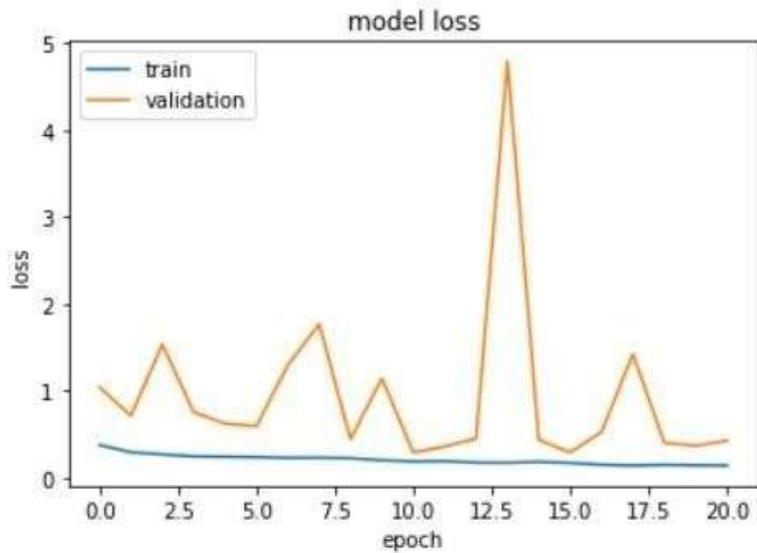
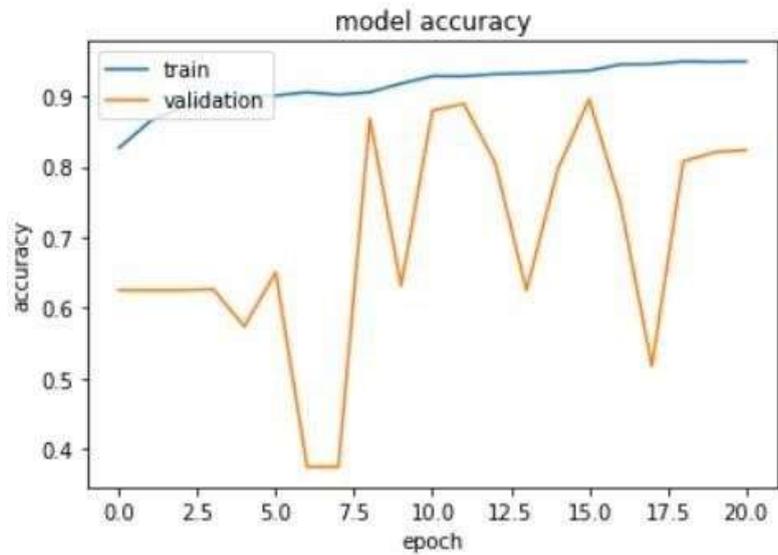
```

```

Epoch 1/100
163/163 [=====] - 249s 2s/step - loss: 0.4760 - accuracy: 0.7838 - val_loss:
1.0436 - val_accuracy: 0.6250
Epoch 2/100
163/163 [=====] - 255s 2s/step - loss: 0.3065 - accuracy: 0.8530 - val_loss:
0.7193 - val_accuracy: 0.6250
Epoch 3/100
163/163 [=====] - 242s 1s/step - loss: 0.2699 - accuracy: 0.8820 - val_loss:
1.5382 - val_accuracy: 0.6250
Epoch 4/100
163/163 [=====] - 244s 1s/step - loss: 0.2396 - accuracy: 0.9003 - val_loss:
0.7575 - val_accuracy: 0.6266
Epoch 5/100
163/163 [=====] - 239s 1s/step - loss: 0.2527 - accuracy: 0.8961 - val_loss:
0.6258 - val_accuracy: 0.5737
Epoch 6/100
163/163 [=====] - 218s 1s/step - loss: 0.2468 - accuracy: 0.9022 - val_loss:
0.5967 - val_accuracy: 0.5506
Epoch 7/100
163/163 [=====] - 215s 1s/step - loss: 0.2317 - accuracy: 0.9058 - val_loss:
1.2968 - val_accuracy: 0.3750
Epoch 8/100

```

```
1 #Historial de entrenamiento - Plot Training History
2 # "Precision" - "Accuracy"
3 plt.plot(history.history['accuracy'])
4 plt.plot(history.history['val_accuracy'])
5 plt.title('model accuracy')
6 plt.ylabel('accuracy')
7 plt.xlabel('epoch')
8 plt.legend(['train', 'validation'], loc='upper left')
9 plt.show()
10
11 # "Perdida" - "Loss"
12 plt.plot(history.history['loss'])
13 plt.plot(history.history['val_loss'])
14 plt.title('model loss')
15 plt.ylabel('loss')
16 plt.xlabel('epoch')
17 plt.legend(['train', 'validation'], loc='upper left')
18 plt.show()
```



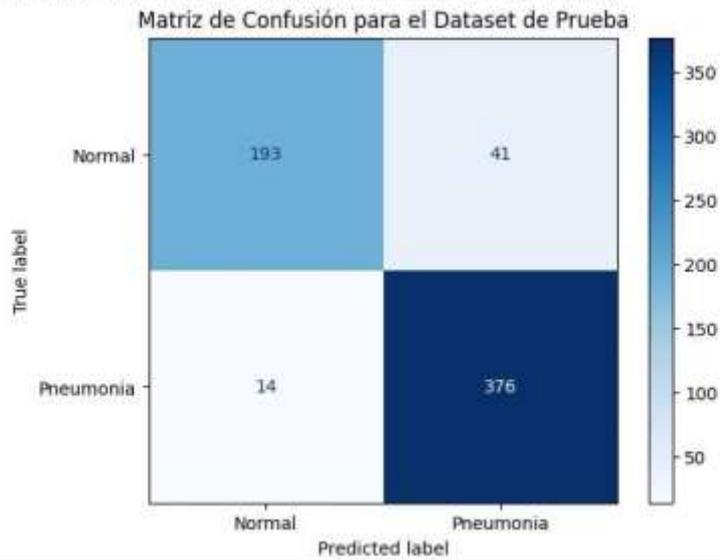
```
+ Código + Texto  
[ ] 1 # Evaluacion de Modelo en el conjunto de datos de prueba  
[18] 1 # Cargar el modelo CNN entrenado  
      2 cnn_model = load_model(MODEL_LOC)  
      3  
      4 # Almacenamiento de clases verdaderas del dataset de prueba  
      5 y_true = test_dataset.classes  
      6  
      7 # Predecir las clases verdaderas del dataset de prueba  
      8 y_pred = cnn_model.predict(test_dataset, steps=len(test_dataset), verbose=1)  
      9  
      10 # Almacenar la probabilidad predicha Storing the predicted probability  
      11 y_pred_prob = y_pred[:, 1]  
      12  
      13 # Almacenar las clases binarias para las predicciones  
      14 y_pred_binary = y_pred_prob > 0.5  
      15  
      16  
      17  
      18  
      19  
      20/20 [=====] - 183s 9s/step  
[20] 1 from sklearn.metrics import confusion_matrix, ConfusionMatrixDisplay, \  
      2 classification_report, roc_auc_score, roc_curve  
      3  
      4  
      5  
      6  
      7  
      8  
      9  
      10  
      11 # Matriz de Confusión para el Dataset de Prueba  
      12 print('\nMatriz de Confusión para el Dataset de Prueba\n -----')  
      13 cm = confusion_matrix(y_true, y_pred_binary)  
      14 print(cm)
```

```
+ Código + Texto  
[21] 1 # Matriz de Confusión para el Dataset de Prueba  
2 print('\nMatriz de Confusión para el Dataset de Prueba\n-----')  
3 cm = confusion_matrix(y_true, y_pred_binary)  
4 print(cm)
```

```
Matriz de Confusión para el Dataset de Prueba  
-----  
[[193  41]  
 [ 14 376]]
```

```
1 cm_display = ConfusionMatrixDisplay(cm, display_labels=['Normal', 'Pneumonia'])  
2 cm_display.plot(cmap = 'Blues')  
3 plt.title('Matriz de Confusión para el Dataset de Prueba')
```

```
Text(0.5, 1.0, 'Matriz de Confusión para el Dataset de Prueba')
```



```

+ Código + Texto
1 # Informe de clasificación
2 # accuracy: (tp + tn) / (p + n)
3 # precision tp / (tp + fp)
4 # recall: tp / (tp + fn)
5 # f1_score: 2 tp / (2 tp + fp + fn)
6 print('\nInforme de clasificación\n -----')
7 print(classification_report(y_true, y_pred_binary))

Informe de clasificación
-----
              precision    recall  f1-score   support

     0       0.93      0.82      0.88        234
     1       0.90      0.96      0.93        390

 accuracy          0.91          0.91          0.91          624
 macro avg         0.92          0.89          0.90          624
 weighted avg      0.91          0.91          0.91          624

[24] 1 # ROC AUC
2 auc = roc_auc_score(y_true, y_pred_prob)
3 print(f'ROC AUC (Test Dataset) {auc:.2}')

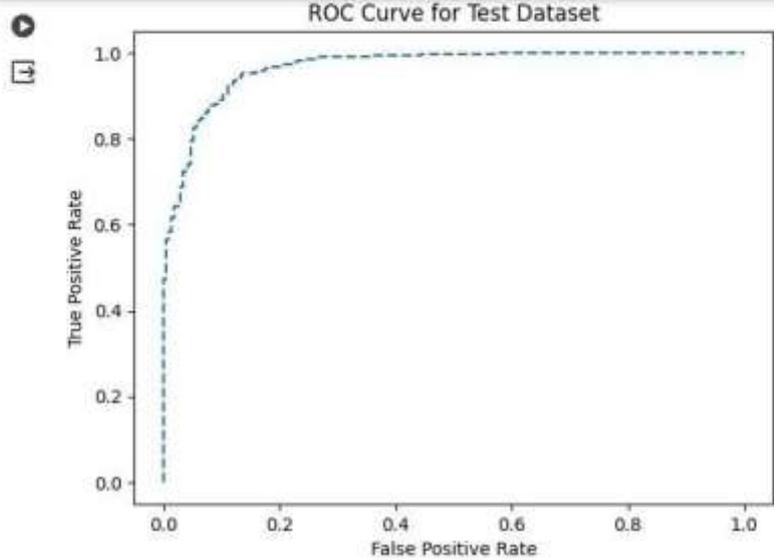
ROC AUC (Test Dataset) 0.97

[25] 1 # Calcular la curva roc
2 fpr, tpr, _ = roc_curve(y_true, y_pred_prob)
3
4 # Trazar la curva de roc para el modelo
5 plt.figure()
6 plt.plot(fpr, tpr, linestyle='--')
7 plt.xlabel('False Positive Rate')
8 plt.ylabel('True Positive Rate')
9 plt.title('ROC Curve for Test Dataset')
10 plt.show()
  
```

ROC Curve for Test Dataset

+ Código + Texto

- ☰
- 🔍
- (X)
- 🔑
- 📄
- ↩
- ⏪
- ⏩
- 📄
- 🔍



```
[ ] 1 # Evaluación de Modelo en el conjunto de datos de validación
```

```
[26] 1 # Almacenar las clases verdaderas del dataset de prueba  
2 y_true_val = val_dataset.classes  
3  
4 # Predecir las clases del dataset de prueba  
5 y_pred_val = cnn_model.predict(val_dataset, steps=len(val_dataset), verbose=1)  
6  
7 # Almacenar la probabilidad predicha  
8 y_pred_val_prob = y_pred_val[:, 1]  
9  
10 # Almacenando las clases binarias para las predicciones  
11 y_pred_val_binary = y_pred_val_prob > 0.5
```

1/1 [-----] - 1s 721ms/step



+ Código + Texto

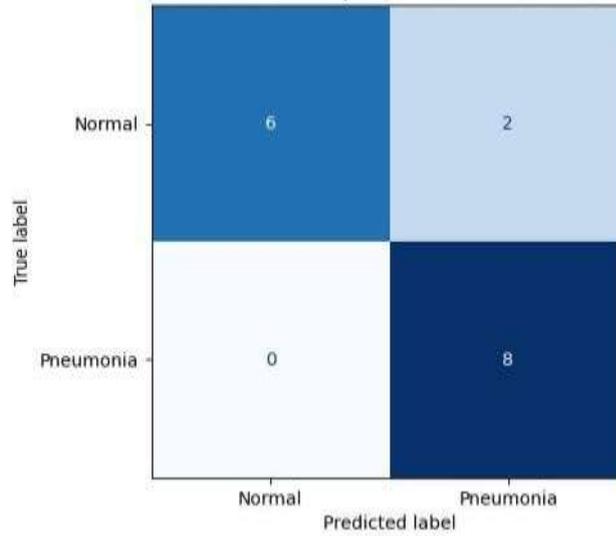
```
[27] 1 # Matrix de confusion para el dataset de validacion
      2 print('\nMatrix de confusion para el dataset de validacion\n -----')
      3 cm_val = confusion_matrix(y_true_val, y_pred_val_binary)
      4 print(cm_val)
      5
      6 cm_display_val = ConfusionMatrixDisplay(cm_val, display_labels=['Normal', 'Pneumonia'])
      7 cm_display_val.plot(cmap='Blues', colorbar=False)
      8 plt.title('Matrix de confusion para el dataset de validacion')
```

Matrix de confusion para el dataset de validacion

```
[[6 2]
 [0 8]]
```

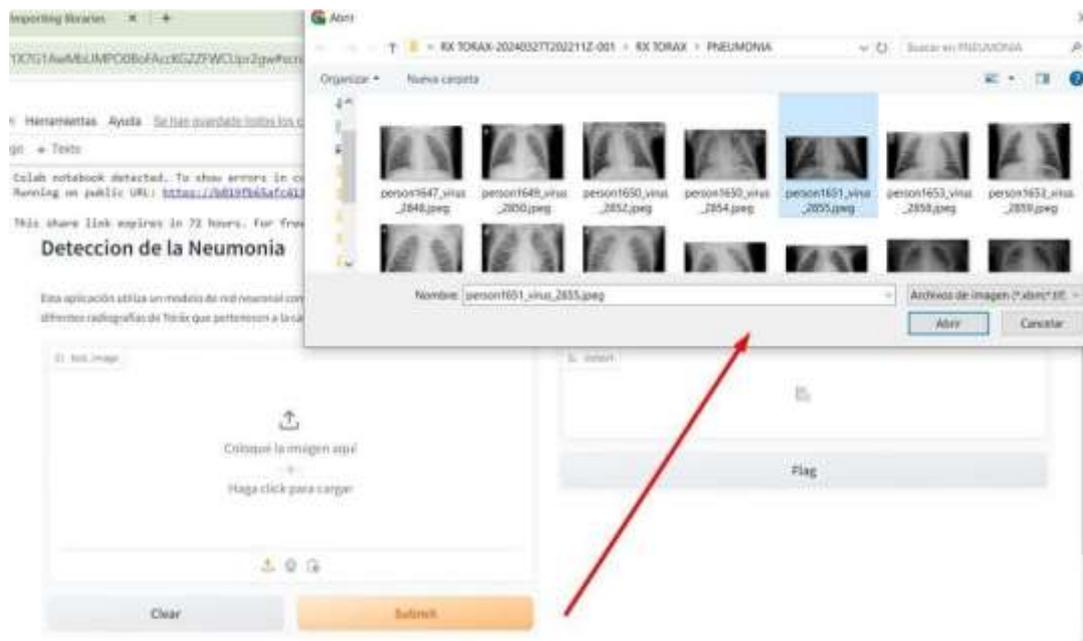
Text(0.5, 1.0, 'Matrix de confusion para el dataset de validacion')

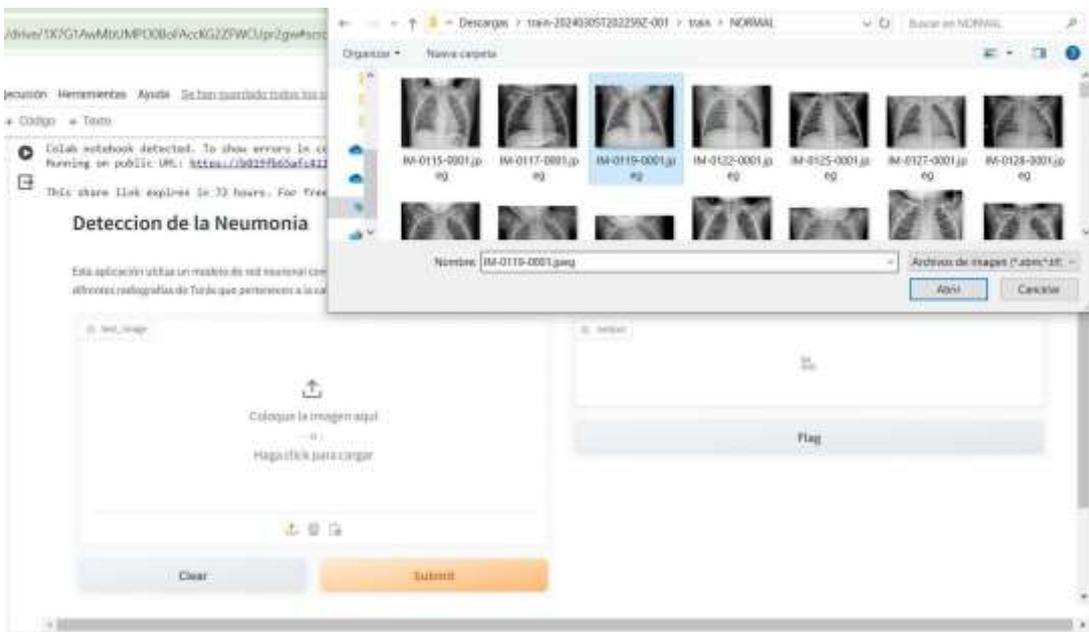
Matrix de confusion para el dataset de validacion



Deteccion de la Neumonia

Esta aplicación utiliza un modelo de red neuronal convolucional (CNN) para predecir si una radiografía de tórax muestra si la persona tiene neumonía o no. Para comprobar el modelo predictivo, se emplean diferentes radiografías de tórax que pertenecen a la categoría normal y categoría neumonía.







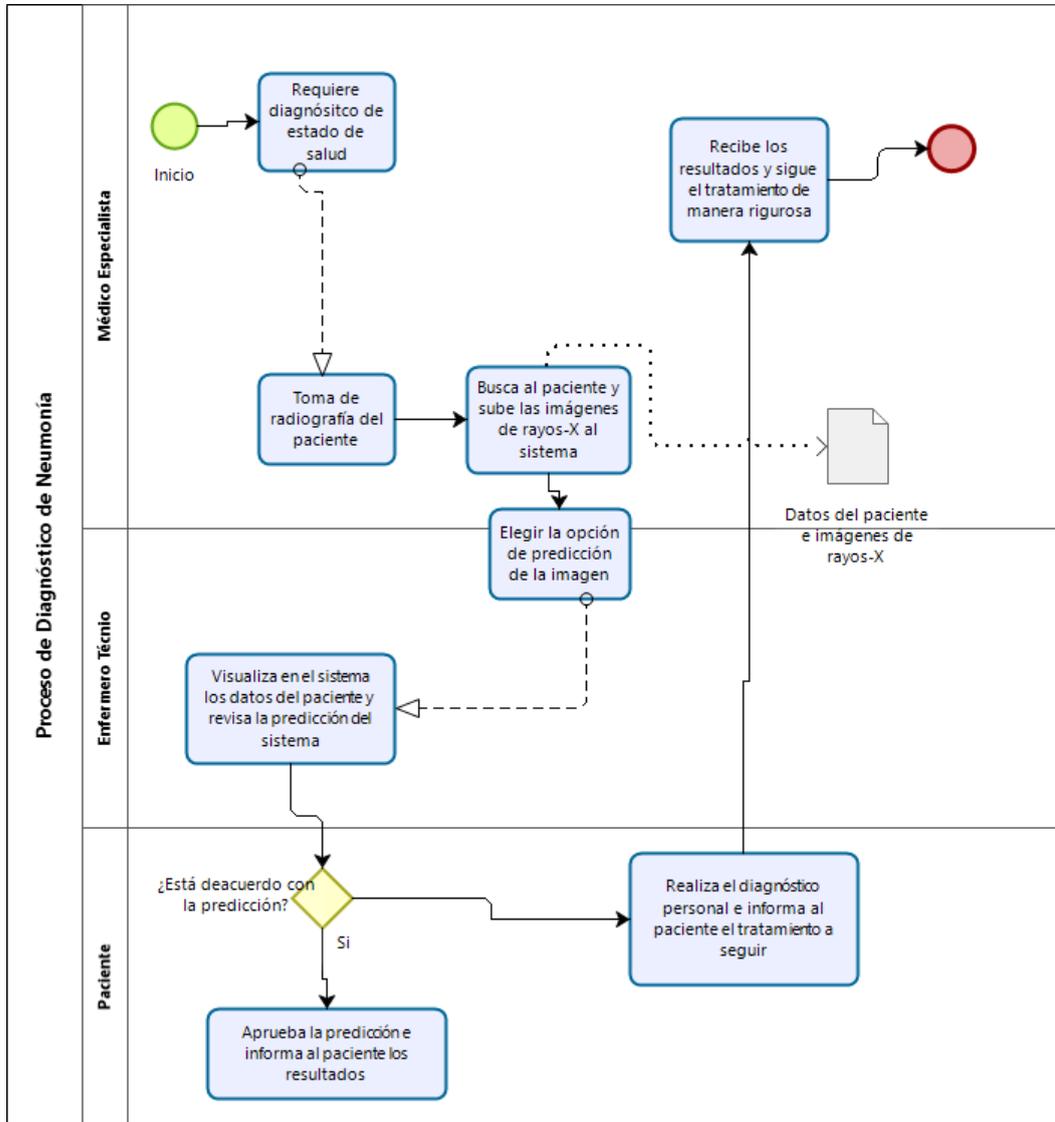
chest_image

Normal

| | |
|-----------|------|
| Normal | 100% |
| Pneumonia | 0% |

Flag

ANEXO 14: Proceso de Diagnóstico de Neumonía con el Diseño Implementado



ANEXO 15: Lugar de Investigación



ANEXO 16: Solicitud de Apoyo al Diagnóstico de Rayos X


HOSPITAL DE APOYO BAGUA II
"Gustavo Lanatta Luján"
SOLICITUD DE APOYO AL DIAGNÓSTICO - RAYOS X


Nombres: [REDACTED]
 PARTICULAR: SIS: H. C. 913275080
 CODIGO SIS: 21-113143710 EDAD: 41 SEXO: E
 DIAGNÓSTICO: pc Neumonia
 SERVICIO: Emergencia ESPECIALIDAD: Pediatría

| CANT. DIMENSIONES DE PLACAS | ESPECIFICACIÓN | POSICIÓN |
|--|--|--|
| <input type="checkbox"/> 24 x 30 | Rx. Mano Rx. Muñeca Rx. Hueso Propio Nariz. | Fy Oblicua FyL FyL |
| <input type="checkbox"/> 30 x 40 | Rx. Antebrazo Rx. Brazo Rx. Hombro Rx. Columna Cervical Rx. Columna Dorsal Rx. Columna Lumbar Rx. Rodilla Rx. Rodilla Rx. Tobillo Rx. Pie Rx. Codo Rx. Cráneo Rx. Muslo Rx. Senos Paranasales | FyL FyL 2 Posiciones FyL FyL FyL FyL Sol. Macaride FyL Fy Oblicua FyL FyL FyL FyL |
| <input type="checkbox"/> 14 x 17 (35 x 43) | Rx. Pared Costal Rx. Columna Densa Lumb. Rx. Columna Lumbo Sacro Rx. Pelvis Rx. Piernas Rx. Abdomen Simple, Abdomen Completo. | 2 Posiciones FyL FyL AP FyL |
| <input checked="" type="checkbox"/> 14 x 14 35 x 35) | Rx. VON ROSEES Rx. Cadera Tórax Pelvis | 2 Posiciones Fy Axial AP |
| <input type="checkbox"/> Perí apical Adulto <input type="checkbox"/> Perí apical Niño <input type="checkbox"/> Oclusal | | |

Otros Especificar: _____

MINISTERIO DE SALUD
 GOBIERNO REGIONAL AMAZONAS
 HOSPITAL DE APOYO BAGUA II, I.

Emily Consuelo Silva Zamora
 MÉDICO CIRUJANO
 C.M.P. 021859
 FIRMA Y SELLO DEL MÉDICO

Fecha: 14 / 03 / 24

ANEXO 17: Reporte de Autenticidad y Similitud



UNIVERSIDAD NACIONAL DEL CALLAO
FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS
UNIDAD DE INVESTIGACIÓN



CONSTANCIA DE ANTIPLAGIO N° 028-2024

EL DIRECTOR DE LA UNIDAD DE INVESTIGACIÓN DE LA FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS, QUE SUSCRIBE:

HACE CONSTAR

QUE, LOS BACHILLERES:

- ALVA ITA JUNIOR EDERSON
- ASUNCION RUIZ DANTYA MIRIELLI
- HUAMAN LLANOS ALEX ALFREDO

HAN PRESENTADO SU TESIS TITULADA: "DISEÑO DE UN MODELO DE RED NEURONAL CONVOLUCIONAL PARA MEJORAR EL PROCESO DE DIAGNÓSTICO DE NEUMONÍA EN LOS PACIENTES DEL HOSPITAL GUSTAVO LANATTA LUJÁN DE BAGUA, 2024" PARA LA EVALUACIÓN ANTIPLAGIO COMPILATIO MAGISTER, OBTENIENDO COMO RESULTADO 09% DE SIMILITUD, ESTANDO DENTRO DEL PORCENTAJE PERMITIDO (MÁXIMO 30%).

SE EXPIDE LA PRESENTE CONSTANCIA A SOLICITUD DE LOS INTERESADOS PARA REALIZAR TRÁMITES CORRESPONDIENTES A LA SUSTENTACIÓN DE TESIS.

Belavista, 06 de mayo de 2024



UNIVERSIDAD NACIONAL DEL CALLAO
UNIDAD DE INVESTIGACIÓN FIS

Dr. SAKIBARU MAURICIO LUIS ALBERTO
DIRECTOR UI FIS-UNAC