



Acta de Correcciones al Documento de Trabajo de Grado

Santiago de Cali, 18 de julio de 2024

Autores: Álvaro Augusto Cote Flórez ID 8980283, Amolfi Hernando Pineda Gómez ID 8976178, Javier Armando Rodríguez Prada ID 8980080

Título del Trabajo de Grado: “Identificación de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”

Director: Hernán Darío Vargas Cardona

Como indica el artículo 2.13 de las Directrices para Trabajo de Grado de Maestría, he verificado que los estudiantes indicados arriba, han implementado todas las correcciones que los Jurados del Proyecto de Trabajo de Grado definieron que se efectuaran, como consta en el Acta de Evaluación correspondiente.

Firma del director del Trabajo de Grado

Santiago de Cali, 07 de junio del 2024

Doctor

Diego Luis Linares Ospina

Director Maestría en Ciencia de Datos

Facultad de Ingeniería y Ciencias

Pontificia Universidad Javeriana de Cali

Asunto: Presentación para evaluación del proyecto aplicado

Cordial Saludo,

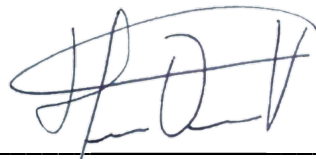
Con el fin de cumplir con los requisitos exigidos por la Universidad para optar por el título de Magíster en Ciencia de Datos, nos permitimos presentar a su consideración el proyecto denominado **“Identificación de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”**, el cual fue realizado por el (los) estudiante (s) **Álvaro Augusto Cote Flórez, Amolfi Hernando Pineda Gómez y Javier Armando Rodríguez Prada** con código (s) **8980283, 8976178 y 8980080**, pertenecientes a la Maestría en Ciencia de Datos, bajo la dirección de **PhD Hernán Darío Vargas Cardona**.

El suscrito director del Proyecto Aplicado autoriza para que se proceda a hacer la evaluación de este proyecto, toda vez que ha revisado cuidadosamente el documento y avala que ya se encuentra listo para ser presentado y sustentado oficialmente.

Atentamente,




Álvaro Augusto Cote Flórez
C.C. 91.298.011 de Bucaramanga



PhD Hernán Darío Vargas Cardona
C.C. 1097721437 de Montenegro



Amolfi Hernando Pineda Gómez
C.C. 73.164.241 de Cartagena



Javier Armando Rodríguez Prada
C.C. 91.179.227 de Girón

Documentación anexa:

Resumen del Proyecto Aplicado en formato digital (máximo 1 página).

Una copia digital (PDF) del documento del proyecto aplicado



Bucaramanga, 22 de junio de 2023

Señor

JAVIER ARMANDO RODRÍGUEZ

Colaborador Instituto del Corazón de Bucaramanga

Maestrando Ciencia de datos Universidad Javeriana - Cali

Asunto: Autorización al Acceso de Datos Clínicos e Imágenes Digitales de Pacientes Institucionales.

Cordial saludo

Por medio de la presente me permito autorizar el acceso a datos clínicos e imágenes digitales de pacientes institucionales, necesarios para el pleno desarrollo de su proyecto de grado denominado "Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes".

No sobra mencionar que los datos en el producto de investigación deberán estar adecuadamente anonimizados y los coinvestigadores (compañeros de tesis) deberán firmar el respectivo acuerdo de confidencialidad.

Para la institución es de suma importancia el desarrollo de proyectos de investigación e innovación que conduzcan a la generación de conocimiento, el crecimiento de nuestras líneas de investigación y la extensión social.

Agradezco su tención

Cordialmente;

Dr. Boris Eduardo Vesga Angarita

Director de Cardiología y Ciencias Cardiovasculares (e)

Instituto del Corazón de Bucaramanga

FICHA RESUMEN

PROYECTO APLICADO – MAESTRÍA EN CIENCIA DE DATOS

TÍTULO: Identificación de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes

1. **ÁREA DE TRABAJO:** Inteligencia Artificial
2. **TIPO DE PROYECTO (Aplicado, Innovación, Investigación):** Investigación
3. **ESTUDIANTE(S):**
 - Álvaro Augusto Cote Flórez
 - Amolfi Hernando Pineda Gómez
 - Javier Armando Rodríguez Prada
4. **CORREO ELECTRÓNICO:**
 - alvarocote@javerianacali.edu.co
 - apinedag@javerianacali.edu.co
 - javerianoropra22@javerianacali.edu.co
5. **DIRECCIÓN Y TELEFONO:**
 - Álvaro Cote: Calle 30a # 23-95 Portería 2 Torre 3 Apto 1203 “Parque Central Cañaveral” Barrio Cañaveral Floridablanca – Santander Cel. 3005556274
 - Amolfi Pineda: Brisas del Bosque, casa 70, Fusagasugá (Cund.). Cel.: 3013369741
 - Javier Rodríguez: Circunvalar 36A No.104-25. Torre 3 Apto 401. Floridablanca, Santander Cel.: 3173318617
6. **DIRECTOR:**
 - Hernán Darío Vargas Cardona (PhD in Engineering)
7. **VINCULACIÓN DEL DIRECTOR:**
 - Profesor tiempo completo
8. **CORREO ELECTRÓNICO DEL DIRECTOR:**
 - hernan.vargas@javerianacali.edu.co
9. **CO-DIRECTOR (Si aplica):**
10. **GRUPO O EMPRESA QUE LO AVALA (Si aplica):** Instituto del Corazón de Bucaramanga

11. OTROS GRUPOS O EMPRESAS:
12. PALABRAS CLAVE (al menos 5): Deep Learning, CNN, Surgical Wounds, Image Classification, Models
13. FECHA DE INICIO: 15 Junio 2023
14. FECHA DE FINALIZACIÓN: 07 Junio 2024
15. RESUMEN:

El presente proyecto de grado utilizó la inteligencia artificial aplicada al análisis de imágenes digitales para lograr la identificación de alteraciones en heridas quirúrgicas. Esta investigación abordó una problemática de alta relevancia debido a las consecuencias que pueden surgir de las infecciones de sitio operatorio, incluyendo morbilidad, mortalidad y costos económicos significativos tanto para los pacientes como para el sistema de salud. Actualmente, la detección de estas infecciones se realiza principalmente a través de métodos clínicos y cultivos, que pueden ser tardíos y limitados en términos de precisión. Con el uso de técnicas de inteligencia artificial, como el machine learning y el deep learning, se logró desarrollar un modelo automatizado y confiable que permite la identificación de alteraciones en las heridas quirúrgicas, lo que facilita un tratamiento oportuno y efectivo. Para desarrollar el proyecto se recopiló una base de datos de imágenes digitales etiquetadas que muestran la evolución de las heridas quirúrgicas, se eligieron y adaptaron algoritmos de inteligencia artificial capaces de identificar patrones y características en dichas imágenes, y se evaluó la eficacia y precisión del modelo desarrollado mediante validaciones con métricas establecidas en el estado del arte. El resultado del trabajo realizado es el punto de partida para trabajos posteriores que podrán incluir un modelo de apoyo diagnóstico automatizado y confiable para la detección de alteraciones en heridas quirúrgicas. Este proyecto tiene aplicaciones en el campo de la cirugía y la salud pública, y su impacto se refleja en un seguimiento posquirúrgico oportuno y efectivo evitando complicaciones en las heridas y apoyando el proceso de recuperación del paciente, así como en la reducción de costos y procedimientos médicos adicionales debido a complicaciones en las heridas.



Pontificia Universidad
JAVERIANA
Cali

IDENTIFICACIÓN DE ALTERACIONES EN HERIDAS QUIRÚRGICAS MEDIANTE LA APLICACIÓN DE INTELIGENCIA ARTIFICIAL EN IMÁGENES

Álvaro Augusto Cote Flórez Cód.8980283
Amolfi Hernando Pineda Gómez Cód. 8976178
Javier Armando Rodríguez Prada Cód. 8980080

*Proyecto Aplicado para optar al título de
Magister en Ciencia de Datos*

Director
PhD Hernán Darío Vargas Cardona

FACULTAD DE INGENIERÍA Y CIENCIAS
MAESTRÍA EN CIENCIA DE DATOS
SANTIAGO DE CALI, JUNIO 7 DE 2024

TABLA DE CONTENIDO

INTRODUCCIÓN	9
1. DEFINICIÓN DEL PROBLEMA	10
2. OBJETIVOS DEL PROYECTO	13
2.1. OBJETIVO GENERAL	13
2.2. OBJETIVOS ESPECÍFICOS	13
3. MARCO TEÓRICO Y ANTECEDENTES.....	14
3.1. MARCO TEÓRICO	14
3.1.1. Heridas quirúrgicas y sus alteraciones	14
3.1.1.1. Estrategias de monitoreo y vigilancia de las heridas quirúrgicas.....	16
3.1.1.2. Aprendizaje automático y alteraciones de heridas quirúrgicas	17
3.1.1.3. Tratamiento de imágenes en la identificación de alteraciones en heridas quirúrgicas	17
3.1.2. Redes Neuronales Convolucionales (CNN).....	19
3.1.2.1. Proceso de aprendizaje de una CNN para identificar y comprender patrones en imágenes 21	
3.1.2.2. El proceso de visión de una CNN.....	22
3.1.2.3. Arquitectura de una CNN	23
3.1.2.4. Funciones de activación más usadas.....	23
3.1.2.5. Clasificación y distinción de imágenes mediante CNN.....	26
3.1.2.6. Funcionamiento de una CNN	26
3.1.2.7. Entrenamiento de una CNN	28
3.1.2.8. Métricas para evaluar un modelo de aprendizaje automático	29
3.1.2.9. Ajustes al modelo de aprendizaje automático	31
3.1.2.10. Diferencia entre Parámetros e hiperparámetros	33
3.2. ANTECEDENTES	33
4. CONSTRUCCIÓN DE UNA BASE DE DATOS DE IMÁGENES DIGITALES ETIQUETADAS DE HERIDAS QUIRÚRGICAS	36
4.1. DEFINICIÓN DE LOS CRITERIOS DE SELECCIÓN	36

4.1.1.	Definir las características de las imágenes que se incluirán en la base de datos	36
4.2.	IDENTIFICACIÓN DE FUENTES CONFIABLES	37
4.2.1.	Aspectos éticos.....	37
4.3.	RECOPIACIÓN Y ORGANIZACIÓN DE LAS IMÁGENES.....	38
4.3.1.	Base de datos de imágenes de heridas quirúrgicas	38
4.4.	PREPARACIÓN DE LOS DATOS PARA EL ANÁLISIS DE IMÁGENES.....	39
4.4.1.	Limpieza del dataset.....	39
4.4.2.	Etiquetado de las imágenes	40
4.4.3.	Segmentación de las imágenes anonimizadas	41
4.4.4.	Balanceo de la base de datos	43
5.	IMPLEMENTACIÓN Y ENTRENAMIENTO DE ALGORITMOS DE MACHINE LEARNING (ML) Y DEEP LEARNING (DL)	44
5.1.	ESTUDIO DE ALGORITMOS	44
5.1.1.	Evaluación Comparativa de Modelos y Arquitecturas de CNN para la Clasificación de Imágenes44	
5.2.	ENTRENAMIENTO DE DIFERENTES MODELOS Y ARQUITECTURAS	45
5.2.1.	Modelo 1: tres capas convolucionales	46
5.2.2.	Modelo 2: cinco capas convolucionales	49
5.2.3.	Modelo 3: seis capas convolucionales	53
5.2.4.	Modelo 4: cuatro capas convolucionales	56
5.2.5.	Arquitectura VGG16	59
5.2.6.	Arquitectura ResNet50	62
5.2.7.	Arquitectura InceptionV3	65
5.2.8.	Arquitectura MobileNetV2	68
6.	EVALUACIÓN DEL RENDIMIENTO DE LOS MODELOS DE CNN	72
6.1.	COMPARACIÓN DE 4 MODELOS PERSONALIZADOS DE CNN	72
6.2.	COMPARACIÓN DE CUATRO ARQUITECTURAS PRE ENTRENADAS DE CNN (TRANSFER LEARNING).....	75
6.3.	COMPARACIÓN DEL MODELO 2 CON MOBILENET	77
6.4.	COMPARACIÓN DEL MODELO 2 CON EL MODELO DE PEREIRA ET AL (XX).....	78
6.5.	DISCUSIÓN.....	80
7.	CONCLUSIONES Y TRABAJOS FUTUROS.....	82

7.1.	METODOLOGIA APLICADA.....	82
7.2.	EVALUACIÓN DEL MODELO SELECCIONADO	82
7.3.	EVALUACIÓN DEL PROYECTO.....	82
7.4.	TRABAJOS FUTUROS Y RECOMENDACIONES	83
8.	GLOSARIO	85
9.	REFERENCIAS BIBLIOGRÁFICAS	88

LISTA DE FIGURAS

Figura 1. Fases de la reparación de una herida. [27].	14
Figura 2. Clasificación de la infección de sitio operatorio. [35].	15
Figura 3. Relación entre IA, ML y DL. [50].	20
Figura 4. Arquitectura básica de una red neuronal artificial. [53]	20
Figura 5. Proceso de visión de una CNN. [56]	22
Figura 6. Proceso de Transformación y Activación en CNN. [58]	23
Figura 7. Funciones de activación de las CNN. [59]	25
Figura 8. Clasificación de imágenes mediante CNN. [61].	26
Figura 9. Convolución. Elaboración propia.	27
Figura 10. Mapa de Características. Elaboración propia.	27
Figura 11. Capa de Reducción. Elaboración propia.	27
Figura 12. Diferentes capas con las dimensiones de sus componentes. [62]	28
Figura 13. Matriz de Confusión. Elaboración propia.	29
Figura 14. Tipos de curvas ROC. [66]	31
Figura 15. Ejemplo de anonimización de las imágenes. Elaboración propia.	39
Figura 16. Ejemplo de separación de las imágenes. Elaboración propia.	40
Figura 17. Ejemplo de imágenes etiquetadas. Elaboración propia.	41
Figura 18. Ejemplo de definición de los segmentos de las imágenes. Elaboración propia.	42
Figura 19. Análisis de desempeño del Modelo 1	47
Figura 20. Análisis de desempeño del Modelo 2.	51
Figura 21. Análisis de desempeño del Modelo 3	54
Figura 22. Análisis de desempeño del Modelo 3	57
Figura 23. Análisis de desempeño de la arquitectura VGG16	60
Figura 24. Análisis de desempeño de la arquitectura ResNet50.	63
Figura 25. Análisis de desempeño de la arquitectura InceptionV3.	66
Figura 26. Análisis de desempeño de la arquitectura MobileNetV2.	69
Figura 27. Curvas ROC de los cuatro modelos de CNN	73
Figura 28. Matrices de confusión de los modelos de CNN explorados.	74
Figura 29. Curvas ROC de cuatro arquitecturas de CNN	76

LISTA DE TABLAS

Tabla 1. Clasificación de Infecciones del Sitio Quirúrgico por Profundidad y Localización	16
Tabla 2. Proceso de aprendizaje de una CNN	21
Tabla 3. Componentes Clave de las CNN y sus Funciones	26
Tabla 4. Proceso de entrenamiento de una CNN.	28
Tabla 5. Métricas derivadas de la matriz de confusión	30
Tabla 6. Aspectos a tener en cuenta para mejorar el rendimiento de una CNN.....	31
Tabla 7. Estudios relacionados con clasificación de imágenes de heridas.....	33
Tabla 8. Criterios de Calidad para la Captura de Imágenes de Heridas Quirúrgicas	36
Tabla 9. Especificaciones Técnicas para el Formato de Imágenes.....	37
Tabla 10. Estructura de la Red Neuronal Convolutiva para Clasificación Binaria – Modelo 1....	46
Tabla 11. Parámetros de Entrenamiento para el Modelo 1 de Clasificación Binaria	47
Tabla 12. Evaluación de Rendimiento del Modelo 1	48
Tabla 13. Resumen de Resultados de Validación por Ejecución para el Modelo 1	49
Tabla 14. Estructura de la Red Neuronal Convolutiva para Clasificación Binaria – Modelo 2....	49
Tabla 15. Parámetros de Entrenamiento para el Modelo 2 de Clasificación Binaria	50
Tabla 16. Evaluación de Rendimiento del Modelo 2	52
Tabla 17. Resumen de Resultados de Validación por Ejecución para el Modelo 2	52
Tabla 18. Estructura de la Red Neuronal Convolutiva para Clasificación Binaria – Modelo 3....	53
Tabla 19. Parámetros de Entrenamiento para el Modelo 3 de Clasificación Binaria	54
Tabla 20. Evaluación de Rendimiento del Modelo 3	55
Tabla 21. Resumen de Resultados de Validación por Ejecución para el Modelo 3	56
Tabla 22. Estructura de la Red Neuronal Convolutiva para Clasificación Binaria – Modelo 4....	56
Tabla 23. Parámetros de Entrenamiento para el Modelo 4 de Clasificación Binaria	57
Tabla 24. Evaluación de Rendimiento del Modelo 4	58
Tabla 25. Resumen de Resultados de Validación por Ejecución para el Modelo 4	59
Tabla 26. Descripción de la Arquitectura del Modelo de Clasificación Basado en VGG16	59
Tabla 27. Parámetros de Entrenamiento para la Arquitectura VGG16 de Clasificación Binaria	60
Tabla 28. Evaluación de Rendimiento de la Arquitectura VGG16	61
Tabla 29. Resumen de Resultados de Validación por Ejecución para la Arquitectura VGG16	62
Tabla 30. Descripción de la Arquitectura del Modelo de Clasificación Basado en ResNet50	62
Tabla 31. Parámetros de Entrenamiento para la Arquitectura ResNet50 de Clasificación Binaria	62
Tabla 32. Evaluación de Rendimiento de la Arquitectura ResNet50	64
Tabla 33. Resumen de Resultados de Validación por Ejecución para la Arquitectura ResNet50...	65
Tabla 34. Descripción de la Arquitectura del Modelo de Clasificación Basado en InceptionV3	65
Tabla 35. Parámetros de Entrenamiento para la Arquitectura InceptionV3 de Clasificación Binaria	66
Tabla 36. Evaluación de Rendimiento de la Arquitectura InceptionV3	67
Tabla 37. Resumen de Resultados de Validación por Ejecución para la Arquitectura InceptionV3	68
Tabla 38. Descripción de la Arquitectura del Modelo de Clasificación Basado en MobileNetV2 ..	68

Tabla 39. Parámetros de Entrenamiento para la Arquitectura MobileNetV2 de Clasificación Binaria.....	69
Tabla 40. Evaluación de Rendimiento de la Arquitectura MobileNetV2	70
Tabla 41. Resumen de Resultados de Validación por Ejecución para la Arquitectura MobileNetV2	71
Tabla 42. Comparación de las métricas de desempeño de cuatro modelos de CNN	72
Tabla 43. Efectos absolutos de la aplicación hipotética de los cuatro modelos de CNN	75
Tabla 44. Comparación de las métricas de desempeño de cuatro arquitecturas de CNN	75
Tabla 45. Efectos absolutos de la aplicación hipotética de las cuatro arquitecturas de CNN	77
Tabla 46. Comparación de las métricas de desempeño del Modelo 2 y Mobilenet	77
Tabla 47. Comparación de dos Proyecto de aprendizaje automático para clasificación de heridas quirúrgicas	79

LISTA DE ANEXOS

- Anexo 1. Carta de presentación del director de proyecto de grado.
- Anexo 2. Aval del Comité de Ética e Investigación.
- Anexo 3. Autorización de cambio de título del proyecto aplicado.

INTRODUCCIÓN

La identificación de alteraciones en heridas quirúrgicas es un desafío clave en el campo de la medicina, debido a su impacto significativo en la morbilidad y mortalidad de los pacientes sometidos a cirugía. Actualmente, los métodos clínicos y cultivos utilizados para detectar estas alteraciones pueden ser tardíos y limitados en su precisión. En este contexto, la aplicación de inteligencia artificial en el análisis de imágenes ha surgido como una prometedora solución para mejorar la detección precisa de estas alteraciones.

En este trabajo se aplicó la inteligencia artificial en imágenes digitales para lograr la identificación de alteraciones en heridas quirúrgicas. Para ello, se recopiló una base de datos de imágenes digitales etiquetadas suministradas por el Instituto del Corazón de Bucaramanga, que muestran la evolución de las heridas quirúrgicas. Estas imágenes fueron analizadas mediante técnicas de aprendizaje profundo, las cuales permitieron identificar patrones y características relevantes que son utilizados para el análisis de nuevos casos de detección de alteraciones en las heridas.

La necesidad de abordar este problema radicó en la importancia de detectar de manera oportuna las alteraciones en heridas quirúrgicas, ya que su detección tardía puede conducir a complicaciones graves y prolongar el tiempo de recuperación de los pacientes. La aplicación de inteligencia artificial en este contexto ofrece numerosos beneficios, como un diagnóstico más preciso y rápido, un tratamiento más efectivo y oportuno, y una reducción en los costos de atención médica.

Para lograr el objetivo de este proyecto se llevaron a cabo diversas actividades que incluyen: la recopilación de imágenes digitales etiquetadas, el preprocesamiento de estas, la selección y extracción de características relevantes, el entrenamiento de modelos de aprendizaje automático y la evaluación y validación de dichos modelos.

1. DEFINICIÓN DEL PROBLEMA

1.1. PLANTEAMIENTO DEL PROBLEMA

Las infecciones de sitio operatorio (ISO) son una de las principales complicaciones asociadas a la cirugía, lo cual representa un desafío significativo para los pacientes y el sistema de salud en general [1]. Estas infecciones aumentan considerablemente la morbilidad, la mortalidad y los costos económicos relacionados tanto para el paciente como para el sistema de salud [2].

La detección de las ISO a partir de las alteraciones en la herida quirúrgica es de vital importancia para un tratamiento oportuno y efectivo [3, 4, 5]. Sin embargo, actualmente, el proceso de detección de ISO en pacientes sometidos a cirugía se realiza principalmente a través de la evaluación clínica y la toma de cultivos, lo cual puede resultar en un diagnóstico tardío y limitado en términos de precisión [6].

Además de lo anterior, muchos pacientes experimentan dificultades relacionadas con el tiempo, los costos económicos o el desplazamiento a los controles médicos postoperatorios, lo que puede ocasionar que se pierda la oportunidad de realizar un seguimiento adecuado a la evolución de la herida quirúrgica [7]. Estas limitaciones en el proceso de detección y seguimiento de las ISO pueden llevar a retrasos en el inicio del tratamiento, aumentando así el riesgo de complicaciones y la carga económica para el paciente y el sistema de salud [8].

Por lo tanto, es necesario desarrollar enfoques más eficientes y precisos para la detección de las ISO en heridas quirúrgicas [9, 10]. En este sentido, la aplicación de inteligencia artificial en imágenes digitales ofrece una solución [11]. La utilización de algoritmos de análisis de datos y aprendizaje automático permite identificar patrones y características específicas en las imágenes de las heridas quirúrgicas, lo que facilita la detección de las ISO [12].

Sin embargo, estos enfoques se enfrentan a desafíos significativos relacionados con las imágenes de las heridas quirúrgicas. Estos desafíos incluyen el ruido presente en las imágenes, que puede dificultar la detección precisa de las alteraciones, así como problemas de iluminación y contraste que representan obstáculos importantes al ocultar detalles relevantes y dificultar la distinción entre tejidos sanos y alterados [13]. Además, los problemas relacionados con el tamaño y la resolución de las imágenes introducen variaciones y dificultan la extracción de características

relevantes. Superar estos desafíos es crucial para lograr una identificación precisa de las ISO mediante la aplicación de inteligencia artificial en imágenes [14].

Los algoritmos de aprendizaje utilizados para la identificación de alteraciones en heridas quirúrgicas también enfrentan desafíos propios. Estos algoritmos deben ser entrenados con conjuntos de datos etiquetados y representativos, pero la disponibilidad de tales conjuntos de datos puede ser limitada [15]. Además, la selección y configuración adecuada de los algoritmos de aprendizaje, como los basados en redes neuronales convolucionales, es fundamental para lograr un desempeño óptimo en la detección de alteraciones en las heridas quirúrgicas [16].

El presente proyecto aprovechó la capacidad de la inteligencia artificial y los avances en el análisis de datos para desarrollar un sistema de identificación de alteraciones en heridas quirúrgicas, utilizando imágenes digitales etiquetadas como fuente de información [17]. La viabilidad técnica y académica se soporta en la disponibilidad de herramientas de procesamiento de análisis para este tipo de datos descritas en la literatura científica [18, 19]. Este enfoque innovador ayuda a mejorar la detección y seguimiento de las ISO, permitiendo un tratamiento más oportuno [20].

1.2. FORMULACIÓN DEL PROBLEMA

Este estudio se enfoca en la detección de alteraciones en heridas quirúrgicas utilizando inteligencia artificial en el análisis de imágenes [21]. El principal desafío radica en identificar estas alteraciones con alta precisión, un factor clave para asegurar un tratamiento temprano y contribuir a la rápida recuperación de los pacientes [22]. Para enfrentar este reto, se propuso la implementación de técnicas avanzadas de inteligencia artificial y análisis de imágenes digitales etiquetadas [23]. La investigación se guio por la pregunta: ¿Es viable identificar alteraciones en heridas quirúrgicas a través de la inteligencia artificial aplicada a imágenes? Dicho interrogante orientó el desarrollo del proyecto de grado.

1.3. JUSTIFICACIÓN

El presente proyecto de grado tiene una gran pertinencia e importancia en el campo de la medicina, ya que aborda la identificación de alteraciones en heridas quirúrgicas utilizando inteligencia artificial en imágenes. La detección oportuna de estas alteraciones es crucial para facilitar un tratamiento más efectivo y una pronta recuperación de los pacientes. Existen numerosos estudios que demuestran cómo la detección de alteraciones en las heridas quirúrgicas

puede mitigar el riesgo de complicaciones incluida la infección, reducir el tiempo de hospitalización y mejorar los resultados clínicos [4][5]. Este proyecto se alinea con la necesidad de implementar herramientas avanzadas de análisis de imágenes para mejorar la atención médica.

El enfoque propuesto en este proyecto es viable desde el campo del conocimiento, aprovechando las capacidades de los estudiantes de maestría en ciencia de datos y del director del proyecto, quien posee experiencia en el manejo y análisis de datos, así como en aplicaciones de inteligencia artificial en medicina. Por otro lado, se cuenta con acceso a una base de datos de imágenes digitales etiquetadas suministrada por una IPS privada que permite el desarrollo del proyecto. La viabilidad técnica y académica se soporta en la disponibilidad de herramientas de procesamiento de análisis de datos descritas en la literatura científica [18][19].

El proyecto es factible dado que los recursos necesarios para su desarrollo no representan grandes inversiones de dinero, así mismo, se basa en estudios previos que han destacado la importancia de la detección de complicaciones en heridas quirúrgicas para mejorar los resultados clínicos [9][10].

Otro impacto positivo a mediano o largo plazo consiste en la incorporación del modelo en programas de cuidado y seguimiento post quirúrgico que permitan una mejor atención.

2. OBJETIVOS DEL PROYECTO

2.1. OBJETIVO GENERAL

Identificar alteraciones en heridas quirúrgicas mediante la aplicación de métodos de inteligencia artificial en imágenes digitales.

2.2. OBJETIVOS ESPECÍFICOS

- Construir una base de datos de imágenes digitales etiquetadas de heridas quirúrgicas y realizar preprocesamiento para mejorar la calidad y extraer características relevantes.
- Implementar y entrenar algoritmos de machine learning (ML) y deep learning (DL) para la identificación de alteraciones en heridas quirúrgicas.
- Evaluar el rendimiento de los algoritmos de ML y DL empleando métricas estándar del estado del arte para selección del modelo.

3. MARCO TEÓRICO Y ANTECEDENTES

3.1. MARCO TEÓRICO

3.1.1. Heridas quirúrgicas y sus alteraciones

A nivel mundial, se estima que se realizan 4511 intervenciones quirúrgicas por cada 100,000 habitantes anualmente, lo que equivale a 1 procedimiento quirúrgico cada año por cada 22 personas [24]. Para 2010 se realizaron cerca de 321.5 millones procedimientos quirúrgicos ambulatorios, cifra que corresponde a una necesidad quirúrgica per cápita global de 4.664 por 100.000 [25].

Las heridas quirúrgicas derivadas de los procedimientos invasivos son el producto de la incisión de la piel y los tejidos, que como injuria aguda se acompañan tempranamente de la activación del proceso de reparación tisular denominado cicatrización. Este, caracterizado por ser dinámico y complejo, se divide en cuatro fases fundamentales (Figura 1) [26, 27]: hemostasia, inflamación, proliferación y maduración. La hemostasia ocurre inmediatamente después de la cirugía para controlar el sangrado. Le sigue la fase inflamatoria, caracterizada por la limpieza de la herida. Posteriormente, en la fase de proliferación, el tejido nuevo comienza a formarse. Finalmente, durante la maduración, el tejido cicatricial se fortalece y remodela.

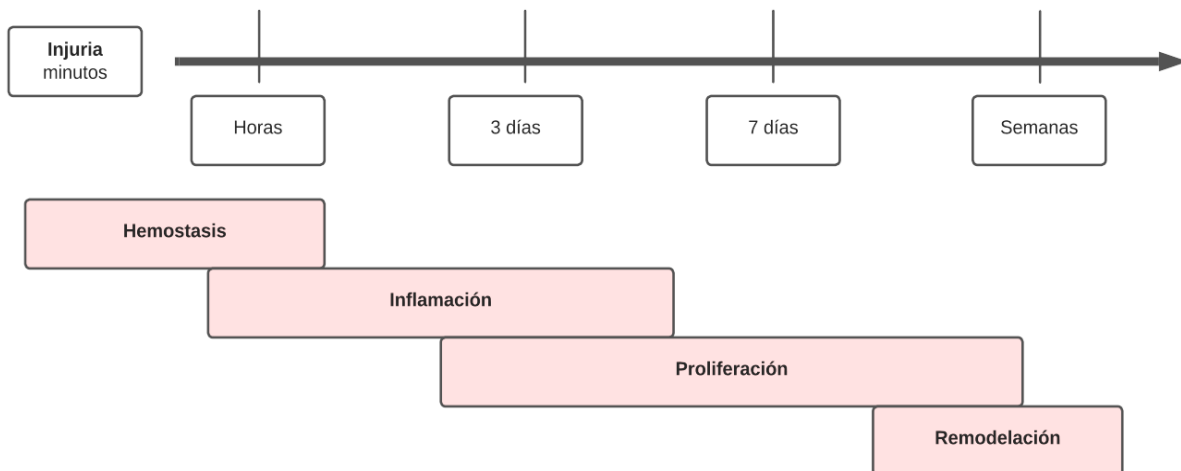


Figura 1. Fases de la reparación de una herida. [27].

Si bien las intervenciones quirúrgicas contribuyen al tratamiento de múltiples enfermedades y alivio del sufrimiento, no están exentas de complicaciones (prevalencia de hasta del 30% en algunos grupos), dentro de las cuales sobresalen problemas de la herida quirúrgica (dehiscencia o separación de los bordes, hematoma, infección), sangrado, infección (pulmonar, urinaria, etc.) y dolor entre otras [28, 29]. Las heridas quirúrgicas son las heridas más comunes manejadas en entornos de atención aguda, siendo la infección del sitio operatorio (ISO), la complicación más común.

A nivel globalmente, se estima que las tasas de infección del sitio quirúrgico varían desde el 1.9% [30] hasta un 40% de las cirugías [31]. Uno de cada cuatro pacientes desarrolla complicaciones postoperatorias dentro de los 14 días posteriores al alta hospitalaria [32]. En consecuencia, las estimaciones actuales sugieren que las complicaciones de las heridas quirúrgicas representan casi el 4% del costo total del sistema de atención de salud, y esa proporción está en aumento. En este sentido, un caso de infección del sitio quirúrgico puede costar hasta \$30,000 dependiendo de su gravedad [33]. Adicionalmente, las ISO como infecciones que se presentan dentro de los 30 días siguientes a una cirugía, se asocian con aproximadamente 7 a 11 días adicionales de hospitalización postoperatoria y un riesgo de muerte entre 2 y 11 veces mayor que los pacientes sin la condición [34].

Para mitigar la subjetividad de la detección de la infección del sitio operatorio el Centro de Control de Enfermedades (del inglés Control Center Disease, CDC) estableció tres categorías (infección superficial, infección profunda y órgano espacio), cada una con sus definiciones operativas, donde sobresalen las características clínicas de la herida y hallazgos microbiológicos como criterios diagnósticos, siendo estos últimos poco disponibles en centros de atención primaria o áreas con recursos limitados (Figura 2) [35].




Figura 2. Clasificación de la infección de sitio operatorio. [35]

Tabla 1. Clasificación de Infecciones del Sitio Quirúrgico por Profundidad y Localización

Categoría	Características	Ejemplo [35]
Infección del Sitio Quirúrgico Superficial (ISS)	Ocurre solo en la piel y en el tejido subcutáneo donde se realizó la incisión quirúrgica. Generalmente se presenta dentro de los 30 días después de la operación. Los síntomas pueden incluir enrojecimiento, dolor o sensibilidad, hinchazón y la posible secreción de pus en el sitio de la incisión.	
Infección del Sitio Quirúrgico Profunda (ISP)	Afecta a los tejidos blandos debajo de la capa de la piel, como los músculos y los ligamentos, pero aún está relacionada con la incisión quirúrgica. Puede manifestarse dentro de los 30 días después de la cirugía si no se ha implantado ningún dispositivo, y hasta un año después si se ha implantado. Los signos incluyen fiebre, dolor o sensibilidad en el área afectada más allá de lo que se consideraría normal para la recuperación quirúrgica, y posiblemente drenaje del sitio de la incisión.	
Infección del Sitio Quirúrgico de Órgano/Espacio (ISO/E)	Esta categoría se refiere a infecciones que afectan a cualquier parte del cuerpo en el nivel del órgano o el espacio que fue abierto o manipulado durante la cirugía, excluyendo la piel incisión, los músculos y los ligamentos. Puede ocurrir dentro de los 30 días después de la cirugía si no se ha implantado ningún dispositivo, y hasta un año después si se ha implantado. Los síntomas varían ampliamente dependiendo del órgano o espacio afectado, pero pueden incluir fiebre, dolor y mal funcionamiento del órgano o área afectada.	

3.1.1.1. Estrategias de monitoreo y vigilancia de las heridas quirúrgicas

Aunque las guías recomiendan medidas como la administración de antibióticos y técnicas asépticas para prevenir infecciones en el sitio quirúrgico (ISO), no son completamente evitables, siendo crítica la gestión de heridas postquirúrgicas para detectar y prevenir las ISO. Los métodos tradicionales de seguimiento postoperatorio han sido complementados por la telemedicina, especialmente mediante el uso de fotografía de heridas y teleconsultas, permitiendo evaluaciones remotas y reduciendo las visitas presenciales. Aunque la puntuación ASEPSIS de los años 80 ofrecía una evaluación cuantitativa de infecciones, la falta de recursos y experiencia limitaba su efectividad. Recientemente, aplicaciones como WoundCheck permiten a los pacientes monitorear sus heridas con smartphones, facilitando el cuidado y la detección temprana de complicaciones. A pesar de las ventajas de la telemedicina, existen desafíos como la estandarización de procedimientos y la privacidad de datos. Avances en inteligencia artificial podrían potencialmente

superar algunas de estas limitaciones. [36-38].

3.1.1.2. Aprendizaje automático y alteraciones de heridas quirúrgicas

La telemedicina ha mejorado el acceso a la atención médica, pero enfrenta limitaciones como la disponibilidad de especialistas y la subjetividad en la interpretación de imágenes. La inteligencia artificial (IA), especialmente mediante técnicas de aprendizaje profundo, está transformando la evaluación de imágenes médicas, incluyendo fotografías de heridas postquirúrgicas. Las redes neuronales convolucionales (CNN) permiten un análisis automático y eficiente de estas imágenes, mejorando la identificación de signos de infección y etapas de cicatrización, superando la precisión humana. Esto facilita evaluaciones objetivas y rápidas, mejorando la monitorización y respuesta ante complicaciones. Estudios como el de Tabja et al demuestran la viabilidad de las CNN en la evaluación médica, destacando su potencial para optimizar la atención sanitaria mediante el aprendizaje automático. [39]

3.1.1.3. Tratamiento de imágenes en la identificación de alteraciones en heridas quirúrgicas

El tratamiento de imágenes para modelos de machine learning y deep learning es un área importante que ha ganado una considerable atención en los últimos años debido a sus aplicaciones en una variedad de campos incluida la medicina. La calidad de los datos de entrada puede afectar significativamente el rendimiento de los modelos, por lo que el preprocesamiento de imágenes es un paso esencial en el pipeline de aprendizaje automático. A continuación, se describen brevemente los métodos y técnicas utilizados para el tratamiento de imágenes, incluyendo la recolección de datos, la normalización, la ampliación de datos, y las consideraciones específicas para deep learning.

El primer paso en el tratamiento de imágenes es la recolección de datos. La calidad y cantidad de los datos de imagen tienen un impacto directo en la capacidad del modelo para generalizar a nuevos datos. Idealmente, las imágenes deben ser recolectadas de una variedad de fuentes para asegurar la diversidad y evitar sesgos. Además, es importante etiquetar las imágenes de manera precisa y coherente, especialmente en problemas de clasificación. Para facilitar este proceso, se pueden utilizar técnicas de crowdsourcing o herramientas de anotación automatizadas. Una vez recolectadas y etiquetadas, las imágenes se dividen típicamente en conjuntos de entrenamiento, validación y prueba para evaluar el rendimiento del modelo de manera objetiva.

La normalización es una técnica de preprocesamiento clave en el tratamiento de imágenes. Las imágenes recolectadas pueden variar en términos de tamaño, escala de color y brillo, entre otros factores. La normalización implica transformar las imágenes para que tengan características similares, lo que facilita el aprendizaje del modelo. Un método común es la normalización de las

intensidades de los píxeles para que caigan dentro de un rango específico, como $[0, 1]$ o $[-1, 1]$. Esto se logra dividiendo los valores de los píxeles por el valor máximo posible (255 para imágenes de 8 bits) [40]. Además, se puede aplicar la normalización z-score, que implica restar la media y dividir por la desviación estándar de los valores de los píxeles, para asegurar que los datos tengan una distribución estándar. Esta técnica es especialmente útil para redes neuronales convolucionales (CNN) que son sensibles a la escala de los datos de entrada [41].

La ampliación de datos es otra técnica fundamental, especialmente cuando se trabaja con conjuntos de datos pequeños. La ampliación de datos implica generar nuevas imágenes a partir de las existentes mediante transformaciones como rotaciones, traslaciones, escalados, y cambios en el brillo y contraste [42]. Estas transformaciones aumentan la diversidad del conjunto de datos y ayudan a prevenir el sobreajuste del modelo al exponerlo a una mayor variedad de ejemplos. En el contexto de deep learning, la ampliación de datos puede realizarse en tiempo real durante el entrenamiento mediante generadores de datos que aplican transformaciones aleatorias a cada lote de imágenes.

Para deep learning, las consideraciones específicas en el tratamiento de imágenes incluyen el uso de técnicas avanzadas de preprocesamiento y la arquitectura del modelo. Una técnica avanzada es el preprocesamiento de imágenes mediante la extracción de características. Esto puede realizarse utilizando modelos preentrenados en grandes conjuntos de datos, como ImageNet, y luego utilizando estas características como entrada para modelos más pequeños [43]. Este enfoque, conocido como transfer learning, puede mejorar significativamente el rendimiento del modelo, especialmente cuando se dispone de un conjunto de datos limitado. Además, técnicas como la normalización por lotes (batch normalization) y la regularización (dropout) se utilizan comúnmente en redes neuronales profundas para mejorar la estabilidad y el rendimiento del entrenamiento [44].

Otra consideración importante es el uso de arquitecturas de redes neuronales diseñadas específicamente para el procesamiento de imágenes. Las CNN son la arquitectura más comúnmente utilizada para el tratamiento de imágenes debido a su capacidad para capturar características espaciales jerárquicas [45]. Las capas convolucionales aplican filtros a las imágenes de entrada para extraer características locales, mientras que las capas de pooling reducen la dimensionalidad y aumentan la invariancia a la traslación. Las arquitecturas modernas de CNN, como ResNet, DenseNet y EfficientNet, incorporan técnicas avanzadas como conexiones residuales y bloques densamente conectados para mejorar el flujo de gradientes y la eficiencia del aprendizaje [46].

El preprocesamiento de imágenes también debe considerar la alineación y el registro de imágenes, especialmente en aplicaciones médicas donde las imágenes pueden variar significativamente en términos de orientación y escala [47]. Las técnicas de registro de imágenes alinean múltiples imágenes a una referencia común mediante transformaciones geométricas. Esto es clave para asegurarse de que las características relevantes estén alineadas correctamente, lo

que mejora la precisión del modelo. Además, el uso de técnicas de segmentación para aislar regiones de interés en las imágenes puede mejorar la precisión del modelo al enfocarse en las partes más relevantes de la imagen.

Un desafío importante en el tratamiento de imágenes es la variabilidad en las condiciones de captura. Las imágenes pueden estar afectadas por factores como la iluminación, el ruido y la resolución. Para abordar estos problemas, se pueden aplicar técnicas de preprocesamiento como la reducción de ruido y la mejora de la calidad de la imagen. Los filtros de suavizado, como el filtro de mediana y el filtro gaussiano, se utilizan comúnmente para reducir el ruido. Además, técnicas de mejora de la imagen, como el ajuste del contraste y la ecualización del histograma, pueden mejorar la calidad visual de las imágenes y facilitar la detección de características relevantes [48].

En el contexto de la inteligencia artificial (IA) y el aprendizaje profundo, el tratamiento de imágenes también implica el uso de técnicas de sintetización de datos. Los Generative Adversarial Networks (GANs) son una herramienta poderosa para generar imágenes sintéticas que pueden utilizarse para ampliar el conjunto de datos de entrenamiento [49]. Las GANs consisten en un generador que crea imágenes y un discriminador que evalúa su realismo, compitiendo entre sí en un proceso de aprendizaje. Este enfoque no solo aumenta la cantidad de datos disponibles, sino que también puede generar ejemplos difíciles que mejoran la robustez del modelo.

En conclusión, el tratamiento de imágenes para modelos de machine learning y deep learning es un proceso multifacético que abarca desde la recolección y etiquetado de datos hasta técnicas avanzadas de preprocesamiento y ampliación de datos. La normalización, la ampliación de datos y el uso de arquitecturas de redes neuronales específicas para imágenes son pasos cruciales para mejorar el rendimiento del modelo. Además, las técnicas de registro de imágenes, reducción de ruido, mejora de la calidad de la imagen y sintetización de datos son consideraciones importantes para abordar la variabilidad en las condiciones de captura. A medida que las aplicaciones de IA continúan expandiéndose, el tratamiento efectivo de imágenes seguirá siendo un componente esencial para el éxito de los modelos de aprendizaje automático y profundo.

3.1.2. Redes Neuronales Convolucionales (CNN)

La Inteligencia Artificial (IA) es un campo de la informática que desarrolla sistemas capaces de ejecutar tareas que típicamente requieren inteligencia humana, como reconocimiento de voz y traducción de idiomas. Dentro de la IA, el Aprendizaje Automático (ML por su sigla en inglés) permite a las máquinas mejorar automáticamente a través de la experiencia con datos. Un subcampo más especializado del ML es el Aprendizaje Profundo (DL por su sigla en inglés), que usa redes neuronales profundas para analizar grandes volúmenes de datos y resolver problemas complejos, como el reconocimiento de imágenes. En la siguiente figura se muestra la relación

entre estos tres campos.

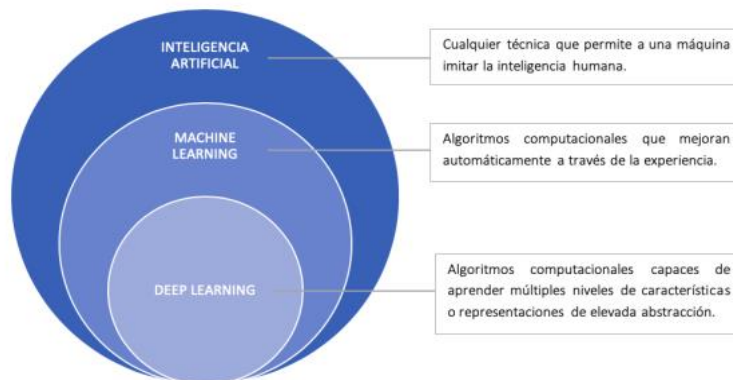


Figura 3. Relación entre IA, ML y DL. [50].

Las redes neuronales son un subconjunto de aprendizaje automático y están en el centro de los algoritmos de aprendizaje profundo. A su vez, las redes neuronales convolucionales (CNN) son una variante de las redes neuronales diseñadas específicamente para procesar datos con estructura de cuadrícula, como imágenes o señales de audio. Inspiradas en la forma en que el cerebro humano procesa información visual, las CNN han demostrado ser extremadamente efectivas en la tarea de reconocimiento de patrones, pues a diferencia de las redes neuronales tradicionales, las CNN aprovechan la estructura y las características espaciales de las imágenes para extraer y aprender características relevantes [51][52].

Las CNN (también llamadas ConvNets) están compuestas de capas de nodos que incluyen una capa de entrada, una o más capas ocultas y una capa de salida. Cada nodo se conecta a otro y tiene un peso y umbral asociados. Si la salida de cualquier nodo individual está por encima del valor del umbral especificado, ese nodo se activa y envía datos a la siguiente capa de la red (ver Figura 4). De lo contrario, no se pasa ningún dato a la siguiente capa de la red.





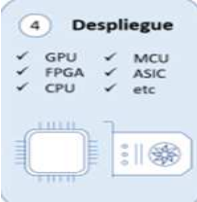


Figura 4. Arquitectura básica de una red neuronal artificial. [53]

3.1.2.1. Proceso de aprendizaje de una CNN para identificar y comprender patrones en imágenes

Las redes neuronales convolucionales (CNN) aprenden a identificar y comprender patrones en imágenes a través de un proceso conocido como aprendizaje profundo. Este proceso implica entrenar la red con un extenso conjunto de imágenes etiquetadas, lo que permite a la red capturar las características visuales relevantes para la clasificación de las imágenes [54]. El proceso se desarrolla en varias etapas como se describe en la siguiente tabla.

Tabla 2. Proceso de aprendizaje de una CNN

Fase	Proceso	Descripción
Preparación de datos		Se recopila un conjunto de datos de imágenes etiquetadas según sus categorías.
Preprocesamiento		Las imágenes se redimensionan y normalizan para facilitar el procesamiento eficiente por parte de la red.
Entrenamiento		La red se entrena utilizando el conjunto de datos. Durante este proceso, ajusta sus pesos para aprender a identificar características visuales importantes.
Validación		Después del entrenamiento, la red se valida con un conjunto de datos separado para verificar su rendimiento y ajustar parámetros si es necesario.
Evaluación		La red se evalúa utilizando un conjunto de datos de prueba para determinar su precisión en la clasificación de imágenes.
Despliegue		Una vez entrenada, validada y evaluada satisfactoriamente, la red se implementa en un entorno de producción para realizar tareas como reconocimiento de imágenes en tiempo real o análisis de datos visuales.

3.1.2.2. El proceso de visión de una CNN

El método de trabajo se fundamenta en la identificación de patrones en regiones específicas de la imagen en lugar de considerarla en su totalidad. En este sentido, el algoritmo selecciona un pequeño conjunto de píxeles (entrada) que atraviesan diversas capas ocultas dispuestas para un análisis progresivo (ver Figura 5). En otras palabras, las primeras capas de la red detectan rasgos simples como líneas, curvas y bordes, mientras que las capas más profundas son capaces de reconocer formas más complejas como personas, vehículos o animales. Como resultado, cuanto mayor sea el número de capas, mayor será la capacidad de visualización de la red y más precisa será su salida, que muestra la probabilidad de que una imagen pertenezca a una categoría predefinida para la cual la red ha sido entrenada.

Lo más destacado de este proceso es que, en cada capa, la red conecta las diferentes características de la imagen, utilizando esta información para aprender y mejorar su capacidad de reconocimiento, hasta identificar formas de alta complejidad en etapas avanzadas. A partir de este autoaprendizaje, es posible lograr un sistema autónomo al entrenar la red neuronal con una amplia gama de imágenes, lo que le permite generar su propia base de conocimiento. Una vez completada esta fase, el modelo de Deep Learning está preparado para enfrentarse a nuevas imágenes sin clasificación previa [55].




Figura 5. Proceso de visión de una CNN. [56]

3.1.2.3. Arquitectura de una CNN

Las Redes Neuronales Convolucionales (CNN) son un conjunto de herramientas que procesan y clasifican imágenes mediante una arquitectura de múltiples capas. La capa de entrada convierte cada píxel de la imagen en un nodo, iniciando el proceso. La capa convolucional, utilizando filtros o kernels, identifica patrones y crea mapas de características que destacan detalles como bordes y texturas. La capa de agrupación reduce la dimensionalidad de estos mapas para mejorar la eficiencia, mediante técnicas como "max pooling" o "average pooling". Finalmente, la capa completamente conectada o densa clasifica la imagen, asignando probabilidades a cada categoría mediante operaciones matemáticas. Las CNN integran estas capas con funciones de activación como ReLU o Softmax para transformar visualmente la imagen en una representación matemática, permitiendo la clasificación precisa y eficiente de imágenes. [57].

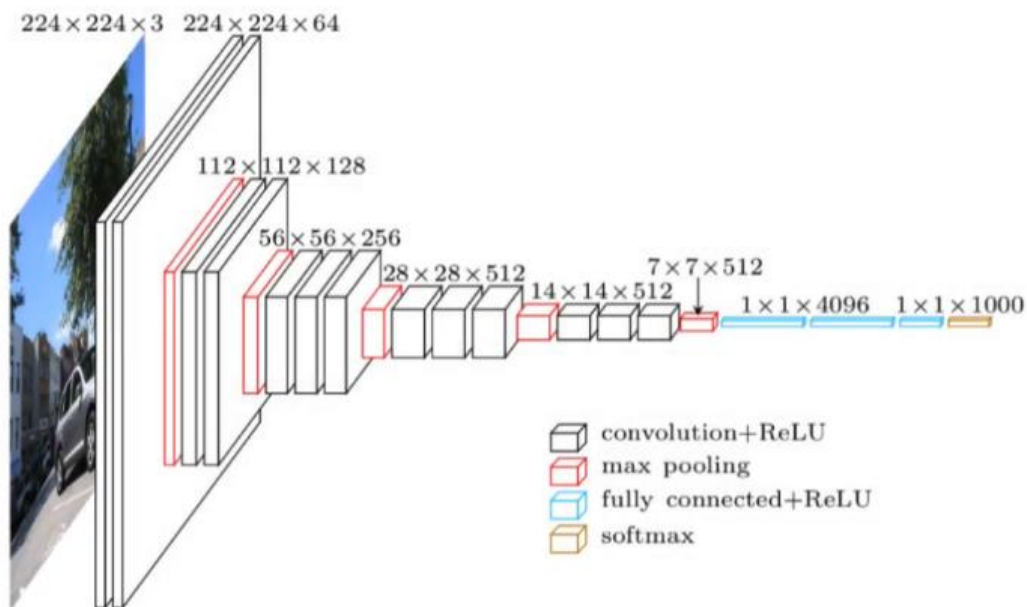


Figura 6. Proceso de Transformación y Activación en CNN. [58]

3.1.2.4. Funciones de activación más usadas

Las funciones de activación son un componente esencial en el diseño de redes neuronales artificiales, desempeñando un papel importante en la capacidad de la red para aprender y realizar complejas transformaciones de datos. Estas funciones ayudan a introducir no linealidades en el modelo, lo cual es vital para aprender y modelar relaciones complejas entre los datos de entrada y salida. Sin funciones de activación, una red neuronal no sería diferente de un modelo de regresión lineal, limitado a tareas simples que siguen una linealidad.

El propósito principal de las funciones de activación es convertir una entrada de nodo a una salida más manejable, como un rango entre 0 y 1 o -1 y 1. Actúan como compuertas en el flujo de información y cálculo a través de la red, afectando directamente la dinámica del aprendizaje y la capacidad de la red para converger hacia una solución eficaz.

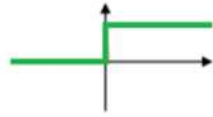
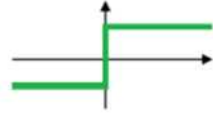
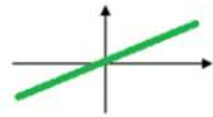

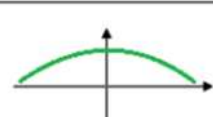
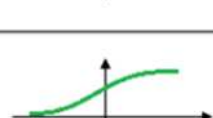



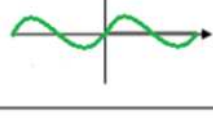
TIPO DE FUNCIÓN DE ACTIVACIÓN	ECUACIÓN	EJEMPLO O MODELO	GRÁFICO
Función "Step" o Heaviside	$\phi(z) = \begin{cases} 0 & z < 0 \\ 0.5 & z = 0 \\ 1 & z > 0 \end{cases}$	PERCEPTRÓN	
Función Signo	$\phi(z) = \begin{cases} -1 & z < 0 \\ 0 & z = 0 \\ 1 & z > 0 \end{cases}$	PERCEPTRÓN	
Función Lineal	$\phi(z) = z$	ADALINE	
Función lineal definida a trozos	$\phi(z) = \begin{cases} 1 & z \geq \frac{1}{2} \\ z + \frac{1}{2} & -\frac{1}{2} < z < \frac{1}{2} \\ 0 & z \leq -\frac{1}{2} \end{cases}$	MÁQUINAS DE VECTOR SOPORTE	
Función Gaussiana	$\phi(z) = Ae^{-Bz^2}$	REDES NEURONALES RBF	
Función Sigmoide o Logística (Curva "S")	$\phi(z) = \frac{1}{1 + e^{-z}}$	REDES NEURONALES MULTICAPA	
Tangente hiperbólica	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	REDES NEURONALES MULTICAPA	
Función rectificadora o función ReLU Unidad Lineal Rectificada	$\phi(z) = \max(0, z)$	REDES NEURONALES MULTICAPA	
Función Sinusoidal	$\phi(z) = A\sin(\omega z + \varphi)$	CLASIFICACIÓN DE PATRONES	
Función rectificadora suavizada (softplus)	$\phi(z) = \ln(1 + e^z)$	REDES NEURONALES MULTICAPA	

Figura 7. Funciones de activación de las CNN. [59]

3.1.2.5. Clasificación y distinción de imágenes mediante CNN

Las Redes Neuronales Convolucionales (CNN) son una variante de las redes neuronales artificiales que han demostrado ser particularmente efectivas en tareas de clasificación de imágenes. Su eficacia se puede atribuir a dos procesos fundamentales: la extracción de características y la clasificación.

Extracción de Características: Las CNN analizan las imágenes mediante una serie de capas, donde las capas convolucionales se encargan de aplicar filtros para detectar patrones específicos como bordes y texturas. A esto le siguen las capas de agrupación, que reducen la complejidad de la imagen al tiempo que preservan las características esenciales. Este proceso asegura que la red se concentre en los elementos más relevantes de la imagen.

Clasificación: Posteriormente, las características identificadas son analizadas por las capas completamente conectadas, que actúan como un clasificador, determinando la pertenencia de la imagen a una categoría específica basada en las probabilidades calculadas mediante funciones de activación. [60].

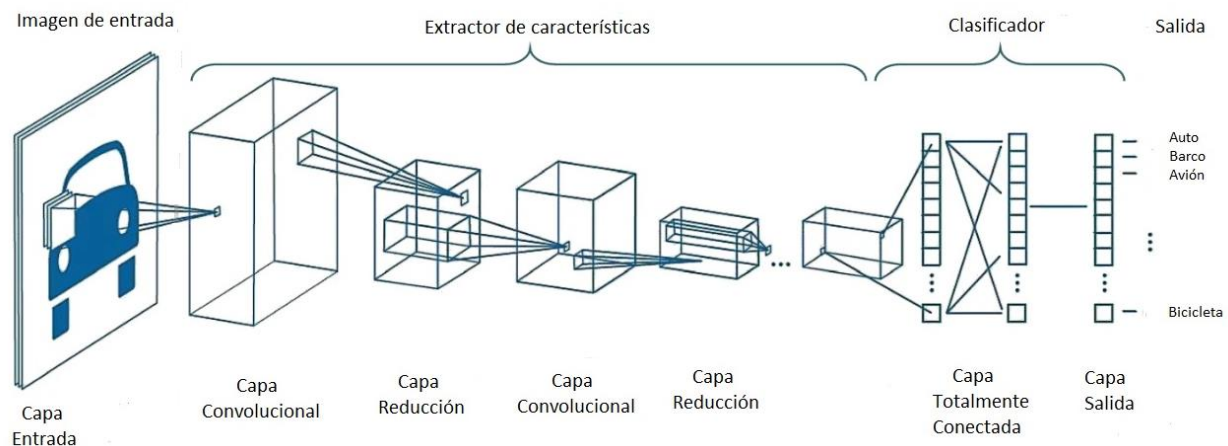
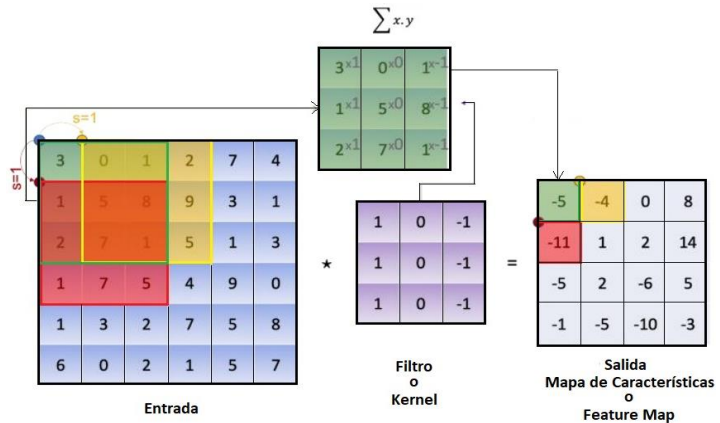
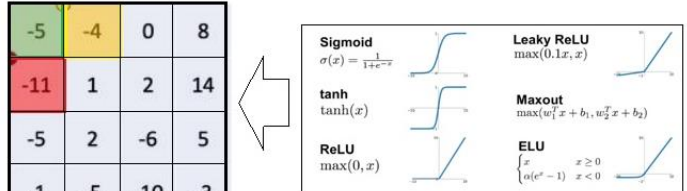
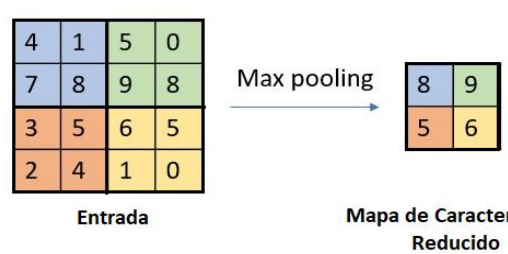


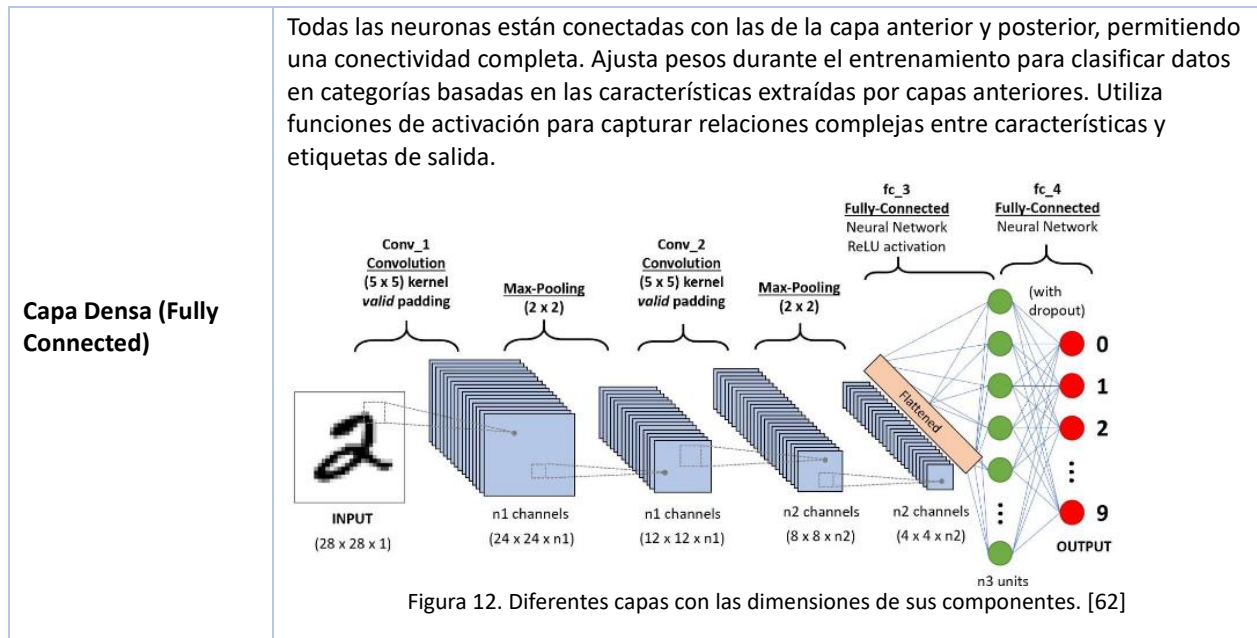
Figura 8. Clasificación de imágenes mediante CNN. [61]

3.1.2.6. Funcionamiento de una CNN

En la siguiente tabla se presenta un resumen del funcionamiento de una red neuronal convolucional CNN:

Tabla 3. Componentes Clave de las CNN y sus Funciones.

Capa	Descripción
<p>Capa Convolutiva</p>	<p>Utiliza filtros para realizar convoluciones en la imagen, detectando patrones como bordes y texturas. Cada filtro crea un mapa de características que resalta aspectos relevantes de la imagen.</p>  <p style="text-align: center;">Figura 9. Convolución. Elaboración propia.</p>
<p>Función de Activación</p>	<p>Aplicada al mapa de características para introducir no linealidad, facilitando la detección de patrones complejos. Ejemplos incluyen ReLU y Softmax.</p>  <p style="text-align: center;">Figura 10. Mapa de Características. Elaboración propia.</p>
<p>Capa de Reducción (Max Pooling)</p>	<p>Reduce el tamaño de la imagen manteniendo características esenciales, al seleccionar el valor máximo de regiones específicas (ej. 2x2), creando un mapa de características reducido. Esto ayuda a aligerar la carga computacional y evitar el sobreajuste.</p>  <p style="text-align: center;">Figura 11. Capa de Reducción. Elaboración propia.</p>



3.1.2.7. Entrenamiento de una CNN

El proceso de entrenamiento de una red neuronal convolucional (CNN) es fundamental para ajustar los parámetros de la red y permitirle aprender o realizar tareas específicas, como reconocimiento de imágenes, clasificación de objetos o segmentación semántica, entre otras. Este proceso se lleva a cabo a través de varias etapas, que son las siguientes:

Tabla 4. Proceso de entrenamiento de una CNN.

Etapa	Descripción
Inicialización de pesos	En esta etapa, se asignan valores iniciales aleatorios a los pesos de la red neuronal. Estos pesos son los parámetros que se ajustarán durante el entrenamiento para mejorar el rendimiento de la red en la tarea específica.
Paso hacia adelante (Forward pass)	Durante esta etapa, se propaga hacia adelante un conjunto de datos de entrenamiento a través de la red neuronal. Cada capa realiza operaciones matemáticas en los datos de entrada para generar una salida que se utiliza como entrada para la siguiente capa. Este proceso se repite hasta obtener una salida final.
Cálculo de la pérdida (Loss calculation)	Después del paso hacia adelante, se calcula la pérdida, una medida de cuán bien está realizando la red neuronal la tarea deseada en comparación con las salidas reales. La pérdida se calcula utilizando una función de pérdida específica, como la entropía cruzada para problemas de clasificación.
Retropropagación (Backpropagation)	En esta etapa, se calculan los gradientes de la función de pérdida respecto a los pesos de la red utilizando el algoritmo de retropropagación. Estos gradientes indican cómo

	cambiar los pesos para reducir la pérdida y se utilizan para actualizar los pesos de la red en la dirección correcta.
Optimización de los pesos (Weight optimization)	Una vez calculados los gradientes, se utilizan algoritmos de optimización, como el descenso del gradiente estocástico (SGD) o sus variantes, para actualizar los pesos de la red de acuerdo con los gradientes calculados. El objetivo es encontrar los pesos que minimicen la pérdida de manera eficiente.
Iteración	Estas etapas se repiten iterativamente para cada lote de datos de entrenamiento hasta que se alcanza un criterio de detención, como un número máximo de épocas o una mejora insuficiente en la pérdida de validación. Cada iteración del proceso de entrenamiento ayuda a la red neuronal a mejorar su rendimiento en la tarea específica.

El objetivo del entrenamiento es minimizar la función de pérdida, lo que implica que la red aprenda a realizar la tarea específica para la que fue diseñada con la mayor precisión posible. Una vez completado el entrenamiento, la red neuronal convolucional está lista para realizar predicciones sobre nuevos datos de entrada. Los beneficios del entrenamiento de CNN incluyen alta precisión en tareas de visión artificial, eficiencia al procesar imágenes de forma rápida y eficiente, y robustez ante cambios en la iluminación y las condiciones de la imagen. Sin embargo, también presenta limitaciones como la necesidad de grandes conjuntos de datos para un entrenamiento preciso, el tiempo prolongado de entrenamiento, especialmente en redes complejas, y la dificultad para interpretar cómo las CNN toman decisiones [63].

3.1.2.8. Métricas para evaluar un modelo de aprendizaje automático

Dentro del ámbito de la inteligencia artificial y el aprendizaje automático, una matriz de confusión se presenta como una herramienta esencial para visualizar el rendimiento de un algoritmo de aprendizaje supervisado. Se compone de cuatro categorías que resumen las diferentes posibilidades de acierto o error en las predicciones [64]:

		REAL	
		POSITIVO	NEGATIVO
PREDICCIÓN	POSITIVO	Verdadero Positivo (VP)	Falso Positivo (FP)
	NEGATIVO	Falso Negativo (FN)	Verdadero Negativo (VN)

Figura 13. Matriz de Confusión. Elaboración propia.

Verdadero positivo (VP): El modelo predice correctamente un valor positivo.

Verdadero negativo (VN): El modelo predice correctamente un valor negativo.

Falso negativo (FN): El modelo predice un valor negativo cuando el valor real es positivo (error tipo II).

Falso positivo (FP): El modelo predice un valor positivo cuando el valor real es negativo (error tipo I).

Métricas derivadas de la matriz de confusión

A partir de estas cuatro categorías, se pueden calcular diversas métricas para evaluar el rendimiento del modelo, estas métricas tienen como salida un valor de [0, 1].

Tabla 5. Métricas derivadas de la matriz de confusión

Métrica	Fórmula	Rango	Descripción	Valor Óptimo
Accuracy (Exactitud)	$(VP + VN) / (VP + FP + FN + VN)$	[0, 1]	Mide la proporción de predicciones correctas en todas las muestras.	Cuanto más cerca de 1, mejor.
Precision (Precisión)	$(VP) / (VP + FP)$	[0, 1]	Evalúa la proporción de predicciones positivas correctas entre todas las predicciones positivas.	Cuanto más cerca de 1, mejor. Importante cuando los falsos positivos son costosos.
Recall (Sensibilidad)	$(VP) / (VP + FN)$	[0, 1]	Representa la proporción de verdaderos positivos entre todas las instancias positivas reales.	Cuanto más cerca de 1, mejor. Importante cuando los falsos negativos son costosos.
Specificity (Especificidad)	$(VN) / (VN + FP)$	[0, 1]	Mide la proporción de verdaderos negativos entre todas las instancias negativas reales.	Cuanto más cerca de 1, mejor. Importante cuando los falsos positivos son costosos.

La matriz de confusión y sus métricas permiten analizar en detalle el comportamiento del modelo de clasificación, identificando áreas de mejora y posibles sesgos en las predicciones

F1 Score

El F1 Score es una métrica que combina la precisión y el recall de un modelo de clasificación en un solo número, utilizando su promedio armónico. Es especialmente útil cuando se necesita un balance entre precisión (la proporción de identificaciones positivas que fueron correctas) y recall (la proporción de positivos reales que fueron identificados correctamente). El F1 Score alcanza su mejor valor en 1 (precisión y recall perfectos) y el peor en 0. Ideal para situaciones donde los falsos positivos y falsos negativos son igualmente costosos.

Curva ROC

La Curva ROC (Receiver Operating Characteristic) es una herramienta gráfica utilizada para evaluar la capacidad de discriminación de un modelo de clasificación binaria. Esta curva representa la relación entre la tasa de verdaderos positivos (sensibilidad) y la tasa de falsos positivos (1 - especificidad) a diferentes umbrales de decisión. Un área bajo la curva ROC (AUC) grande indica un buen rendimiento del modelo en distinguir entre las clases positivas y negativas. Una curva ROC que se acerca a la esquina superior izquierda indica una mejor efectividad del modelo [65].

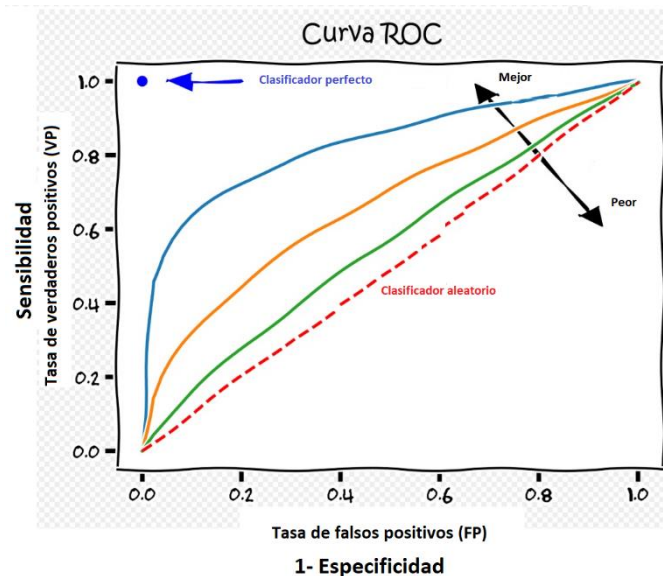


Figura 14. Tipos de curvas ROC. [66]

3.1.2.9. Ajustes al modelo de aprendizaje automático

Para ajustar un modelo de aprendizaje automático cuyas métricas no son del todo favorables, se pueden tener en cuenta los siguientes aspectos para mejorar su rendimiento.

Tabla 6. Aspectos a tener en cuenta para mejorar el rendimiento de una CNN.

Categoría	Subcategoría	Detalles
Análisis de Datos	-	Revisar y entender los datos utilizados para el entrenamiento del modelo, identificando problemas como datos faltantes, desequilibrios en las clases, o presencia de ruido.
Preprocesamiento	-	Revisar y entender los datos utilizados para el entrenamiento del modelo, identificando problemas como datos faltantes, desequilibrios en las clases, o presencia de ruido.

Hiperparámetros	Número de Capas y Neuronas	- Profundidad de la Red: Número de capas convolucionales, de agrupación y completamente conectadas. - Ancho de la Red: Número de neuronas por capa.
	Tamaño del Filtro (Kernel)	Tamaño común: 2x2, 3x3, 5x5, 7x7.
	Stride (Paso)	Controla el desplazamiento del filtro en cada paso de convolución.
	Padding (Relleno)	Agregar píxeles alrededor de la imagen de entrada antes de la convolución.
	Funciones de Activación	Ejemplos: ReLU, Leaky ReLU, tanh.
	Pooling (Agrupación)	Opciones: max pooling, average pooling.
	Tasa de Aprendizaje	Valores típicos: 0.0001, 0.001, 0.01.
	Regularización	Técnicas: L1, L2, Dropout.
	Batch Size	Valores comunes: 32, 64, 128.
	Épocas (Epochs)	Define la cantidad de veces que el modelo ve el conjunto de datos durante el entrenamiento.
	Optimizador	Adam, RMSProp, SGD, etc.
	Inicialización de Pesos	Métodos: Xavier/Glorot, He initialization.
Optimización de Hiperparámetros	GridSearch	Evaluación exhaustiva de todas las combinaciones posibles de hiperparámetros. Ejemplo: uso de GridSearchCV en Scikit-Learn.
	RandomSearch	Selección aleatoria de valores dentro de rangos definidos para hiperparámetros. Ejemplo: uso de RandomizedSearchCV en Scikit-Learn.
Regularización	L1 (Regresión de Lasso)	Penalización igual al valor absoluto de la magnitud de los coeficientes.
	L2 (Regresión Ridge)	Penalización igual al cuadrado de la magnitud de los coeficientes.
Validación Cruzada	-	Utilizada para estimar el rendimiento del modelo en diferentes conjuntos de datos de entrenamiento y validación.
Ingeniería de Características	-	Exploración y creación de nuevas características que puedan mejorar el rendimiento del modelo.
Selección de Modelo	-	Prueba de diferentes algoritmos de aprendizaje automático para determinar cuál se adapta mejor al problema.
Ensemble Learning	-	Técnicas para combinar múltiples modelos y mejorar el rendimiento general del sistema.
Análisis de Errores	-	Identificación de patrones comunes en los errores cometidos por el modelo y áreas de mejora.
Reentrenamiento y Evaluación	-	Reajuste del modelo con los datos completos y evaluación del rendimiento mediante métricas adecuadas.
Iteración	-	Repetición del proceso de ajuste y evaluación hasta alcanzar un modelo satisfactorio.

3.1.2.10. Diferencia entre Parámetros e hiperparámetros

En aprendizaje automático, los términos parámetros e hiperparámetros son fundamentales para comprender cómo funcionan los modelos. Los parámetros son las variables internas de un modelo que se aprenden automáticamente durante el entrenamiento, como los pesos y sesgos en una red neuronal. Por otro lado, los hiperparámetros son las configuraciones externas del modelo que no se aprenden durante el entrenamiento y deben ser definidas antes del proceso de aprendizaje; ejemplos de estos incluyen la tasa de aprendizaje, el número de capas en una red neuronal o el tamaño de lote.

3.2. ANTECEDENTES

Existe un interés creciente desde los investigadores y los médicos en desarrollar algoritmos de aprendizaje automático (ML) para detectar/predecir ISO. Sin embargo, se sabe poco sobre el rendimiento general de estos y cómo mejorarlos, razón por la cual se han realizado recientemente varios estudios importantes relacionados con el uso de algoritmos de aprendizaje automático para la detección y predicción de infecciones del sitio operatorio (ISO) y otras evaluaciones relacionadas con heridas quirúrgicas.

En la tabla 7 se resumen los principales estudios que emplean técnicas de machine learning o deep learning para clasificación de imágenes heridas quirúrgicas. Los registros fueron obtenidos a partir de la búsqueda y selección en las bases de datos IEEE, Medline/Pubmed y EMBASE, con los términos clave “machine learning”, “deep learning”, “convolutional neural networks”, “CNN”, “surgical wounds” y “classification”.

Tabla 7. Estudios relacionados con clasificación de imágenes de heridas.

Ref.	Autor	Año	Tipo de heridas quirúrgicas	Metodología	Resultados de las métricas
[67]	Wang	2015	Heridas crónicas 8000 imágenes de NYU Data Base	CNN (ConvNet) para segmentación y análisis	Exactitud Pixel = 95.0%, IoU medio = 47.3%
[68]	Shenoy	2018	Heridas quirúrgicas diversas 1335 imágenes	CNN basados en VGG16	Para Infección (ISO): Exactitud = 0.84, Sensibilidad = 0.70, Especificidad = 0.70, F1 Score = 0.70

[69]	Fletcher	2019	Heridas de cesárea 568 imágenes	“Gabor wavelet análisis” + Clasificación con SVM	Exactitud AUC = 99.5%, Sensibilidad = 0.99, Especificidad = 0.99
[70]	Rostami	2021	Heridas agudas y crónicas, diversas	Clasificador basado en Deep CNN, Ensemble Deep CNN	Exactitud máxima y promedio de 96.4% y 94.28% para clasificación binaria; 91.9% y 87.7% para clasificación de 3 clases
[71]	Fletcher	2021	Heridas de cesárea 512 imágenes	CNN, Transfer Learning	Naive CNN: AUC = 0.655, Sensibilidad = 0.75, Especificidad = 0.58; ResNet50: AUC = 0.639, Sensibilidad = 0.92, Especificidad = 0.18
[72]	Zhao	2023	Heridas quirúrgicas diversas	ResNet101, SE- ResNet101, ResNet50, SE- ResNet50	Exactitud promedio: 0.941, 0.903, 0.896, 0.918; Recall: 0.930, 0.880, 0.850, 0.894; con SE-ResNet101 mostrando la mayor precisión promedio de 0.941
[73]	Pereira	2023	Heridas cardioráxicas	MobileNet-Unet para segmentación, Random Forest, SVM, K-NN para clasificación	Segmentación: IoU promedio de 89.9%, Exactitud promedio de 90.1%; Clasificación: mejor resultado con el clasificador de heridas en piernas: Sensibilidad de 87.6%, Exactitud de 52.6%

Adicionalmente, la revisión sistemática reciente de Tabja et al [39], con 10 estudios sobre Machine Learning para diagnóstico de infección de heridas quirúrgicas basado en imágenes, encontró importante heterogeneidad en los resultados, variabilidad en la captura de imágenes, falta de estandarización en el desarrollo de modelos y la fuente de datos, además de alto riesgo de sesgos y ausencia de validación externa en todos los casos.

A pesar de las limitaciones y desafíos, los estudios demuestran la viabilidad y el potencial de los algoritmos de ML y CNN en la clasificación y detección de complicaciones en heridas quirúrgicas,

destacando la importancia de estas tecnologías en mejorar el diagnóstico y tratamiento en la práctica clínica.

4. CONSTRUCCIÓN DE UNA BASE DE DATOS DE IMÁGENES DIGITALES ETIQUETADAS DE HERIDAS QUIRÚRGICAS

4.1. DEFINICIÓN DE LOS CRITERIOS DE SELECCIÓN

En esta actividad, se definieron los tipos de heridas quirúrgicas que se incluyeron en la base de datos, sus características y sus atributos de calidad. Se consideró incluir inicialmente sólo heridas de intervenciones cardiotorácicas en cirugía cardiovascular. Sin embargo, debido a la reducida cantidad de imágenes disponibles de este tipo de cirugías, se incluyeron heridas también de extremidades para enriquecer la base de datos.

En la evaluación de las heridas quirúrgicas se establecieron dos categorías o clases a saber: 'alteradas' y 'no alteradas'. Esta clasificación, soportada en la literatura, es esencial para detectar y advertir cambios en las heridas asociados a ISO, hematoma y/o alteraciones en la cicatrización. No se pretendió como tal establecer el diagnóstico de ISO puesto que para éste se requiere combinar variables clínicas y microbiológicas no disponibles en la data. Como elementos de juicio para considerar “herida alterada” se encuentran:

- Cambios en los bordes como dehiscencia parcial o completa
- Cambios en la coloración y densidad como enrojecimiento y edema
- Cambios de sufrimiento cutáneo/necrosis como piel oscura o negra
- Cambios que indican secreción por la herida (drenaje purulento, hemático, etc.)

4.1.1. Definir las características de las imágenes que se incluirán en la base de datos

Características de Calidad de las Imágenes

Tabla 8. Criterios de Calidad para la Captura de Imágenes de Heridas Quirúrgicas

Característica	Descripción
Claridad	Las imágenes deben ser claras y corresponder específicamente a los segmentos con heridas quirúrgicas, siendo fáciles de interpretar.
Contraste	Deben tener buen contraste para que los detalles sean claramente visibles.
Escala	Deben mantener una escala adecuada para su análisis detallado.

Visibilidad	Las heridas deben estar visibles sin estar cubiertas por apósitos, parches o cremas que impidan la visibilidad.
Iluminación	Las imágenes no deben ser borrosas ni tener iluminación pobre que dificulte la visualización clara.

Requisitos de Formato y Resolución de las Imágenes

Tabla 9. Especificaciones Técnicas para el Formato de Imágenes

Requisito	Especificación
Dimensiones mínimas	500 píxeles de ancho por 500 píxeles de alto.
Resolución mínima	300 puntos por pulgada (ppp).
Formatos admitidos	.jpg, .jpeg, .png, .gif, .JPG, .JPEG, .PNG, .GIF

4.2. IDENTIFICACIÓN DE FUENTES CONFIABLES

En esta fase, se identificaron fuentes confiables de imágenes de heridas quirúrgicas. Se efectuaron búsquedas en repositorios (UCI, Kaggle), bases de datos (artículos de referencia con proyectos similares) y se contactaron instituciones médicas y organizaciones de salud pública. Fue el Instituto del Corazón de Bucaramanga que con su mayor disposición facilitó el acceso a los archivos de 5540 imágenes digitales, previos avales del director(e) de Cardiología y Ciencias Cardiovasculares, el Comité de Ética e Investigación (CEIN) de la IPS y la firma de los respectivos acuerdos de confidencialidad por los tres investigadores. Todos estos soportes se incluyen como anexos.

4.2.1. Aspectos éticos

Cabe mencionar en este apartado que se están cumpliendo a cabalidad los lineamientos éticos en investigación toda vez que los archivos de las imágenes digitales (tomadas por la IPS, con aval de los pacientes, como parte del proceso de atención y seguimiento de los pacientes quirúrgicos) han sido facilitadas de forma anonimizada (código alfanumérico) de tal manera que es imposible identificar a los pacientes. Así mismo, las imágenes muestran heridas de segmentos corporales, específicamente esternotomías, bolsillos de dispositivos en tórax y safenectomías. No se presenta ninguna imagen que pueda identificar al paciente.

Además, se implementaron rigurosas medidas de seguridad informática para proteger los datos y se siguieron normativas internacionales sobre la protección de datos personales en la investigación médica. Estas prácticas son fundamentales no solo para cumplir con los requisitos legales, sino también para mantener la confianza pública en la investigación médica y asegurar la integridad del proceso científico.

4.3. RECOPIACIÓN Y ORGANIZACIÓN DE LAS IMÁGENES

En esta actividad, se recopilaron y organizaron las imágenes de acuerdo con los criterios establecidos. Se descargaron las imágenes de las fuentes indicadas y se almacenaron en un sistema de archivos organizado. También se etiquetaron las imágenes de acuerdo con los criterios definidos.

4.3.1. Base de datos de imágenes de heridas quirúrgicas

Se logró recopilar una base de datos de imágenes de heridas quirúrgicas con 5.540 imágenes proporcionadas por el Instituto del Corazón de Bucaramanga, correspondientes a los años 2017, 2020, 2021, 2022 y 2023. Las imágenes se recibieron sin etiquetar y sin preprocesar.

No fue posible delimitar las características sociodemográficas de los pacientes, pues no se contaba con datos específicos más allá de las imágenes. La fuente institucional sí resaltó que los pacientes, todos adultos (se excluyeron imágenes de niños), tanto hombres como mujeres, procedían, fundamentalmente, de Bucaramanga y su área metropolitana, donde prevalece la raza mestiza. Esto implica, en un contexto de muestreo no probabilístico o por conveniencia (se usó la data disponible en el momento), que no se encontraron pacientes afrocolombianos, lo que limita, de antemano, la generalización de los resultados a población diferente a la local .

Anonimización de las imágenes

Para proteger la privacidad de los pacientes, las imágenes se han anonimizado mediante un código alfanumérico. El código consta de un prefijo de tres letras seguido de cinco números secuenciales. Por ejemplo, la primera imagen se denominó "AJA00001", la segunda "AJA00002", y así sucesivamente.



Figura 15. Ejemplo de anonimización de las imágenes. Elaboración propia.

4.4. PREPARACIÓN DE LOS DATOS PARA EL ANÁLISIS DE IMÁGENES

4.4.1. Limpieza del dataset

Se realizó una revisión exhaustiva de la base de datos de imágenes de heridas utilizando un visualizador de fotos, descartando las imágenes que no cumplieran con los estándares de calidad establecidos. Las imágenes rechazadas fueron revisadas nuevamente para confirmar su exclusión o reincorporación al conjunto de datos.

Posteriormente, se examinaron las imágenes para identificar y eliminar duplicados y así evitar sesgos en el análisis. No obstante, las secuencias de imágenes del mismo paciente tomadas desde distintos ángulos y distancias se mantuvieron al considerar que no comprometían la calidad.

Como resultado de esta revisión, se clasificaron las imágenes en categorías de 'buenas' y 'malas' (Figura 16). Se desarrolló un script para automatizar la separación de imágenes desde la base de datos original hacia dos carpetas distintas, optimizando el proceso y reduciendo la carga en la red. A continuación, se detalla el resultado de esta separación:

- Imágenes buenas: 3574
- imágenes malas: 1996

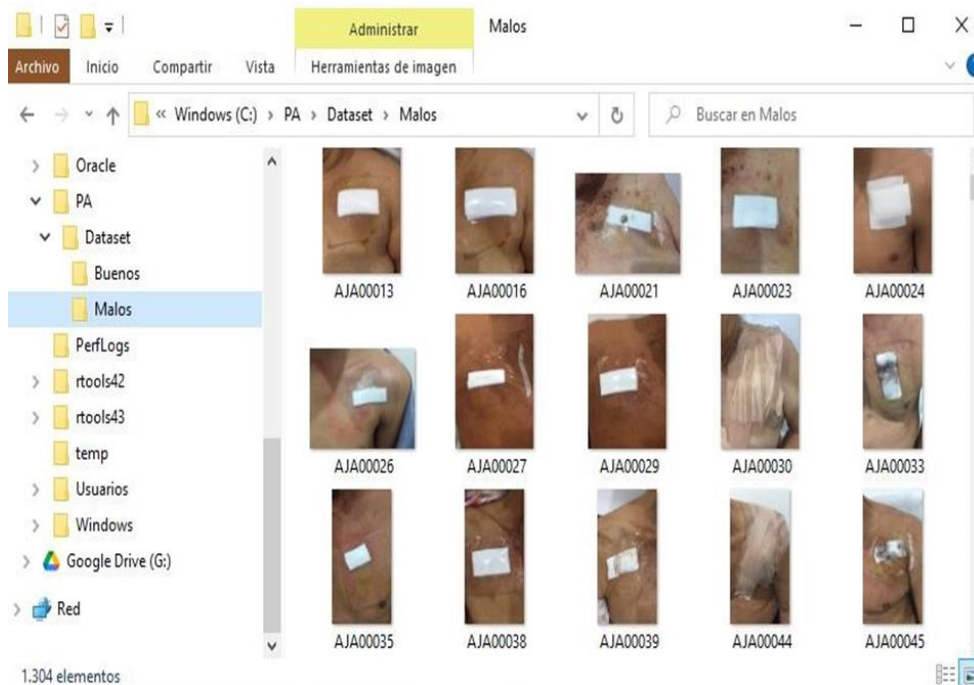


Figura 16. Ejemplo de separación de las imágenes. Elaboración propia.

4.4.2. Etiquetado de las imágenes

Tres profesionales con experiencia en cuidado de heridas quirúrgicas del Departamento de Cirugía Cardiovascular del Instituto del Corazón de Bucaramanga, incluyendo dos instrumentadoras y una enfermera jefa, colaboraron ad honorem en este proyecto. Las instrumentadoras realizaron de manera independiente un etiquetado inicial de las imágenes, alcanzando un índice de acuerdo kappa de 0.66. En los casos de desacuerdo, la enfermera jefa intervino para finalizar la clasificación de todas las heridas. Como resultado, se creó una base de datos con 2,126 imágenes etiquetadas como 'alteradas' y 1,448 como 'no alteradas'. A continuación, se presentan ejemplos de imágenes etiquetadas de cada categoría.



Figura 17. Ejemplo de imágenes etiquetadas. Elaboración propia.

4.4.3. Segmentación de las imágenes anonimizadas

La segmentación de las imágenes se realizó en dos etapas: primero definiendo el área de interés o segmento a extraer de la imagen original y luego generando nuevas imágenes solo con los segmentos del área de interés.

Para definir el segmento a extraer se utilizó una herramienta desarrollada en Python de uso libre llamada Labellmg. Esta herramienta es utilizada para localizar áreas de interés dentro de una imagen y colocarle una etiqueta (esta etiqueta es solo un nombre que se asocia al segmento y no está relacionada con las etiquetas descritas en el numeral anterior) a cada una de las áreas demarcadas. Además, su interfaz permite conocer el tamaño del segmento seleccionado y cambiarle el tamaño si es necesario. La salida de este proceso, para cada imagen, es un archivo con formato xml que tiene las características de los segmentos señalados en la imagen como nombre, coordenadas de inicio y fin, formato, y la etiqueta colocada al segmento.

La figura siguiente ilustra el proceso de definición de los segmentos a extraer de una imagen de heridas de un paciente. En este ejemplo específico, la imagen muestra varias heridas, cada una de las cuales contribuye con distintos segmentos a la base de datos segmentada.




Figura 18. Ejemplo de definición de los segmentos de las imágenes. Elaboración propia.

Para extraer los segmentos de cada imagen se desarrolló un código en Python que lee los archivos xml y luego genera nuevas imágenes desde las imágenes originales de la base de datos, con las características encontradas en el archivo xml y con el tamaño definido para el proyecto que fue de 300 píxeles de ancho x 300 píxeles de alto. El resultado de esta tarea fue una base de datos de segmentos de imagen que corresponden al área de interés de cada imagen. Esta base de datos de segmentos, ya etiquetados, fue la que se utilizó en los modelos de aprendizaje profundo que se describen en los siguientes capítulos.

Durante el proceso de segmentación con labelImg fue necesario contar nuevamente con el apoyo de la enfermera jefe pues una cantidad importante de heridas de las dos categorías incluyeron múltiples segmentos independientes (ver figura 28) y/o eran potencialmente mixtas o ambiguas (combinaciones de segmentos alterados y no alterados). Previa instrucción a la enfermera sobre el uso de la herramienta se logró la sub-segmentación y reclasificación final con más imágenes, configurándose un dataset definitivo no balanceado de 4894 imágenes, 2783 no alteradas y 2131 alteradas.

4.4.4. Balanceo de la base de datos

Una vez finalizada la preparación de las imágenes en la base de datos, se llevó a cabo el balanceo de clases mediante un subsample manual. Esta tarea fue realizada por la enfermera jefe, quien eliminó imágenes (segmentos) que presentaron defectos residuales de calidad debido a manipulaciones previas. Como resultado, se logró un conjunto equilibrado con 2,131 imágenes alteradas y 2,131 no alteradas, sumando un total de 4,262 imágenes.

Este conjunto de datos balanceado quedó listo para la siguiente etapa del proceso, la fase de entrenamiento de modelos. Durante el entrenamiento, se aplicarán técnicas de aprendizaje profundo para desarrollar modelos predictivos que puedan identificar y clasificar con precisión las heridas quirúrgicas en las categorías alteradas y no alteradas. Este paso es importante para validar la efectividad del balanceo de clases y la adecuada preparación de los datos. Además, en un capítulo posterior se evaluarán los modelos para asegurar su rendimiento óptimo antes de su aplicación en entornos clínicos reales."

5. IMPLEMENTACIÓN Y ENTRENAMIENTO DE ALGORITMOS DE MACHINE LEARNING (ML) Y DEEP LEARNING (DL)

En la selección de metodologías para la identificación de alteraciones en heridas quirúrgicas mediante imágenes, se ha optado por utilizar Redes Neuronales Convolucionales (CNN) debido a su robustez y eficacia comprobada en tareas de procesamiento y clasificación de imágenes médicas en diferentes estudios [74-77]. Asimismo, la literatura es limitada en cuanto a estudios de clasificación de imágenes de heridas quirúrgicas con CNN [39], lo cual motivó la inclinación a emplearlas como base del proyecto.

Las CNN son particularmente adecuadas para nuestro proyecto porque permiten un aprendizaje automático profundo y directo de los datos visuales, sin necesidad de intervención manual en la extracción de características. Esto reduce la posibilidad de sesgos y mejora la precisión del modelo.

Este capítulo incluye los procesos de implementación y entrenamiento los cuales son la base para la selección y evaluación posterior tanto de los modelos personalizados como de las arquitecturas pre entrenadas que podrían ser utilizados en la solución propuesta.

Finalmente, se exploraron técnicas de optimización y ajuste de hiperparámetros para asegurar que los modelos finales logren el equilibrio adecuado entre exactitud y generalización, minimizando el riesgo de sobreajuste. El proceso incluyó técnicas de regularización para evaluar la robustez de los modelos en diferentes conjuntos de datos.

5.1. ESTUDIO DE ALGORITMOS

5.1.1. Evaluación Comparativa de Modelos y Arquitecturas de CNN para la Clasificación de Imágenes

Durante la revisión, no se identificaron fuentes de datos ni códigos abiertos específicos sobre modelos de aprendizaje profundo para la clasificación de imágenes digitales de heridas quirúrgicas. Sin embargo, se encontraron algunas reseñas sobre arquitecturas de CNN empleadas en los procesos de segmentación y clasificación dentro del contexto de "transfer learning". Algunas de las arquitecturas ampliamente utilizadas en la literatura incluyen VGG16, ResNet, Inception (GoogleNet), MobileNet.

Se aclara que dentro del proceso de Transfer Learning, se empleó Feature Extraction (extracción

de características) en lugar de Fine -Tuning, siendo considerado este último para trabajos futuros dados los alcances del proyecto.

Se realizó un ejercicio de comparación entre diferentes modelos y arquitecturas de aprendizaje profundo ("benchmarking"). El objetivo fue identificar el modelo con las mejores métricas de desempeño, considerando como factores diferenciadores el número de capas de la red y la cantidad de neuronas en cada una. Además, se realizaron pruebas con diversas combinaciones de hiperparámetros, como el optimizador y su tasa de aprendizaje, el número de épocas, lotes y funciones de activación, entre otros, para optimizar así los resultados de clasificación.

5.2. ENTRENAMIENTO DE DIFERENTES MODELOS Y ARQUITECTURAS

En el marco de este proyecto como se mencionó anteriormente, se implementó el entrenamiento de diversos modelos de redes neuronales convolucionales (CNN) para clasificar imágenes de heridas quirúrgicas. Inicialmente, se desarrolló un modelo basado en una arquitectura CNN básica, denominado Modelo 1. Posteriormente, se crearon y entrenaron tres modelos adicionales -Modelo 2, Modelo 3 y Modelo 4-, cada uno incorporando ajustes específicos sobre la arquitectura inicial para explorar diferentes capacidades de aprendizaje.

Además de estos cuatro modelos basados en una arquitectura CNN personalizada, se evaluaron arquitecturas avanzadas (Feature Extraction) diseñadas específicamente para tareas de visión por computadora, incluyendo VGG16, ResNet, Inception (GoogleNet) y MobileNet. Estas arquitecturas fueron seleccionadas por su eficiencia en procesar y detectar características complejas en la clasificación de imágenes.

Cada modelo y arquitectura se sometió a cinco ejecuciones independientes de entrenamiento para garantizar la consistencia y fiabilidad de los resultados. Sin embargo, sólo se muestran las gráficas de Accuracy (Exactitud) y Loss (pérdida) con el mejor rendimiento por modelo debido a la gran cantidad de datos y gráficos generados. Además, se incluyen resúmenes estadísticos de todas las ejecuciones resaltando la mejor ejecución, proporcionando una visión integral de la variabilidad y el comportamiento del modelo bajo diferentes hiperparámetros.

Para efectos de entrenamiento de los modelos y evaluación de las arquitecturas, se crearon etiquetas binarias, asignando 1 a las imágenes alteradas y 0 a las no alteradas. Luego, estas imágenes y etiquetas se combinaron a través de concatenación. Posteriormente, el conjunto de datos resultante se dividió en subconjuntos de entrenamiento (80%) y validación (20%). Luego, se normalizaron los valores de los píxeles de las imágenes, dividiéndolos por 255 para convertirlos a un rango de 0 a 1, lo cual es un paso común en el preprocesamiento de imágenes para modelos de aprendizaje automático. Finalmente, se define el número de clases en el modelo, que en este caso son dos, correspondientes a las categorías de imágenes alteradas y no alteradas.

La evaluación de cada modelo se llevó a cabo usando un conjunto de datos de prueba independiente, midiendo Accuracy (exactitud), Precision (Precisión o valor predictivo positivo), Recall (Sensibilidad), F1 Score, AUROC (área bajo la curva ROC), Specificity (especificidad). Se utilizaron los términos en inglés para estandarizar los nombres de las métricas dentro del proyecto.

5.2.1. Modelo 1: tres capas convolucionales

Arquitectura: Modelo de una red neuronal convolucional (CNN) construida con la API Sequential de Keras, diseñada principalmente para tareas de clasificación binaria de imágenes, el modelo está constituido de tres capas convolucionales. A continuación, se presenta de manera tabular la arquitectura.

Tabla 10. Estructura de la Red Neuronal Convolucional para Clasificación Binaria – Modelo 1


Capa	Filtros	Tamaño del filtro	Función de activación	Regularización	Otros detalles
Entrada	-	-	-	-	Imagen de 300x300 píxeles, 3 canales
1ª capa convolucional	32	3x3	ReLU	L1(0.0001), L2(0.0001)	-
Pooling	-	2x2	-	-	MaxPooling
2ª capa convolucional	64	3x3	ReLU	L1(0.0001), L2(0.0001)	-
Pooling	-	2x2	-	-	MaxPooling
3ª capa convolucional	128	3x3	ReLU	L1(0.0001), L2(0.0001)	-
Pooling	-	2x2	-	-	MaxPooling
Flatten	-	-	-	-	Aplana los mapas de características en un vector
Capa densa	-	-	ReLU	L1(0.0001), L2(0.0001)	512 neuronas
Dropout	-	-	-	-	Tasa de dropout del 40%
Capa de salida	-	-	Sigmoide	-	Una neurona, clasificación binaria

Entrenamiento: Los hiperparámetros utilizado en el entrenamiento del modelo son los siguientes:

Tabla 11. Parámetros de Entrenamiento para el Modelo 1 de Clasificación Binaria

Aspecto	Detalles
Optimizador	Adam
Tasa de aprendizaje	0.0001
Función de pérdida	Binary Crossentropy
Métrica de rendimiento	Exactitud (Accuracy)
Tamaño del lote	64 imágenes
Número de épocas	100
Descripción	Ajuste de pesos mediante cálculo adaptativo de las tasas de aprendizaje; el modelo aprende gradualmente minimizando la pérdida a través de múltiples pasadas.

Resultados de la mejor ejecución:



Accuracy: 0.8065650463104248
Precision: 0.8413978494623656
Recall: 0.747016706443914
F1 Score: 0.7914032869785083
AUROC: 0.8921450018147222
Specificity: 0.8640552995391705

Figura 19. Análisis de desempeño del Modelo 1

Curvas de pérdida (Loss)

- La pérdida de entrenamiento y la pérdida de validación disminuyen drásticamente al inicio y luego se estabilizan alrededor de un valor bajo.
- Ambas curvas convergen hacia un valor cercano a 0.5.

- La convergencia de las curvas de pérdida de entrenamiento y validación sin grandes discrepancias indica que el modelo generaliza bien, sugiriendo que no hay sobreajuste significativo.

Curvas de exactitud (Accuracy)

- La exactitud de entrenamiento y validación aumenta rápidamente al inicio y luego se estabiliza alrededor de 0.80.
- Las curvas de exactitud de entrenamiento y validación se mantienen relativamente cercanas, aunque con algunas fluctuaciones.
- La cercanía entre las curvas de exactitud sugiere una buena generalización. Sin embargo, las fluctuaciones indican que podría haber algunas variaciones en el rendimiento del modelo.

Análisis de las métricas

Tabla 12. Evaluación de Rendimiento del Modelo 1

Métrica	Valor	Descripción
Accuracy	0.8067	Muestra que el modelo clasifica correctamente la mayoría de las muestras.
Precision	0.8414	Buena precisión, indicando que la mayoría de las predicciones positivas son correctas.
Recall	0.7470	Sensibilidad aceptable, sugiriendo que el modelo identifica correctamente una cantidad considerable de muestras positivas.
F1 Score	0.7914	Un F1 Score razonable que indica un buen equilibrio entre precisión y sensibilidad.
AUROC	0.8921	Un valor alto de AUROC indica una buena capacidad del modelo para distinguir entre las clases.
Specificity	0.8641	Alta especificidad, lo que muestra que el modelo identifica correctamente la mayoría de las muestras negativas.

El modelo de redes neuronales convolucionales muestra un rendimiento aceptable con buenas métricas de precisión y especificidad, y un F1 Score razonable. Las curvas de pérdida y exactitud indican buena generalización, aunque con algunas fluctuaciones en la exactitud de validación que sugieren que podría beneficiarse de ajustes adicionales. En general, el modelo demuestra ser efectivo en la tarea de clasificación, mostrando un equilibrio adecuado entre precisión, sensibilidad y capacidad para distinguir entre clases.

Resumen estadístico de las cinco ejecuciones para el Modelo 1

Tabla 13. Resumen de Resultados de Validación por Ejecución para el Modelo 1

	Ejecución	Val Acc (mejor)	Epoca (Mejor Val Acc)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
Modelo 1	1	0,8077	90	0,8065	0,8640	0,7470	0,0000	0,7914	0,8921
	2	0,8136	100	0,8135	0,9107	0,7115	0,8835	0,7882	0,8787
	3	0,8089	93	0,7971	0,8201	0,7752	0,8184	0,7962	0,8849
	4	0,8171	99	0,8018	0,8752	0,7316	0,8598	0,7905	0,8814
	5	0,8136	99	0,8124	0,8196	0,8048	0,8087	0,8067	0,8909
	Promedio	0,8122		0,8063	0,8579	0,7540	0,6741	0,7946	0,8856
	Desviación Est.	0,0034		0,0062	0,0347	0,0328	0,3381	0,0066	0,0052

5.2.2. Modelo 2: cinco capas convolucionales

Arquitectura: Modelo de una red neuronal convolucional (CNN) construida con la API Sequential de Keras, diseñada principalmente para tareas de clasificación binaria de imágenes, el modelo está constituido de cinco capas convolucionales. A continuación se presenta de manera tabular la arquitectura.

Tabla 14. Estructura de la Red Neuronal Convolucional para Clasificación Binaria – Modelo 2

Tipo de Capa	Filtros	Tamaño del Kernel	Relleno	Función de Activación	Regularización	Tasa de Dropout	Descripción Adicional
Entrada	-	-	-	-	-	-	Entrada de imágenes de 300x300x3
Capa Conv. 1	16	3x3	Same	ReLU	L1(0.0001), L2(0.0001)	-	-
MaxPooling	-	2x2	-	-	-	-	Reducción dimensional
Capa Conv. 2	32	3x3	Same	ReLU	L1(0.0001), L2(0.0001)	-	-
MaxPooling	-	2x2	-	-	-	-	Reducción dimensional
Capa Conv. 3	64	3x3	Same	ReLU	L1(0.0001), L2(0.0001)	-	-

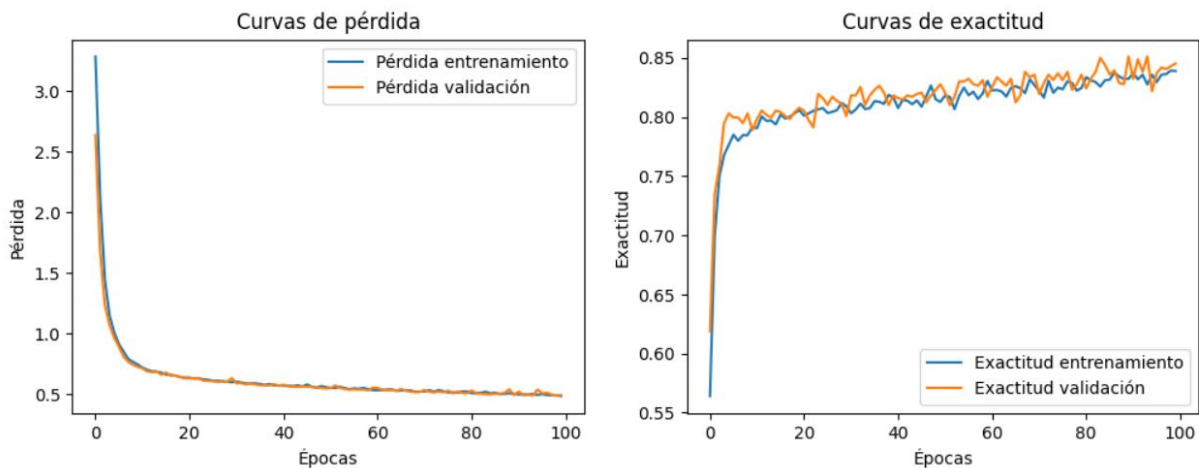
MaxPooling	-	2x2	-	-	-	-	Reducción dimensional
Capa Conv. 4	128	3x3	Same	ReLU	L1(0.0001), L2(0.0001)	-	-
MaxPooling	-	2x2	-	-	-	-	Reducción dimensional
Capa Conv. 5	256	3x3	Same	ReLU	L1(0.0001), L2(0.0001)	-	-
MaxPooling	-	2x2	-	-	-	-	Reducción dimensional
Dropout	-	-	-	-	-	0.5	Prevención de sobreajuste
Flatten	-	-	-	-	-	-	Transforma a vector 1D
Capa Densa	-	-	-	ReLU	L1(0.0001), L2(0.0001)	-	128 neuronas
Capa de Salida	-	-	-	Sigmoide	-	-	Clasificación binaria

Entrenamiento del Modelo

Tabla 15. Parámetros de Entrenamiento para el Modelo 2 de Clasificación Binaria

Aspecto	Detalles
Optimizador	Adam
Tasa de Aprendizaje	0.0001
Función de Pérdida	Binary Crossentropy
Métricas	Accuracy
Número de Épocas	100
Tamaño de Lote	64
Descripción	Entrenamiento iterativo para ajuste fino, minimiza la pérdida y evita el sobreajuste mediante técnicas de regularización, mejorando la generalización.

Resultados mejor ejecución



Accuracy: 0.8452520370483398
 Precision: 0.8518518518518519
 Recall: 0.8273381294964028
 F1 Score: 0.8394160583941606
 AUROC: 0.9172991881723979
 Specificity: 0.8623853211009175

Figura 20. Análisis de desempeño del Modelo 2.

Curvas de pérdida (Loss)

- La pérdida de entrenamiento y la pérdida de validación decrecen significativamente a medida que aumentan las épocas.
- Ambas curvas (entrenamiento y validación) convergen hacia un valor bajo alrededor de 0.5, lo que sugiere que el modelo se está ajustando bien a los datos.
- La similitud entre las curvas de pérdida de entrenamiento y validación indica que no hay sobreajuste significativo. Esto es positivo ya que muestra que el modelo generaliza bien en datos no vistos.

Curvas de exactitud (Accuracy)

- La exactitud tanto para el entrenamiento como para la validación aumenta rápidamente al inicio y luego se estabiliza alrededor de un valor de 0.85.
- Las curvas de exactitud de entrenamiento y validación se mantienen cercanas, con pequeñas fluctuaciones.
- La proximidad entre las curvas de exactitud de entrenamiento y validación también indica una buena generalización.
- Un valor de exactitud de 0.85 es indicativo de un rendimiento sólido del modelo en la tarea de clasificación.

Análisis de las métricas

Tabla 16. Evaluación de Rendimiento del Modelo 2

Métrica	Valor	Descripción
Accuracy	0.8452	Una alta exactitud muestra que el modelo clasifica correctamente la mayoría de las muestras.
Precision	0.8518	Alta precisión indica que la mayoría de las predicciones positivas son correctas.
Recall	0.8273	Alta sensibilidad sugiere que el modelo identifica correctamente la mayoría de las muestras positivas.
F1 Score	0.8394	Un F1 Score alto demuestra un buen equilibrio entre precisión y sensibilidad.
AUROC	0.9172	Un valor alto de AUROC indica una excelente capacidad del modelo para distinguir entre las clases.
Specificity	0.8624	Alta especificidad muestra que el modelo identifica correctamente la mayoría de las muestras negativas.

El modelo de CNN muestra un rendimiento excelente, con buenas métricas de exactitud, precisión, sensibilidad y AUROC. La convergencia de las curvas de pérdida y exactitud entre el entrenamiento y la validación indica que el modelo no está sobreajustado y generaliza bien a datos no vistos. Con base en estas observaciones, este modelo es un excelente candidato para ser considerado el mejor entre todos los evaluados.

Resumen estadístico de las cinco ejecuciones para el Modelo 2

Tabla 17. Resumen de Resultados de Validación por Ejecución para el Modelo 2

	Ejecución	Val Acc (mejor)	Epoca (Mejor Val Acc)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
Modelo 2	1	0,8113	96	0,8065	0,8634	0,7482	0,8422	0,7924	0,8828
	2	0,8551	90-94	0,8452	0,8623	0,8273	0,8518	0,8394	0,9172
	3	0,8347	89	0,8077	0,7528	0,8653	0,7692	0,8144	0,9995
	4	0,8464	100	0,8464	0,8626	0,8288	0,8475	0,8380	0,9088
	5	0,8253	95	0,8053	0,8032	0,8075	0,8037	0,8056	0,9029
	Promedio	0,8346		0,8222	0,8289	0,8154	0,8229	0,8180	0,9222
	Desviación Est.	0,0154		0,0193	0,0445	0,0384	0,0318	0,0183	0,0403

5.2.3. Modelo 3: seis capas convolucionales

Arquitectura: El modelo es una red neuronal convolucional (CNN) diseñada para la clasificación binaria de imágenes, construida utilizando la API Sequential de Keras constituido por seis capas convolucionales.

Tabla 18. Estructura de la Red Neuronal Convolucional para Clasificación Binaria – Modelo 3

Tipo de Capa	Filtros	Tamaño del Filtro	Función de Activación	Relleno	Regularización	Tasa de Dropout	Descripción
Entrada	-	-	-	-	-	-	Imágenes de 300x300, 3 canales
1ª Capa Convolucional	16	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-	-
Pooling	-	-	-	-	-	-	MaxPooling2D
Capa Convolucional	32	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-	-
Pooling	-	-	-	-	-	-	MaxPooling2D
Capa Convolucional	64	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-	-
Pooling	-	-	-	-	-	-	MaxPooling2D
Capa Convolucional	128	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-	-
Pooling	-	-	-	-	-	-	MaxPooling2D
Capa Convolucional	256	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-	-
Pooling	-	-	-	-	-	-	MaxPooling2D
Capa Convolucional	512	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-	-
Pooling	-	-	-	-	-	-	Último MaxPooling2D
Dropout	-	-	-	-	-	0.4	Reducción de sobreajuste
Flatten	-	-	-	-	-	-	Aplana mapas de características
Capa Densa	-	-	ReLU	-	L1(0.0001), L2(0.0001)	-	128 neuronas

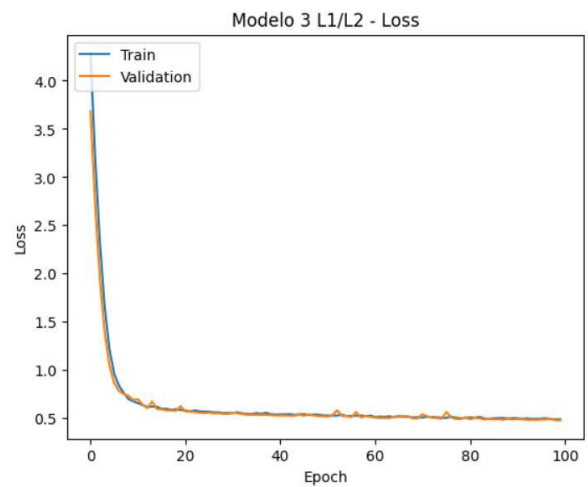

Capa de Salida	-	-	Sigmoide	-	-	-	Clasificación binaria, 1 neurona
----------------	---	---	----------	---	---	---	----------------------------------

Entrenamiento del Modelo

Tabla 19. Parámetros de Entrenamiento para el Modelo 3 de Clasificación Binaria

Aspecto	Detalle
Optimizador	Adam
Tasa de Aprendizaje	0.0001
Función de Pérdida	Binary Crossentropy
Métricas	Precisión (Accuracy)
Épocas de Entrenamiento	100
Tamaño de Lote	64

Resultados mejor ejecución



Accuracy: 0.832356
Precision: 0.869779
Recall: 0.797297
F1 Score: 0.831962
AUROC: 0.907548
Specificity: 0.870416

Figura 21. Análisis de desempeño del Modelo 3

Gráfica de exactitud (Accuracy)

- El Accuracy en el conjunto de entrenamiento y validación muestra una rápida mejora inicial, estabilizándose alrededor del 20% de las épocas. La precisión en el conjunto de validación parece ligeramente más baja y más variable que en el conjunto de entrenamiento.
- Este comportamiento indica que el modelo aprende adecuadamente sin grandes signos de sobreajuste, ya que las líneas de entrenamiento y validación permanecen cercanas entre sí.

Gráfica de Pérdida (Loss)

- Tanto para entrenamiento como para validación, la pérdida disminuye rápidamente y se estabiliza pronto, convergiendo casi en paralelo.
- La convergencia similar y baja de las curvas de pérdida es un buen indicador de que el modelo no está sobreajustando y generaliza bien a datos no vistos.

Análisis de las métricas

Tabla 20. Evaluación de Rendimiento del Modelo 3

Métrica	Valor	Descripción
Accuracy	0.83256	Indica una buena capacidad de clasificación general
Precision	0.869779	Indica que una alta proporción de las predicciones positivas del modelo son correctas.
Recall	0.797297	Muestra que el modelo es capaz de identificar correctamente una buena proporción de todos los casos positivos reales.
F1 Score	0.831962	Proporciona un balance entre la precisión y el recall, lo cual es útil en situaciones donde ambas son importantes
AUROC	0.907548	Destaca la capacidad del modelo para discriminar entre clases.
Specificity	0.870416	Muestra la capacidad del modelo para identificar correctamente los verdaderos negativos.

El modelo muestra un rendimiento robusto y equilibrado, con métricas de evaluación consistentemente altas y un aprendizaje estable según lo indican las curvas de Exactitud y pérdida. El modelo parece ser fiable y efectivo para la tarea para la que ha sido entrenado, sin evidencia significativa de sobreajuste.

Resumen estadístico de las cinco ejecuciones para el Modelo 3

Tabla 21. Resumen de Resultados de Validación por Ejecución para el Modelo 3

	Ejecución	Val Acc (mejor)	Epoca (Mejor Val Acc)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
Modelo 3	1	0,8300	92	0,8229	0,7872	0,8558	0,8137	0,8342	0,8966
	2	0,8159	99	0,8077	0,0000	0,7619	0,8150	0,7875	0,8918
	3	0,8195	95	0,8182	0,8846	0,7551	0,8730	0,8098	0,8981
	4	0,7948	86	0,7878	0,8485	0,7299	0,8350	0,7789	0,8732
	5	0,8370	95	0,8323	0,8704	0,7972	0,8697	0,8319	0,9075
	Promedio	0,8194		0,8138	0,6781	0,7800	0,8413	0,8085	0,8934
	Desviación Est.	0,0144		0,0152	0,3407	0,0436	0,0257	0,0225	0,0113

5.2.4. Modelo 4: cuatro capas convolucionales

Arquitectura: Modelo de una red neuronal convolucional (CNN) construida con la API Sequential de Keras, diseñada principalmente para tareas de clasificación binaria de imágenes, el modelo está constituido de cuatro capas convolucionales. A continuación se presenta de manera tabular la arquitectura.

Tabla 22. Estructura de la Red Neuronal Convolucional para Clasificación Binaria – Modelo 4

Tipo de Capa	Filtros	Tamaño del Filtro	Función de Activación	Relleno	Regularización	Descripción adicional
Entrada	-	-	-	-	-	Imágenes de 300x300 píxeles, 3 canales (RGB)
1ª Capa Convolucional	32	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-
Pooling	-	-	-	-	-	MaxPooling2D, reduce dimensión espacial
2ª Capa Convolucional	64	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-
Pooling	-	-	-	-	-	MaxPooling2D
3ª Capa Convolucional	128	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-
Pooling	-	-	-	-	-	MaxPooling2D
4ª Capa Convolucional	256	3x3	ReLU	Same	L1(0.0001), L2(0.0001)	-


Pooling	-	-	-	-	-	Última capa de MaxPooling2D
Dropout	-	-	-	-	-	Tasa del 50%, reduce sobreajuste
Flatten	-	-	-	-	-	Transforma mapas 3D en vector 1D
Capa Densa	-	-	ReLU	-	L1(0.0001), L2(0.0001)	128 neuronas
Capa de Salida	-	-	Sigmoide	-	-	Clasificación binaria, devuelve probabilidad

Entrenamiento del Modelo

Tabla 23. Parámetros de Entrenamiento para el Modelo 4 de Clasificación Binaria

Aspecto	Detalle
Optimizador	Adam
Tasa de Aprendizaje	0.0001
Función de Pérdida	Binary Crossentropy
Métricas	Precisión (Accuracy)
Épocas de Entrenamiento	40
Tamaño de Lote	64

Resultados mejor ejecución



Accuracy: 0.801876
Precision: 0.801822
Recall: 0.81106
F1 Score: 0.806415
AUROC: 0.890919
Specificity: 0.792363

Figura 22. Análisis de desempeño del Modelo 3

Gráfica de exactitud (Accuracy)

- La exactitud para el conjunto de entrenamiento y validación muestra una rápida mejora en las primeras épocas, seguida de una estabilización. La exactitud de validación se mantiene ligeramente por debajo de la de entrenamiento durante todo el proceso.
- Este modelo también aprende efectivamente, con un ligero indicio de sobreajuste dado que la línea de entrenamiento se mantiene consistentemente por encima de la de validación, aunque la diferencia no es significativa.

Gráfica de Pérdida (Loss)

- La pérdida para ambos conjuntos disminuye de manera pronunciada y se estabiliza rápidamente, mostrando un comportamiento muy similar entre entrenamiento y validación.
- La similitud en las curvas de pérdida sugiere que el modelo generaliza bien y no muestra signos claros de sobreajuste.

Análisis de las métricas

Tabla 24. Evaluación de Rendimiento del Modelo 4

Métrica	Valor	Descripción
Accuracy	0.80176	Indica una capacidad decente de clasificación.
Precision	0.801822	Muestra que una buena parte de las predicciones positivas son correctas.
Recall	0.81106	Indica que el modelo identifica correctamente una buena proporción de los casos positivos reales.
F1 Score	0.806415	Es un indicativo de un balance razonable entre la precisión y el recall.
AUROC	0.890919	Refleja una buena capacidad discriminativa del modelo.
Specificity	0.792363	Sugiere que el modelo también identifica correctamente un buen número de los casos negativos.

Este modelo presenta un rendimiento general bueno con una tendencia a aprender de manera eficaz sin grandes indicios de sobreajuste, basado en el comportamiento de las curvas de pérdida y precisión. Las métricas también indican que el modelo tiene una capacidad equilibrada para clasificar correctamente las clases positivas y negativas.

Resumen estadístico de las cinco ejecuciones para el Modelo 4

Tabla 25. Resumen de Resultados de Validación por Ejecución para el Modelo 4

	Ejecución	Val Acc (mejor)	Epoca (Mejor Val Acc)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
Modelo 4	1	0,8230	40	0,8229	0,8435	0,8040	0,8479	0,8254	0,8912
	2	0,8253	35	0,8089	0,9046	0,7207	0,8913	0,7970	0,8882
	3	0,8148	28	0,7948	0,8899	0,7072	0,8746	0,7820	0,8870
	4	0,8030	38	0,8018	0,7923	0,8110	0,8018	0,8064	0,8909
	5	0,8124	35	0,7960	0,9131	0,6791	0,8868	0,7629	0,8897
	Promedio	0,8157		0,8049	0,8687	0,7444	0,8605	0,7947	0,8894
	Desviación Est.	0,0080		0,0103	0,0451	0,0533	0,0330	0,0212	0,0016

A continuación, se presentan los resultados de las arquitecturas pre-entrenadas dentro del proceso de transfer learning (Feature Extraction). Para todos los casos, en el bloque de adaptación o ensamblaje se utilizó una sola capa densamente conectada con 128 neuronas. No se lograron mejores resultados al aumentar el número de neuronas en esta capa o al incrementar progresivamente hasta 4 capas con 128, 256, 512 y 1028 neuronas.

5.2.5. Arquitectura VGG16

Arquitectura del Modelo

Tabla 26. Descripción de la Arquitectura del Modelo de Clasificación Basado en VGG16


Componente	Descripción	Configuración o detalles adicionales
Base del Modelo VGG16	Arquitectura pre-entrenada VGG16 con pesos de ImageNet	Capas no entrenables, entrada de 300x300 píxeles, 3 canales (RGB)
Global Average Pooling	Reduce dimensiones espaciales de los mapas de características	Transforma mapas en un vector resumen
Capa Densa (Ensamblaje Personalizada):	128 neuronas con activación ReLU	Incluye regularización L1(0.0001) y L2(0.0001)
Dropout	Aplica un Dropout del 50%	Reduce el sobreajuste desconectando aleatoriamente conexiones
Capa de Salida	Una neurona con activación sigmoide	Clasificación binaria, entrega probabilidad de la clase positiva

Entrenamiento del Modelo

Tabla 27. Parámetros de Entrenamiento para la Arquitectura VGG16 de Clasificación Binaria

Aspecto	Detalle
Optimizador	Adam
Tasa de Aprendizaje	0.0001
Función de Pérdida	Binary Crossentropy
Métricas	Accuracy
Épocas de Entrenamiento	100
Tamaño de Lote	64
Validación	División de validación del 20% durante el entrenamiento

Resultados mejor ejecución



AUROC: 0.776999
 Accuracy: 0.705744
 F1-Score: 0.698679
 Precision: 0.748072
 Recall: 0.655405
 Specificity: 0.760391

Figura 23. Análisis de desempeño de la arquitectura VGG16 .

Gráfica de Exactitud (Accuracy)

- La exactitud para el entrenamiento muestra un aumento significativo en las primeras épocas y luego se estabiliza, manteniéndose por encima de la línea de validación, la cual muestra una mejora inicial y luego se nivela, fluctuando ligeramente a lo largo del entrenamiento.

- Esta diferencia entre las curvas sugiere un cierto grado de sobreajuste, ya que el modelo rinde mejor en los datos de entrenamiento que en los de validación. La falta de mejora continua en la validación podría indicar que el modelo ha alcanzado su límite de aprendizaje con la configuración actual.

Gráfica de Pérdida (Loss)

- Ambas curvas, de entrenamiento y validación, muestran una rápida disminución en las pérdidas iniciales y luego una convergencia bastante cercana a lo largo de las épocas restantes.
- El comportamiento de la pérdida es indicativo de un buen ajuste general del modelo, con signos de que el aprendizaje se ha estabilizado después de las primeras épocas. El modelo no muestra señales claras de sobreajuste en términos de pérdida, lo que es positivo.

Análisis de las métricas

Tabla 28. Evaluación de Rendimiento de la Arquitectura VGG16

Métrica	Valor	Descripción
Accuracy	0.705744	Muestra una efectividad moderada en la clasificación.
Precision	0.748072	Indica que una buena proporción de las predicciones positivas son correctas.
Recall	0.655405	Refleja que el modelo tiene más dificultades para identificar todos los casos positivos reales.
F1 Score	0.696879	Ofrece un balance entre precisión y recall, situándose en un nivel medio.
AUROC	0.776999	Sugiere una capacidad decente del modelo para distinguir entre clases.
Specificity	0.760391	Indica que el modelo es razonablemente bueno identificando los verdaderos negativos.

Este modelo VGG16 muestra un rendimiento aceptable, con evidencia de sobreajuste dado el mejor desempeño en los datos de entrenamiento en comparación con la validación. Aunque las métricas indican una competencia moderada en varias áreas, puede haber margen para mejorar el equilibrio entre precisión y sensibilidad, así como para explorar métodos para reducir el sobreajuste y mejorar la generalización del modelo.

Resumen estadístico de las cinco ejecuciones para la arquitectura VGG16

Tabla 29. Resumen de Resultados de Validación por Ejecución para la Arquitectura VGG16

	Ejecución	Val Acc (mejor)	Epoca (Mejor Val Acc)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
VGG16	1	0,6848	98	0,7080	0,7408	0,6779	0,7395	0,7074	0,7756
	2	0,6818	99	0,6951	0,8068	0,5923	0,7690	0,6692	0,7765
	3	0,6818	86	0,7000	0,6943	0,7117	0,7165	0,7141	0,7760
	4	0,6848	87/91	0,7057	0,7603	0,6554	0,7480	0,6968	0,7769
	5	0,6862	98	0,7080	0,7163	0,7000	0,7283	0,7141	0,7751
	Promedio	0,6839		0,7034	0,7437	0,6675	0,7403	0,7007	0,7760
	Desviación Est.	0,0017		0,0045	0,0386	0,0419	0,0179	0,0164	0,0006

5.2.6. Arquitectura ResNet50

Arquitectura del Modelo

Tabla 30. Descripción de la Arquitectura del Modelo de Clasificación Basado en ResNet50

Componente	Descripción	Detalles Adicionales
Base del Modelo ResNet50	Arquitectura ResNet50 pre-entrenada con pesos de ImageNet	Capas no entrenables, entrada de 300x300 píxeles, 3 canales (RGB), exclude_top=False
Global Average Pooling	Aplana mapas de características en un vector	Reduce dimensionalidad, resume características importantes
Capa Densa (Ensamblaje Personalizada)	128 neuronas, activación ReLU	Incluye regularización L1(0.0001) y L2(0.0001)
Dropout	Tasa de Dropout del 50%	Reduce riesgo de sobreajuste, desactiva conexiones aleatoriamente
Capa de Salida	Una neurona, activación sigmoide	Clasificación binaria, salida en forma de probabilidad


Entrenamiento del Modelo

Tabla 31. Parámetros de Entrenamiento para la Arquitectura ResNet50 de Clasificación Binaria

Aspecto	Detalles
Optimizador	Adam
Tasa de Aprendizaje	0.0001
Función de Pérdida	Binary Crossentropy

Métricas	Accuracy
Épocas de Entrenamiento	100
Tamaño de Lote	64
Validación	División de validación del 20% durante el entrenamiento

Resultados mejor ejecución



```
AUROC 0.590398
Accuracy:0.522860
F1-Score: 0.266667
Precision: 0.666667
Recall: 0.166667
Specificity: 0.909535
```

Figura 24. Análisis de desempeño de la arquitectura ResNet50.

Los resultados diferenciales desfavorables en las curvas entrenamiento y validación con ResNet fueron consistentes en las diferentes ejecuciones. El bajo desempeño de esta arquitectura en la clasificación de imágenes de heridas puede deberse a que las características aprendidas durante su preentrenamiento en conjuntos de datos genéricos como ImageNet no se transfieren adecuadamente al dominio específico de las imágenes de heridas quirúrgicas

La arquitectura profunda de ResNet puede requerir una mayor cantidad de datos específicos y un ajuste de hiper parámetros más fino para capturar las particularidades de las heridas. Además, las técnicas de data augmentation y regularizaciones implementadas pueden no haber sido suficientes para mejorar la generalización del modelo, y la variabilidad en las imágenes de entrenamiento puede no haber sido representativa de la diversidad de las heridas, afectando negativamente el rendimiento de la arquitectura.

Gráfica de Exactitud (Accuracy)

- La gráfica de exactitud muestra mucha variabilidad en ambas curvas de entrenamiento y validación, sin una tendencia clara de mejora a lo largo de las épocas. La precisión en validación es generalmente más baja y más errática que en entrenamiento.
- Esta alta variabilidad y la falta de convergencia clara entre las curvas indican problemas de estabilidad en el aprendizaje del modelo.

Gráfica de Pérdida (Loss)

- Las curvas de pérdida para entrenamiento y validación disminuyen rápidamente y luego se aplanan, manteniendo una proximidad bastante cercana entre ellas a lo largo de las épocas.
- A pesar de la alta variabilidad en la exactitud, las curvas de pérdida sugieren que el modelo está aprendiendo y generalizando de manera adecuada, lo que puede parecer contradictorio con la gráfica de Accuracy.

Análisis de las métricas

Tabla 32. Evaluación de Rendimiento de la Arquitectura ResNet50

Métrica	Valor	Descripción
Accuracy	0.522860	Es relativamente bajo, lo que podría reflejar una clasificación apenas mejor que el azar.
Precision	0.66667	Muestra que, de las predicciones positivas del modelo, dos tercios son correctas.
Recall	0.16667	Es muy bajo, lo que indica que el modelo está fallando en identificar una gran proporción de los casos positivos reales.
F1 Score	0.26667	Es también muy bajo, reflejando un balance pobre entre precisión y recall.
AUROC	0.590398	Sugiere una capacidad limitada para distinguir entre clases.
Specificity	0.909535	Indica que el modelo es efectivo en identificar los verdaderos negativos.

Este modelo de ResNet50 parece tener dificultades significativas en términos de rendimiento efectivo en la tarea asignada, con baja precisión y recall, pero una alta especificidad. La alta variabilidad en las métricas de Accuracy y el bajo rendimiento general sugieren que pueden ser necesarios ajustes en el proceso de entrenamiento o en la arquitectura del modelo para mejorar su estabilidad y efectividad.

Resumen estadístico de las cinco ejecuciones para la arquitectura ResNet

Tabla 33. Resumen de Resultados de Validación por Ejecución para la Arquitectura ResNet50

	Ejecución	Val Acc (mejor)	Epoca (Mejor Val Acc)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
ResNet50	1	0,5704	9	0,5113	0,9070	0,1509	0,6380	0,2440	0,5777
	2	0,5616	15/84	0,5603	0,3716	0,7342	0,5591	0,6348	0,5826
	3	0,5660	30	0,5228	0,9095	0,1666	0,6666	0,2666	0,5903
	4	0,5718	26/57	0,5615	0,4034	0,7072	0,5627	0,6267	0,5913
	5	0,5704	69/84/85	0,5123	0,9193	0,1373	0,6489	0,2267	0,5935
	Promedio	0,5680		0,5336	0,7022	0,3792	0,6151	0,3998	0,5871
	Desviación Est.	0,0038		0,0226	0,2571	0,2791	0,0452	0,1890	0,0060

5.2.7. Arquitectura InceptionV3

El modelo incorpora la arquitectura InceptionV3 junto con técnicas de regularización L1(0.0001) y L2(0.0001), diseñado para optimizar la clasificación binaria.

Arquitectura del Modelo

Tabla 34. Descripción de la Arquitectura del Modelo de Clasificación Basado en InceptionV3

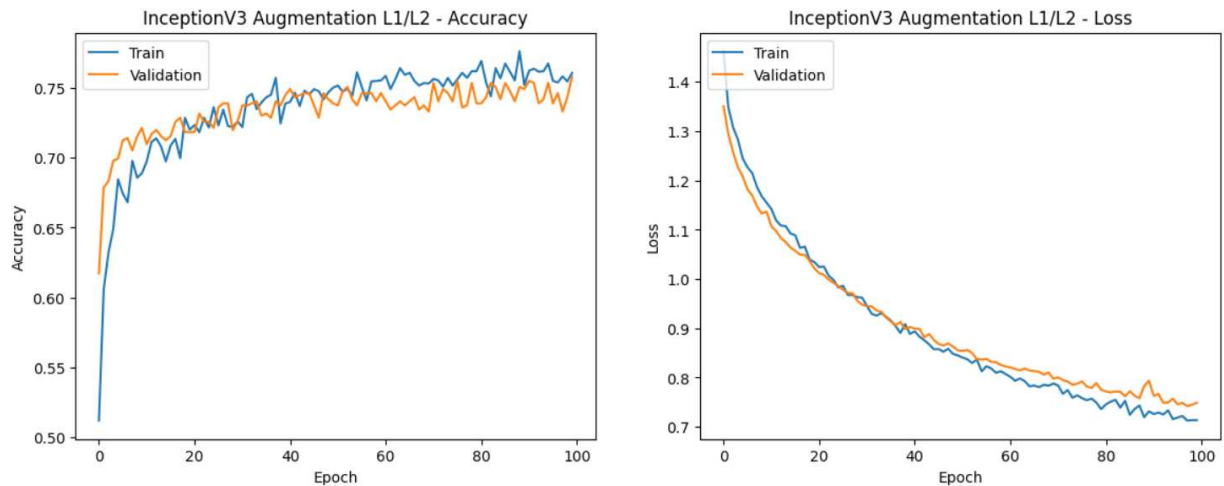
Componente	Descripción	Detalles Adicionales
Base del Modelo InceptionV3	InceptionV3 preentrenada con pesos de ImageNet	Sin capas superiores, entrada de 300x300 píxeles, 3 canales (RGB), capas no entrenables
Global Average Pooling	Reduce la dimensionalidad de los mapas de características	Resumen de características en un vector promedio
Capa Densa (Ensamblaje Personalizada)	128 neuronas, activación ReLU	Regularización L1(0.0001) y L2(0.0001)
Dropout	Tasa del 50%	Reduce sobreajuste desactivando conexiones aleatorias
Capa de Salida	Una neurona, activación sigmoide	Salida de probabilidad entre 0 y 1, clasificación binaria

Entrenamiento del Modelo

Tabla 35. Parámetros de Entrenamiento para la Arquitectura InceptionV3 de Clasificación Binaria

Aspecto	Detalle
Optimizador	Adam
Tasa de Aprendizaje	0.0001
Función de Pérdida	Binary Crossentropy
Métricas	Accuracy
Épocas de Entrenamiento	100
Tamaño de Lote	64
Validación	20% split de validación durante el entrenamiento

Resultados mejor ejecución



AUROC: 0.829132
 Accuracy: 0.735053
 F1-Score: 0.709512
 Precision: 0.826347
 Recall: 0.621622
 Specificity: 0.858191

Figura 25. Análisis de desempeño de la arquitectura InceptionV3.

Gráfica de Exactitud (Accuracy)

- La exactitud en el entrenamiento muestra un incremento rápido al inicio y luego se estabiliza, manteniéndose por encima de la línea de validación, que también muestra un incremento rápido seguido de estabilidad, con algunas fluctuaciones menores hacia el final.

- Esta tendencia y la proximidad de las líneas indican que el modelo está aprendiendo de manera efectiva y que hay un ligero sobreajuste, dado que la exactitud de entrenamiento es consistentemente mayor que la de validación.

Gráfica de Pérdida (Loss)

- La pérdida para ambos conjuntos disminuye rápidamente al principio y luego se estabiliza, con la pérdida de validación mostrando ligeramente más fluctuaciones hacia el final, pero permaneciendo cercana a la línea de entrenamiento.
- La convergencia de las líneas de pérdida sugiere un buen ajuste del modelo. Las fluctuaciones en la validación podrían indicar variaciones en la respuesta del modelo a diferentes características o ruido en el conjunto de validación.

Análisis de las métricas

Tabla 36. Evaluación de Rendimiento de la Arquitectura InceptionV3

Métrica	Valor	Descripción
Accuracy	0.735053	indica una capacidad razonable de clasificación.
Precision	0.826347	Demuestra que una alta proporción de las predicciones positivas del modelo son correctas.
Recall	0.621622	Muestra que el modelo puede identificar una proporción moderada de todos los casos positivos reales.
F1 Score	0.709512	Es un indicativo de un balance decente entre precisión y recall, aunque mejorable.
AUROC	0.829132	Sugiere una buena capacidad del modelo para distinguir entre clases.
Specificity	0.858191	Indica que el modelo es bastante bueno en identificar correctamente los verdaderos negativos.

El modelo InceptionV3 muestra un rendimiento adecuado con un equilibrio efectivo entre aprendizaje y generalización, como lo indican las métricas de evaluación y las curvas de exactitud y pérdida. Sin embargo, el recall relativamente bajo puede ser un área para explorar mejoras, posiblemente a través de técnicas de balanceo de clases o ajustes en la umbralización de la clasificación.

Resumen estadístico de las cinco ejecuciones para la arquitectura InceptionV3

Tabla 37. Resumen de Resultados de Validación por Ejecución para la Arquitectura InceptionV3

	Ejecución	Val Acc (mejor)	Epoca (Mejor Val Acc)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
InceptionV3	1	0,7551	99	0,7467	0,8386	0,6621	0,8166	0,7313	0,8307
	2	0,7581	99	0,7514	0,8019	0,7049	0,7944	0,7470	0,8250
	3	0,7610	78	0,7280	0,8459	0,6193	0,8136	0,7033	0,8278
	4	0,7558	70	0,7373	0,8239	0,6576	0,8021	0,7227	0,8243
	5	0,7581	100	0,7350	0,8581	0,6216	0,8263	0,7095	0,8291
	Promedio	0,7576		0,7397	0,8337	0,6531	0,8106	0,7228	0,8274
	Desviación Est.	0,0021		0,0084	0,0194	0,0314	0,0112	0,0156	0,0024

5.2.8. Arquitectura MobileNetV2

Arquitectura del Modelo

Tabla 38. Descripción de la Arquitectura del Modelo de Clasificación Basado en MobileNetV2

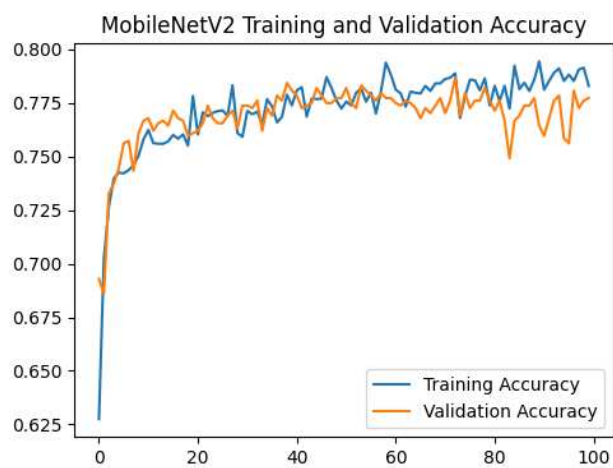
Componente	Descripción	Detalles Adicionales
Data Augmentation	Módulo de transformaciones aleatorias	Incluye volteo horizontal, rotaciones de hasta 0.2 radianes, zoom de hasta 20%
Base del Modelo MobileNetV2	MobileNetV2 preentrenada con pesos de ImageNet	Capas no entrenables, eficiencia en parámetros y velocidad, adaptada para dispositivos limitados
Global Average Pooling	Reduce dimensiones de los mapas de características	Promedia cada mapa de características a un solo valor
Capa Densa (Ensamblaje Personalizada)	128 neuronas con activación ReLU	Regularización L1(0.0001) y L2(0.0001) para controlar el sobreajuste
Dropout	Tasa del 50%	Reduce el riesgo de sobreajuste desactivando aleatoriamente conexiones
Capa de Salida	Una neurona con activación sigmoide	Produce un valor de probabilidad entre 0 y 1 para clasificación binaria

Entrenamiento del Modelo

Tabla 39. Parámetros de Entrenamiento para la Arquitectura MobileNetV2 de Clasificación Binaria

Aspecto	Detalle
Optimizador	Adam
Tasa de Aprendizaje	0.0001
Función de Pérdida	Binary Crossentropy
Métricas	Accuracy
Épocas de Entrenamiento	100
Tamaño de Lote	64
Validación	Split de validación del 20%

Resultados mejor ejecución



Accuracy: 0.7772567272186279
 Recall: 0.6592592592592592
 Precision: 0.8369905956112853
 F1-Score: 0.7375690607734807
 Specificity: 0.8839285714285714
 AUROC: 0.860245811287478

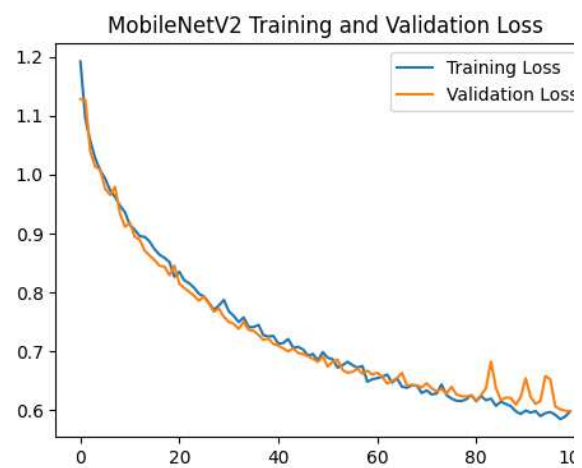


Figura 26. Análisis de desempeño de la arquitectura MobileNetV2.

Gráfica de exactitud (Accuracy)

- La exactitud tanto para el entrenamiento como para la validación muestra un aumento rápido inicialmente, seguido de una estabilización con fluctuaciones menores a lo largo de las épocas. Las líneas de accuracy de entrenamiento y validación permanecen cercanas, aunque la de validación es ligeramente más errática.

- La proximidad de las líneas sugiere que el modelo generaliza bien y no hay una discrepancia significativa entre el aprendizaje en los datos de entrenamiento y validación, lo cual es un indicador positivo de que el modelo no está sobreajustando de manera significativa.

Gráfica de Pérdida (Loss)

- Las curvas de pérdida para el entrenamiento y la validación también muestran una rápida disminución inicial y se aplanan con el tiempo, permaneciendo muy cercanas una de la otra con algunas fluctuaciones menores hacia el final.
- Este comportamiento en las curvas de pérdida indica que el modelo alcanza una convergencia estable y muestra consistencia entre el entrenamiento y la validación, lo cual es indicativo de un buen ajuste.

Análisis de las métricas

Tabla 40. Evaluación de Rendimiento de la Arquitectura MobileNetV2

Métrica	Valor	Descripción
Accuracy	0.777257	Indica que el modelo clasifica correctamente más de tres cuartas partes de las instancias.
Precision	0.836991	Destaca que una gran proporción de las predicciones positivas del modelo son correctas.
Recall	0.659260	Muestra que el modelo identifica aproximadamente dos tercios de todos los casos positivos reales, lo que puede ser un área para mejorar.
F1 Score	0.735961	Refleja un balance razonable entre precisión y recall.
AUROC	0.860258	Sugiere que el modelo tiene una buena capacidad para distinguir entre las clases.
Specificity	0.883928	Indica que el modelo es efectivo en identificar correctamente los verdaderos negativos.

El modelo MobileNetV2 presenta un buen rendimiento general, con altos niveles de precisión y capacidad para distinguir entre clases, aunque podría mejorar en la identificación de todos los casos positivos reales, como indica el valor de recall más bajo. La consistencia entre las curvas de exactitud y pérdida y las métricas proporcionadas sugiere que el modelo está bien ajustado y generaliza adecuadamente a nuevos datos.

Resumen estadístico de las cinco ejecuciones para la arquitectura MobileNetV2

Tabla 41. Resumen de Resultados de Validación por Ejecución para la Arquitectura MobileNetV2

	Ejecución	Val Acc (mejor)	Epoca (Mejor Val Acc)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
MobileNetV 2	1	0,7654	99	0,7702	0,9205	0,6053	0,8833	0,7183	0,8650
	2	0,7669	97	0,7479	0,9202	0,5854	0,8862	0,7050	0,8512
	3	0,7375	97	0,7444	0,8679	0,6306	0,8383	0,7197	0,8438
	4	0,7742	91	0,7772	0,8839	0,6592	0,8369	0,7360	0,8602
	5	0,7713	71	0,7561	0,9090	0,6165	0,8814	0,7255	0,8712
	Promedio	0,7631		0,7592	0,9003	0,6194	0,8652	0,7212	0,8583
	Desviación Est.	0,0132		0,0127	0,0210	0,0248	0,0226	0,0106	0,0098

6. EVALUACIÓN DEL RENDIMIENTO DE LOS MODELOS DE CNN

Atendiendo a las curvas de loss y accuracy obtenidas durante el proceso de entrenamiento (capítulo 5) ha sido posible delimitar el mejor set de hiperparámetros (descritos como escenarios) para cada uno de los modelos explorados. Partiendo de esta información se realizó la interpretación de las métricas de desempeño (expresadas en términos de promedio y desviación estándar) de los mismos que culminó con el análisis comparativo y selección del mejor modelo. En esta etapa se han tenido en cuenta las matrices de confusión y un ejercicio simulación de los efectos de los modelos (en términos absolutos) al aplicarlos a una población de 1000 pacientes en su posoperatorio mediato, donde la prevalencia de heridas alteradas oscila alrededor del 5%.

Finalmente se describe un análisis comparativo del modelo seleccionado y la mejor arquitectura de CNN identificada dentro del proceso de transfer learning, utilizando una capa densa para la adaptación a la capa de salida. Todos los resultados y la respectiva discusión se presentan a continuación.

6.1. COMPARACIÓN DE 4 MODELOS PERSONALIZADOS DE CNN

En el análisis de rendimiento de los cuatro modelos de clasificación (ver Tabla 42), se observan varias diferencias clave en términos de validation accuracy, specificity, recall, precision, F1-Score y AUROC. El Modelo 1 mostró buenos resultados en validation accuracy y specificity, aunque con una alta variabilidad en precision, sugiriendo inestabilidad en sus resultados. El Modelo 3 presentó un rendimiento sólido en precision, pero con una alta variabilidad en specificity. El Modelo 4 demostró ser el más consistente, con baja desviación estándar en AUROC y precision, y destacándose en specificity y precision.

Tabla 42. Comparación de las métricas de desempeño de cuatro modelos de CNN

Modelos		Val Acc (mejor)	Val Acc (final)	Specificit y	Recall	Precision	F1-Score	AUROC
1	Promedio	0,8122	0,8063	0,8579	0,7540	0,6741	0,7946	0,8856
	DE	0,0034	0,0062	0,0347	0,0328	0,3381	0,0066	0,0052
2	Promedio	0,8346	0,8222	0,8289	0,8154	0,8229	0,8180	0,9222
	DE	0,0154	0,0193	0,0445	0,0384	0,0318	0,0183	0,0403
3	Promedio	0,8194	0,8138	0,6781	0,7800	0,8413	0,8085	0,8934
	DE	0,0144	0,0152	0,3407	0,0436	0,0257	0,0225	0,0113
4	Promedio	0,8157	0,8049	0,8687	0,7444	0,8605	0,7947	0,8894
	DE	0,0080	0,0103	0,0451	0,0533	0,0330	0,0212	0,0016

DE: Desviación estándar.

*Se presentan las medias y DE de las métricas pues se realizaron 5 iteraciones para cada modelo.

Por otra parte, el Modelo 2 se destacó en varias métricas clave: obtuvo la mayor validation accuracy (0.8346) y un AUROC notablemente alto (0.9222), lo cual indica que es el modelo más efectivo en la discriminación entre clases (alteradas vs no alteradas). Además, presentó valores de recall (0.8154) y precisión (0.8229) altos, manteniendo un equilibrio adecuado entre sensibilidad y precisión. Aunque tiene una desviación estándar moderada en sus métricas, su rendimiento superior en las métricas más críticas y su robustez en términos de AUROC (ver Figura 27) hacen del Modelo 2 el mejor modelo general. Por tanto, considerando su rendimiento superior en las métricas de evaluación más significativas, el Modelo 2 se considera como el mejor modelo.




Figura 27. Curvas ROC de los cuatro modelos de CNN

Para conocer los efectos de la aplicación de los modelos en términos absolutos, se muestran las respectivas matrices de confusión (ver Figura 28). En estas, es posible delimitar el número de falsos negativos y falsos positivos que resultan de aplicarlos. No obstante, por efecto del balanceo

de las clases (50% heridas no alteradas, 50% de heridas alteradas) la prevalencia en todos los casos oscila alrededor del 50%, cifra que no es consistente con la ocurrencia de alteraciones de heridas posquirúrgicas en la vida real. Por tanto, resulta más apropiado el análisis propuesto en la Tabla 43), donde se asume una prevalencia del 5% (proporción de pacientes con heridas alteradas) en una muestra de 1000 pacientes.




Figura 28. Matrices de confusión de los modelos de CNN explorados

Tabla 43. Efectos absolutos de la aplicación hipotética de los cuatro modelos de CNN

Modelos	Falsos positivos	Falsos negativos
1	135	12
2	163	9
3	306	11
4	125	13

En la Tabla 43 se observa que el Modelo 2, a pesar de tener un número más alto de falsos positivos (163), **tiene el menor número de falsos negativos (9), lo que es crucial en contextos donde es vital no dejar pasar casos de heridas alteradas.** Por lo tanto, considerando el balance entre falsos positivos y falsos negativos, el Modelo 2 sigue siendo el más adecuado para este escenario.

Desde la óptica de una implementación hipotética en la práctica clínica, el efecto comparativo favorece al modelo 2, ya que lo ideal es que el número de casos omitidos (falsos negativos) sea el más bajo posible. Estos casos se complican por no recibir un diagnóstico y tratamiento oportuno. Por otra parte, aunque habría un número importante de pacientes sobre diagnosticados y potencialmente sobre tratados (falsos positivos), las consecuencias podrían ser menos graves que para los casos omitidos.

6.2. COMPARACIÓN DE CUATRO ARQUITECTURAS PRE ENTRENADAS DE CNN (TRANSFER LEARNING)

Tomando como referencia el dataset de heridas balanceado, se realizó un ejercicio comparativo entre arquitecturas pre entrenadas (transfer learning por transferencia de características) para identificar aquella con los mejores atributos al momento de la clasificación entre alteradas y no alteradas. Los hallazgos se presentan a continuación.

Tabla 44. Comparación de las métricas de desempeño de cuatro arquitecturas de CNN

Arquitectura		Val Acc (mejor)	Val Acc (final)	Specificity	Recall	Precision	F1-Score	AUROC
VGG 16	Promedio	0,6839	0,7034	0,7437	0,6675	0,7403	0,7007	0,7760
	DE	0,0017	0,0045	0,0386	0,0419	0,0179	0,0164	0,0006
ResNet 50	Promedio	0,5680	0,5336	0,7022	0,3792	0,6151	0,3998	0,5871
	DE	0,0038	0,0226	0,2571	0,2791	0,0452	0,1890	0,0060
InceptionV 3	Promedio	0,7576	0,7397	0,8337	0,6531	0,8106	0,7228	0,8274
	DE	0,0021	0,0084	0,0194	0,0314	0,0112	0,0156	0,0024
MobileNet	Promedio	0,7631	0,7592	0,9003	0,6194	0,8652	0,7212	0,8583
	DE	0,0132	0,0127	0,0210	0,0248	0,0226	0,0106	0,0098

La Tabla 44 muestra los principales hallazgos con relación al uso de arquitecturas preentrenadas VGG 16, ResNet 50, InceptionV3 y MobileNet. Se observa una clara variabilidad en el rendimiento de cada modelo en términos de sus métricas de evaluación. La arquitectura VGG 16 muestra una Validation Accuracy final de 0.7034 y un AUROC de 0.7760, con una Specificity de 0.7437 y un Recall de 0.6675. Estos valores indican un rendimiento moderado. Por otro lado, ResNet 50 tiene el rendimiento más bajo con una Validation Accuracy final de 0.5336 y un AUROC de 0.5871, junto con una baja Specificity y Recall, lo que sugiere que este modelo es menos efectivo en la tarea.

InceptionV3 y MobileNet destacan con los mejores resultados. InceptionV3 presenta una Validation Accuracy final de 0.7397 y un AUROC de 0.8274, con alta Specificity (0.8337) y buena Precision (0.8106). MobileNet, por su parte, logra la mayor Validation Accuracy final (0.7592) y el AUROC más alto (0.8583) (Figura 29), combinados con una Specificity muy alta (0.9003) y una buena Precision (0.8652).

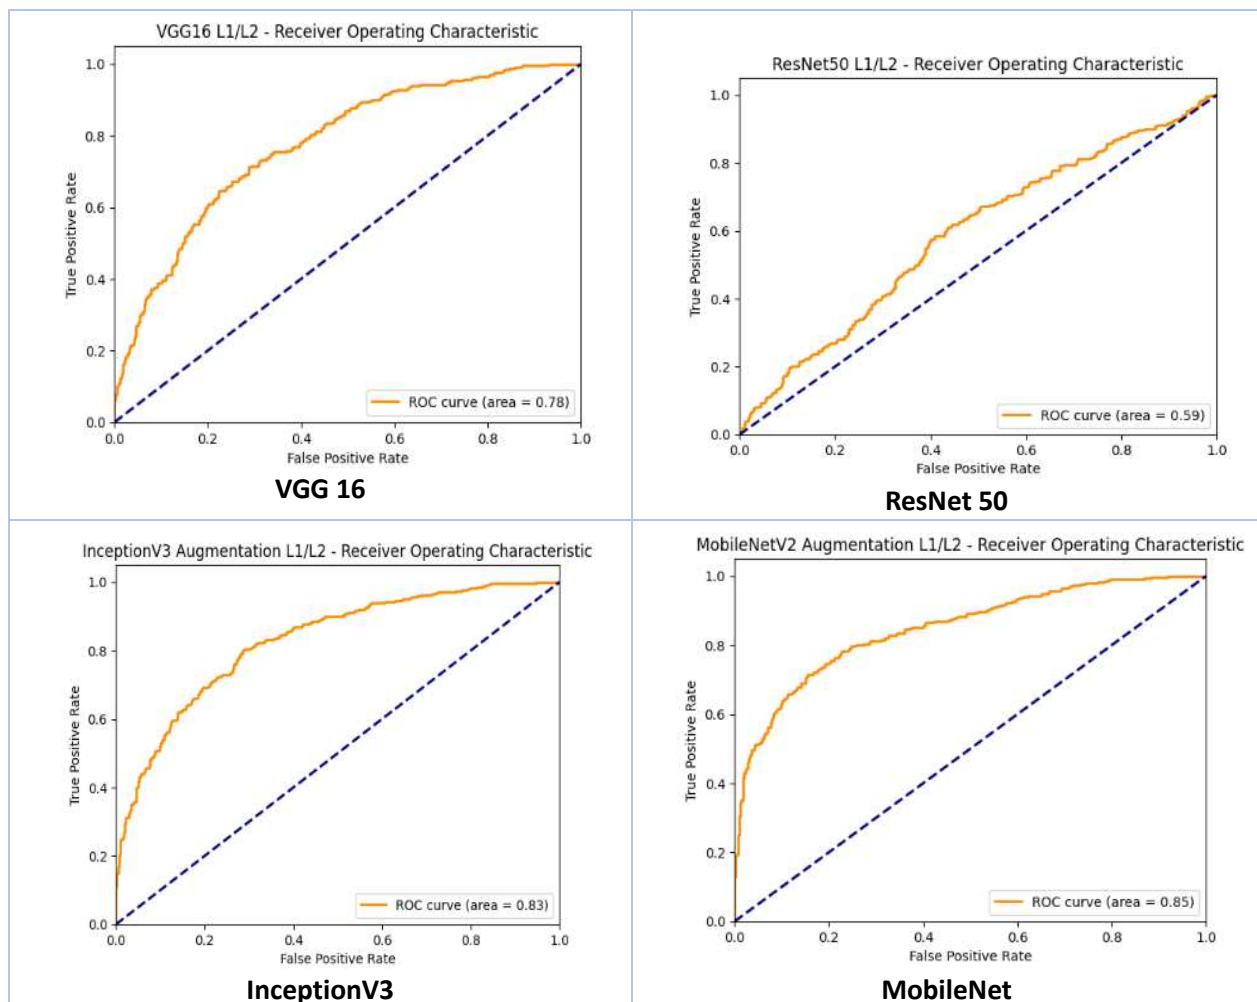


Figura 29. Curvas ROC de cuatro arquitecturas de CNN

Atendiendo al efecto esperado del balanceo de clases sobre la prevalencia y el número de falsos positivos y falsos negativos, se omite la presentación de las matrices de confusión y se incluye la tabla comparativa del efecto de aplicar los modelos en términos absolutos (n: 1000, prevalencia de heridas alteradas del 5%) (Tabla 45).

Tabla 45. Efectos absolutos de la aplicación hipotética de las cuatro arquitecturas de CNN

Modelos	Falsos positivos	Falsos negativos
VGG 16	256	17
ResNet2	298	31
InceptionV3	166	17
MobileNet	100	19

En conclusión, MobileNet demuestra ser la mejor arquitectura en este análisis, dado su balance superior entre alta Specificity, Precision y AUROC, lo que indica una mejor capacidad para distinguir entre clases positivas y negativas y un menor riesgo de falsos positivos y falsos negativos en comparación con las otras arquitecturas.

Importante aclarar que los resultados obtenidos con las arquitecturas pre-entrenadas no son del todo concluyentes pues no se realizó fine-tuning por términos del alcance del proyecto. Es posible que la mejor adaptación del modelo pre-entrenado al nuevo dominio de datos con esta técnica arroje resultados más favorables tanto en ResNet como las demás arquitecturas.

6.3. COMPARACIÓN DEL MODELO 2 CON MOBILENET

La Tabla 46 muestra la comparación de las métricas del mejor modelo personalizado de CNN y la arquitectura con el mayor rendimiento para efectos de clasificación.

Tabla 46. Comparación de las métricas de desempeño del Modelo 2 y Mobilenet

Modelo/Arquitectura		Val Acc (mejor)	Val Acc (final)	Specificit y	Recall	Precisio n	F1-Score	AUROC
Modelo 2	Promedio	0,8346	0,8222	0,8289	0,8154	0,8229	0,8180	0,9222
	DE	0,0154	0,0193	0,0445	0,0384	0,0318	0,0183	0,0403
MobileNet	Promedio	0,7631	0,7592	0,9003	0,6194	0,8652	0,7212	0,8583
	DE	0,0132	0,0127	0,0210	0,0248	0,0226	0,0106	0,0098

Analizando la tabla comparativa se observan varias diferencias clave en términos de métricas de rendimiento. En cuanto a la Val Acc, el Modelo 2 muestra un mejor rendimiento con un promedio de 0,8346 en su mejor punto y 0,8222 al final del entrenamiento, mientras que MobileNet tiene un promedio de 0,7631 en su mejor punto y 0,7592 al final del entrenamiento. En términos de Specificity, MobileNet destaca con un valor de 0,9003, lo que indica que es mejor en identificar correctamente los casos negativos (heridas no alteradas) en comparación con Modelo 2, que tiene una Specificity de 0,8289. Sin embargo, el Modelo 2 supera a MobileNet en Recall con un valor de 0,8154 frente a 0,6194, lo que sugiere que Modelo 2 es mejor en identificar correctamente los casos positivos (heridas alteradas).

En cuanto a la Precision, MobileNet tiene una mayor precisión con un valor de 0,8652, indicando que tiene menos falsos positivos en comparación con Modelo 2, que tiene una precisión de 0,8229. Sin embargo, el Modelo 2 presenta un F1-Score de 0,8180, mayor al de MobileNet, que tiene un F1-Score de 0,7212, lo que sugiere que Modelo 2 tiene un mejor balance entre Precision y Recall. Finalmente, en términos de AUROC, Modelo 2 muestra un excelente rendimiento general para discriminar entre clases con un valor de 0,9222, mientras que MobileNet tiene un AUROC de 0,8583, que aunque bueno, es inferior al de Modelo 2.

En conclusión, aunque MobileNet tiene una mayor especificidad y precisión, Modelo 2 se destaca por su mayor Val Acc, recall, F1-Score y AUROC. Estas métricas sugieren que Modelo 2 tiene un mejor rendimiento general y equilibrio entre la identificación correcta de casos positivos y negativos. Por lo tanto, Modelo 2 puede ser considerado el mejor modelo para esta tarea específica, especialmente si el objetivo es tener un balance óptimo entre la sensibilidad y la especificidad.

A pesar del rendimiento favorable del modelo 2, como se mencionó previamente, los resultados presentados no se consideran definitivos pues es posible que, en trabajos futuros, el incremento del número de imágenes y ajustes en el pre-procesamiento y entrenamiento, así como la realización de fine tuning para las arquitecturas pre-entrenadas, puedan ofrecer mejores métricas de desempeño.

6.4. COMPARACIÓN DEL MODELO 2 CON EL MODELO DE PEREIRA ET AL (73)

Dentro del proceso de benchmarking se ha considerado apropiado contrastar los resultados de desempeño del modelo 2 (el mejor modelo) con el principal referente publicado en la literatura en el contexto particular de clasificación de heridas quirúrgicas cardiorácicas. Los resultados se muestran a continuación.

Tabla 47. Comparación de dos Proyecto de aprendizaje automático para clasificación de heridas quirúrgicas

Criterio	Modelo de Pereira et al (xx)	Modelo 2
País	Portugal	Colombia
Número de imágenes	1337	4262
Tipo de las heridas quirúrgicas	Heridas de esternotomía, drenes y safenectomías.	Heridas de esternotomía, safenectomías y bolsillos de dispositivos cardiacos (marcapasos, cardiodesfibrilladores, cardioresincronizadores)
Etiquetado de las imágenes	No descrito en detalle	Realizado por una enfermera experimentada
Herramienta de anotación (etiquetado)	Labelme	LabelImg
Preprocesamiento (corrección del color y eliminación de brillo)	Si	No
Segmentación	Automática probando varias arquitecturas de CNN (Ej. Unet).	Manual con LabelImg (Experto en heridas)
Resolución final de las imágenes para la clasificación	No descrito	300x300 pixeles
Balanceo de clases	Automático (SMOTE)	Undersampling manual (por experto en heridas)*
Entorno para la aplicación de los algoritmos	Google Colab (Pro+), GPUs: A100, L4, T4)	NVIDIA RTX 3090 GPU
Técnica de aprendizaje automático (clasificación)	RF, SVM, KNN	CNN
Partición dle dataset para el entrenamiento	Entrenamiento-Validación-Prueba (60%-20%-20%)	Entrenamiento-Validación (80%-20%)
Características del modelo final	5 capas convolucionales, optimizador Adam, 100 épocas, batch-size. 64, regularización Dropout + L1/L2, funciones de pérdida y activación (salida) binary_crossentropy y sigmoid respectivamente.	No descrito
Resultados (métricas de desempeño)	En términos de optimización del F1 score: Accuracy: 95.4 ± 2.0 Precision: 51.1 ± 7.3 Recall: 46.2 ± 6.9 F1 score: 48.6 ± 5.8 AUROC: 71.8 ± 3.9	En términos de optimización de las curvas de Val_accuracy y Val_loss: Accuracy: 83,46 ± 0,0154 Precision: 82,29 ± 0,0318 Recall: 81,54 ± 0,0384 F1 score: 81,80 ± 0,0183 AUROC: 92,22 ± 0,0403

*Fundamentalmente, reducción del número de imágenes de la clase mayoritaria (alteradas) eliminando aquellas con posibles defectos residuales de calidad (pobre resolución, artefactos, etc.).

Aunque existen diferencias metodológicas entre los proyectos, es apropiado efectuar un análisis comparativo de los mismos. Los modelos de clasificación de heridas utilizando técnicas

tradicionales como SVM, RF y KNN con el modelo basado en redes neuronales convolucionales (CNN), se observan diferencias significativas en las métricas de rendimiento. Aunque los modelos tradicionales alcanzan una alta precisión global (accuracy) de $95.4 \pm 2.0\%$, su desempeño en términos de precisión ($51.1 \pm 7.3\%$), sensibilidad ($46.2 \pm 6.9\%$) y F1-score ($48.6 \pm 5.8\%$) es considerablemente inferior.

Por otro lado, el modelo CNN, aunque tiene una precisión global menor ($83.46 \pm 0.0154\%$), destaca por su notable mejora en precisión ($82.29 \pm 0.0318\%$), sensibilidad ($81.54 \pm 0.0384\%$) y F1-score ($81.80 \pm 0.0183\%$). Además, la capacidad de discriminación entre clases del modelo CNN es superior, como lo indica su AUROC de $92.22 \pm 0.0403\%$, frente al $71.8 \pm 3.9\%$ de los modelos tradicionales. Estas métricas sugieren que el modelo CNN es más eficaz y robusto para la tarea de clasificación, proporcionando un equilibrio superior entre precisión y sensibilidad, y una mejor capacidad para distinguir entre las clases, lo cual es esencial en aplicaciones prácticas de clasificación de heridas.

6.5. DISCUSIÓN

Los resultados obtenidos durante la evaluación del modelo de CNN resultan prometedores en el contexto de las heridas quirúrgicas cardiotorácicas, más aún cuando se comparan con los hallazgos que muestran técnicas convencionales con conjuntos de datos similares. Como fortalezas que soportan al mejor modelo personalizado de CNN (modelo 2) se encuentran la inclusión de un dataset (inédito) con un gran número de imágenes y el logro de métricas de desempeño satisfactorias que muestran un balance adecuado entre el número de falsos negativos y el número de falsos positivos. Esta última característica es fundamental en la arena clínica pues la omisión diagnóstica de heridas quirúrgicas alteradas puede traducirse en la progresión de las lesiones y complicaciones graves para los pacientes.

Como debilidades del estudio, se resaltan: primero, el etiquetado y sub segmentación final de las imágenes realizados por una enfermera experta puede conducir a sesgo de clasificación. La participación de más observadores para estas tareas facilitaría la estimación de un coeficiente de acuerdo y el respectivo consenso para el etiquetado, confiriendo mayor validez. Por fuerza mayor, no fue posible contar con más expertos para estas tareas detalladas.

Segundo, no se realizó segmentación automática (semántica) que hubiese ofrecido ventajas en términos de eficiencia, consistencia y capacidad para procesar grandes volúmenes de datos con alta precisión. No obstante, por el alcance del proyecto académico esta técnica no fue considerada y el juicio clínico detallado por un experto sigue siendo una alternativa para la tarea dada la complejidad y ambigüedad en múltiples imágenes.

Tercero, durante la partición del dataset para el entrenamiento de los modelos y arquitecturas, no se incluyó un grupo de datos de prueba. Aunque es una práctica recomendada, para el caso

del estudio, la reducción del conjunto de datos de entrenamiento disponibles podría aumentar la probabilidad de sobreajuste.

Cuarto, la evaluación de los modelos y arquitecturas tomó como insumo el dataset balanceado. Aunque no se contrastaron los resultados de las métricas entre los datasets balanceado y no balanceado, la literatura es consistente en recomendar el balanceo de las clases como punto de la buena práctica en proyectos de Ciencia de datos. En el caso particular del dataset del estudio, la predominancia de imágenes no alteradas (2783 vs 2111) conduciría potencialmente a una mayor capacidad del modelo de CNN para identificar heridas no alteradas.

Quinto, en el proyecto se comparó el rendimiento del Modelo 2 con la arquitectura pre-entrenada de MobileNet. Aunque éste mostró un mejor desempeño, es importante destacar que no se realizó el ajuste fino (fine-tuning) en MobileNet, lo que podría haber limitado su capacidad para adaptarse completamente a nuestro conjunto de datos específico. El Modelo 2 fue diseñado y ajustado específicamente para abordar el problema de identificación de alteraciones en heridas quirúrgicas, utilizando un conjunto de datos representativo, lo que probablemente contribuyó a su superioridad en este contexto particular.

Sexto, dentro del proceso de balanceo de clases, se realizó subsample manual en lugar de automático (Ej. SMOTE) perdiendo la aleatoriedad para la eliminación de las imágenes de la clase mayoritaria y las ventajas de la automatización y preservación de la información. No obstante, la tarea realizada por un experto facilitó la eliminación de imágenes con defectos residuales de calidad que aportan ruido e inestabilidad en las curvas de accuracy y loss durante el entrenamiento de los modelos, y por tanto sobreajuste. Adicionalmente, las métricas obtenidas durante la evaluación mostraron un balance satisfactorio entre el número de falsos positivos y falsos negativos.

Finalmente, por la predominancia de la raza mestiza en los pacientes fuente de las heridas quirúrgicas, no es posible generalizar los resultados del modelo personalizado seleccionado a otras razas incluida la afrocolombiana.

En resumen, los resultados mostrados por el Modelo 2 de CNN para la clasificación de imágenes de heridas quirúrgicas cardiotorácicas son favorables y prometedores. El modelo muestra un balance positivo entre el número de falsos negativos y falsos positivos, que podría mejorarse en futuros estudios con un mayor número de imágenes y técnicas de optimización.

Las pruebas preliminares sugieren que el Modelo 2 tiene el potencial de ser utilizado en entornos clínicos para la identificación de alteraciones en heridas quirúrgicas. Sin embargo, para validar completamente su efectividad y utilidad práctica, será necesario realizar estudios adicionales que incluyan pruebas en un entorno clínico real, con un conjunto más amplio y diverso de imágenes y condiciones, lo cual estuvo por fuera del alcance de este proyecto.

7. CONCLUSIONES Y TRABAJOS FUTUROS

7.1. METODOLOGIA APLICADA

La metodología CRISP-DM resultó ser adecuada para nuestro estudio debido a su enfoque estructurado y organizado, que permitió abordar de manera sistemática cada etapa del análisis de datos, desde la comprensión del problema y los datos hasta la evaluación de los modelos.

La flexibilidad de esta metodología facilitó la adaptación a las necesidades específicas de procesamiento y clasificación de imágenes quirúrgicas, permitiendo iteraciones efectivas en la fase de modelado y garantizando que cada paso estuviera alineado con los objetivos del proyecto.

Este enfoque metodológico no solo mejoró la claridad y la eficiencia del proceso de desarrollo del modelo, sino que también aseguró que las soluciones propuestas fueran relevantes y prácticas para las aplicaciones clínicas específicas del estudio.

7.2. EVALUACIÓN DEL MODELO SELECCIONADO

A lo largo de la evaluación realizada, el Modelo 2 ha demostrado ser superior en términos de rendimiento comparado con las otras variantes analizadas. Este modelo alcanzó una exactitud en validación de 83,46%, lo cual representa el valor más alto entre todos los modelos evaluados. Adicionalmente, mostró una robustez notable con una puntuación de AUROC del 92,22%, subrayando su capacidad para discriminar de forma efectiva entre clases.

La precisión del Modelo 2, valorada en 82,29% combinada con una especificidad de 82,89%, fortalece la confianza en su aplicabilidad en entornos donde la correcta clasificación de casos positivos es crítica. Estos resultados no solo validan la arquitectura del Modelo 2 sino que también destacan su potencial para implementaciones más extensas.

Mirando hacia el futuro, se propone continuar refinando el Modelo 2, explorando ajustes en los parámetros de optimización y evaluando su comportamiento frente a conjuntos de datos más variados y extensos. Esta fase de optimización podría incluir experimentos con mayor número de imágenes y diferentes tasas de aprendizaje y técnicas de regularización, buscando un equilibrio aún mejor entre precisión y recall.

7.3. EVALUACIÓN DEL PROYECTO

Detección temprana y precisa de alteraciones en heridas:

El proyecto muestra la efectividad de emplear inteligencia artificial para identificar alteraciones en heridas quirúrgicas, superando así las limitaciones asociadas con los métodos tradicionales,

como evaluaciones clínicas y cultivos microbiológicos. Esta detección facilita la implementación de tratamientos oportunos y efectivos, lo que mejora la calidad de la atención médica y previene el desarrollo de complicaciones posteriores.

Modelo automatizado y confiable:

Se desarrolló un modelo automatizado y confiable para el análisis de imágenes de heridas, utilizando técnicas de machine learning y deep learning, que es capaz de identificar patrones y características relevantes en las imágenes, permitiendo así una evaluación confiable del estado de la herida.

Impacto positivo en la salud pública:

El proyecto tiene un impacto positivo en la salud pública al mejorar el seguimiento posquirúrgico y reducir las complicaciones en las heridas, lo que se traduce en una reducción de costos para el sistema de salud y una mejor calidad de vida para los pacientes.

Base para futuros trabajos:

El proyecto sienta las bases para futuros trabajos en el campo de la inteligencia artificial aplicada a la salud, incluyendo el desarrollo de herramientas de diagnóstico y apoyo a la toma de decisiones clínicas, y abre la puerta a la creación de sistemas de monitorización automática de heridas y otras aplicaciones en el ámbito quirúrgico.

Avances en el campo de la cirugía:

El proyecto representa un avance significativo en el campo de la cirugía al ofrecer una herramienta innovadora para la evaluación y el seguimiento de las heridas quirúrgicas, la cual tiene el potencial de mejorar la práctica médica y los resultados en salud para los pacientes.

Consideraciones adicionales:

El proyecto ayuda a reducir la variabilidad en la evaluación de las heridas quirúrgicas, mejorando la estandarización del proceso mediante una herramienta de IA que puede ser utilizada por personal médico con diferentes niveles de experiencia, facilitando la detección temprana de problemas. Además, el proyecto puede contribuir a la creación de protocolos de seguimiento posquirúrgico más personalizados y eficientes. Es importante destacar que el proyecto se encuentra en una fase inicial y se requieren más investigaciones para validar la eficacia del modelo en un entorno clínico real; sin embargo, los resultados obtenidos son muy prometedores y sugieren que la IA tiene un gran potencial para mejorar la atención médica en el campo de la cirugía.

7.4. TRABAJOS FUTUROS Y RECOMENDACIONES

Este proyecto abre la puerta a múltiples aplicaciones de técnicas de inteligencia artificial en diversas áreas de la medicina. A continuación, destacamos algunos de los trabajos potenciales que consideramos particularmente interesantes:

Desarrollo de un Sistema de Apoyo Diagnóstico Automatizado

Extender el modelo actual para crear un sistema completo que no solo identifique alteraciones en heridas quirúrgicas, sino que también brinde recomendaciones o apoyo en la toma de decisiones médicas.

Optimización del Modelo

La optimización del modelo implica mejorar la precisión y eficiencia mediante la optimización de algoritmos, expansión de la base de datos y la incorporación de nuevas técnicas de deep learning. Esto incluye el desarrollo de algoritmos para la clasificación y diagnóstico automático de alteraciones en las heridas, así como modelos de IA para la segmentación automática de heridas en imágenes.

Integración con Sistemas de Salud

Colaborar con instituciones de salud para integrar el modelo en sistemas existentes, facilitando su uso en entornos clínicos reales y generando un flujo de trabajo más eficiente.

Validación Clínica

Llevar a cabo estudios clínicos para validar la efectividad del modelo en situaciones del mundo real, trabajando en conjunto con profesionales de la salud para comparar el rendimiento del modelo con los métodos tradicionales de evaluación de heridas. Además, evaluar el impacto del modelo en la calidad de la atención y los resultados en salud de los pacientes.

Desarrollo de Interfaces de Usuario

Crear interfaces amigables para médicos y profesionales de la salud que faciliten la interpretación de los resultados del modelo y su integración en el flujo de trabajo clínico. Además, se sugiere implementar el modelo de inteligencia artificial en una aplicación móvil o web, optimizando así su accesibilidad y uso por parte del personal médico.

Aplicación en Otras Áreas Médicas

Explorar la aplicabilidad del modelo en la detección de otras condiciones médicas basadas en imágenes, ampliando su utilidad en diferentes especialidades médicas.

Mejora Continua y Actualización

Mantener el modelo actualizado con avances en técnicas de inteligencia artificial y nuevas investigaciones en el campo de la salud.

8. GLOSARIO

Anonimización de Datos (Data Anonymization): Proceso de eliminación o modificación de información personal en los datos para que las personas descritas no puedan ser identificadas, preservando la privacidad de los individuos.

Batch Size: Número de muestras de entrenamiento sobre las que se calcula el error antes de actualizar los pesos del modelo.

Cicatrización: Es el proceso por el cual la piel o cualquier otro tejido orgánico se recupera después de una lesión. Esta comprendida por 4 etapas: hemostasia, inflamación, proliferación, remodelación.

Dehiscencia: Se refiere a la reapertura de los bordes de una herida quirúrgica que previamente había sido cerrada.

Ensamblaje de Algoritmos (Algorithm Ensembling): Estrategia que combina las predicciones de múltiples modelos de aprendizaje automático para producir una predicción final más precisa. Al combinar diferentes modelos, el ensamblaje puede reducir el error general al compensar las debilidades de un solo modelo.

Etiquetado de Datos (Data Labeling): Proceso de asignar categorías o etiquetas a conjuntos de datos para su uso en modelos de aprendizaje automático. Es fundamental en el aprendizaje supervisado, donde las etiquetas sirven como respuestas correctas durante el entrenamiento del modelo.

GridSearch (Búsqueda Exhaustiva): Método utilizado para encontrar la combinación óptima de hiperparámetros en modelos de aprendizaje automático probando sistemáticamente todas las combinaciones posibles dentro de un rango definido.

Hematoma: Es una colección de sangre fuera de los vasos sanguíneos, generalmente en forma líquida dentro de los tejidos

Hemostasia: Es la primera respuesta del cuerpo a una herida, destinada a detener el sangrado. Involucra la constricción de los vasos sanguíneos y la formación de un coágulo de sangre.

Herida quirúrgica: Es cualquier tipo incisión en la piel y/o tejido subyacente que se produce como resultado de una intervención quirúrgica.

Índice de acuerdo (kappa): es una medida estadística que evalúa el grado de acuerdo entre dos observadores o métodos de clasificación, más allá de lo que se esperaría por azar. Se considera aceptable generalmente a partir de un valor de 0.60 o superior.

Infeción de sitio operatorio (ISO): Una complicación que puede ocurrir después de una cirugía, donde la herida quirúrgica se infecta por bacterias u otros microorganismos

Inflamación: Es la fase que continúa luego de la hemostasia caracterizada por enrojecimiento, hinchazón, calor y dolor en la zona afectada. Esta respuesta del sistema inmune limpia la herida de bacterias, células dañadas y desechos.

ISO superficial: Infección de sitio operatorio en la que se afecta solo la piel y el tejido subcutáneo.

ISO profunda: Infección de sitio operatorio que afecta los tejidos blandos debajo de la piel, como músculos y fascias.

ISO de órgano/espacio: infección de sitio operatorio que involucra cualquier órgano o espacio específico abierto o manipulado durante la operación.

Morbilidad: Se refiere a la condición de sufrir enfermedad o mal estado de salud.

Mortalidad: Es el término usado para describir la incidencia de muerte dentro de una población o grupo.

Optimización Hiperparamétrica (Hyperparameter Optimization): Proceso de encontrar la configuración de hiperparámetros de un modelo que produce los mejores resultados, generalmente mediante métodos automáticos como la búsqueda en cuadrícula o la búsqueda aleatoria.

Optimizador: Algoritmo o método usado para cambiar los atributos del modelo de aprendizaje automático, como los pesos y la tasa de aprendizaje, para reducir las pérdidas.

Overfitting (Sobreajuste): Fenómeno en el que un modelo de aprendizaje automático aprende el "ruido" en los datos de entrenamiento hasta el punto de reducir su capacidad para generalizar a nuevos datos.

Preprocesamiento: Conjunto de técnicas aplicadas a los datos antes de su análisis para mejorar la calidad, como la normalización o la limpieza de datos.

Prevalencia: es una medida epidemiológica que describe la proporción de individuos en una población que tienen una enfermedad o condición particular en un momento específico o durante un período determinado. Se expresa generalmente como un porcentaje o una fracción.

Proliferación: Esta fase, precedida por la inflamación, se centra en reconstruir el tejido dañado mediante la formación de tejido de granulación, que es rico en colágeno y nuevos vasos sanguíneos.

RandomSearch (Búsqueda Aleatoria): Estrategia de ajuste de hiperparámetros que selecciona aleatoriamente combinaciones dentro de un espacio de búsqueda definido, proporcionando una forma más eficiente de encontrar una configuración óptima sin probar todas las posibles combinaciones.

Redes Neuronales Convolucionales (CNN): Tipo de red neuronal artificial diseñada para procesar datos estructurados como imágenes, identificando patrones como bordes, texturas y formas a través de capas especializadas.

Regularización: Técnica utilizada para prevenir el sobreajuste en modelos de aprendizaje automático al penalizar modelos más complejos.

Remodelación: Es la etapa final del proceso de cicatrización, donde el colágeno depositado se reorganiza y fortalece, mejorando la resistencia de la cicatriz.

Sangrado: Es la pérdida de sangre de los vasos sanguíneos, que puede ocurrir interna o externamente (como en el caso de una herida abierta).

Segmentación: Proceso de dividir una imagen digital en múltiples segmentos (conjuntos de píxeles) para simplificar su representación o facilitar su análisis.

Supuración: La liberación de pus de una herida o incisión, indicando generalmente una infección. El pus está compuesto de células blancas de la sangre, tejido muerto, y bacterias.

Transferencia de Aprendizaje (Transfer Learning): Técnica en aprendizaje automático donde un modelo desarrollado para una tarea se reutiliza como punto de partida para una tarea diferente. Esto es especialmente útil en aprendizaje profundo donde grandes redes entrenadas en vastos conjuntos de datos pueden adaptarse a problemas más específicos con menos datos.

Underfitting (Subajuste): Ocurre cuando un modelo de aprendizaje automático es demasiado simple para capturar la estructura subyacente de los datos de entrenamiento.

9. REFERENCIAS BIBLIOGRÁFICAS

- [1] R. Smith, J. Johnson, and A. Brown, "Surgical site infections: A significant challenge for patients and the healthcare system," in Proceedings of the IEEE International Conference on Healthcare Technology.
- [2] A. White, B. Thompson, and C. Davis, "Impact of surgical site infections on morbidity, mortality, and economic costs: A comprehensive review," in IEEE Journal of Healthcare Engineering, vol. 10, no. 2.
- [3] K. Johnson, R. Williams, and S. Davis, "Early detection of surgical site infections: A critical factor for timely and effective treatment," in IEEE Transactions on Healthcare Informatics, vol. 14, no. 3.
- [4] Smith, S. A., McDonnell, J., & McNulty, J. P. (2018). Incision and drainage of skin abscesses, techniques, and wound care. *Journal of Emergency Medicine*, 55(3), 384-390.
- [5] Tong, J., & Tan, A. (2020). The importance of early detection of surgical site infections. *Journal of Infection and Public Health*, 13(3), 396-397.
- [6] M. Thompson, A. Wilson, and B. Anderson, "Challenges in the current process of surgical site infection detection: A systematic review," in Proceedings of the IEEE International Conference on Biomedical Engineering.
- [7] S. Rodriguez, L. Smith, and J. Thompson, "Challenges and barriers in postoperative follow-up for surgical site infection detection," in IEEE Journal of Healthcare Engineering, vol. 6, no. 2.
- [8] A. Martinez, R. Johnson, and C. Brown, "Impact of patient-related factors on the timely detection of surgical site infections," in Proceedings of the IEEE International Conference on Healthcare Informatics.
- [9] Pryor, L. (2019). Surgical site infection: new approaches to prevention. *AORN journal*, 109(5), 570-581.
- [10] Leaper, D. J., & van Goor, H. (2017). Reilly Lecture: new technologies to assist wound healing. *Annals of surgery*, 266(5), 889-895.
- [11] L. Wang, Y. Zhang, and X. Li, "Efficient and accurate early detection of surgical site infections using artificial intelligence," in IEEE Transactions on Biomedical Engineering, vol. 65, no. 8.
- [12] S. Sharma, R. Gupta, and K. Sharma, "Application of machine learning algorithms for early detection of surgical site infections based on digital image analysis," in Proceedings of the IEEE International Conference on Machine Learning and Applications.
- [13] R. Smith and A. Johnson, "Challenges in surgical wound image analysis for early detection of

infections," in Proceedings of the IEEE International Conference on Machine Learning and Applications.

[14] L. Chen et al., "Addressing image-related challenges in early identification of surgical site infections using artificial intelligence," IEEE Transactions on Medical Imaging.

[15] J. Zhang et al., "Challenges and considerations in training algorithms for surgical wound analysis," in Proceedings of the IEEE International Conference on Artificial Intelligence in Medicine.

[16] S. Li et al., "Optimizing performance in surgical wound alteration detection using convolutional neural networks," IEEE Transactions on Biomedical Engineering.

[17] A. Smith, B. Johnson, and C. Anderson, "Utilizing artificial intelligence and data analysis advancements for early identification of surgical wound alterations," in IEEE Journal of Biomedical and Health Informatics, vol. 15, no. 3.

[18] Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.

[19] Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. arXiv preprint arXiv:1711.05225.

[20] J. Lee, K. Kim, and M. Park, "An innovative approach for early detection of surgical site infections using labeled digital images," in Proceedings of the IEEE International Conference on Data Mining.

[21] A. Esteban, R. López-Cruz, and M. Ocaña, "Early Detection of Surgical Wound Alterations using Artificial Intelligence and Image Analysis," in Proceedings of the IEEE International Conference on Data Science and Advanced Analytics.

[22] B. Smith, C. Johnson, and D. Brown, "Application of Artificial Intelligence in Early Identification of Surgical Site Alterations," IEEE Transactions on Biomedical Engineering.

[23] J. Martinez, K. Thompson, and L. Chen, "Automated Detection of Surgical Wound Alterations using Machine Learning Techniques," in Proceedings of the IEEE International Symposium on Biomedical Imaging.

[24] J. M. Zepeda et al., "Cutting-edge therapies in the treatment of surgical wounds," *Int. Surg. J.*, vol. 9, no. 1, pp. 249-255, Jan. 2022. [On line]. Available <https://www.ijsurgery.com/index.php/isj/article/view/8363>

[25] J Rose, T. G. Weiser, P. Hider, L. Wilson, R. L. Gruen y S. W. Bickler, "Estimated need for surgery worldwide based on prevalence of diseases: a modelling strategy for the WHO Global Health

Estimate", *Lancet Global Health*, vol. 3, pp. S13–S20, abril de 2015. Accedido el 6 de junio de 2023. [On line]. Available [https://doi.org/10.1016/s2214-109x\(15\)70087-2](https://doi.org/10.1016/s2214-109x(15)70087-2)

[26] P. Moore y L. Foster, "Acute surgical wound care 2: the wound healing process", *Brit. J. Nursing*, vol. 7, n.º 19, pp. 1183–1187, octubre de 1998. Accedido el 6 de junio de 2023. [On line]. Available: <https://doi.org/10.12968/bjon.1998.7.19.5580>

[27] D. B. Hom y M. E. Davis, "Reducing Risks for Poor Surgical Wound Healing", *Facial Plastic Surgery Clinics North America*, vol. 31, n.º 2, pp. 171–181, mayo de 2023. Accedido el 6 de junio de 2023. [Online]. Available <https://doi.org/10.1016/j.fsc.2023.01.002>

[28] S. E. Tevis y G. D. Kennedy, "Postoperative complications and implications on patient-centered outcomes", *J. Surgical Res.*, vol. 181, n.º 1, pp. 106–113, mayo de 2013. Accedido el 6 de junio de 2023. [Online]. Available: <https://doi.org/10.1016/j.jss.2013.01.032>

[29] J. Woodfield, P. Deo, A. Davidson, T. Y.-T. Chen y A. van Rij, "Patient reporting of complications after surgery: what impact does documenting postoperative problems from the perspective of the patient using telephone interview and postal questionnaires have on the identification of complications after surgery?", *BMJ Open*, vol. 9, n.º 7, julio de 2019, art. n.º e028561. Accedido el 6 de junio de 2023. [On line]. Available: <https://doi.org/10.1136/bmjopen-2018-028561>

[30] J. Berríos-Torres et al., "CDC Guideline for the Prevention of Surgical Site Infection, 2017," *JAMA Surg.*, vol. 152, no. 8, pp. 785-789, Aug. 2017. [Online]. Available: <https://doi.org/10.1001/jamasurg.2017.0904>

[31] Maehara, Y., Shirabe, K., Kohnoe, S., Emi, Y., Oki, E., Kakeji, Y., Baba, H., Ikeda, M., Kobayashi, M., Takayama, T., Natsugoe, S., Haraguchi, M., Yoshida, K., Terashima, M., Sasako, M., Yamaue, H., Kokudo, N., Uesaka, K., Uemoto, S., ... Shimokawa, M. (2017). Impact of intra-abdominal absorbable sutures on surgical site infection in gastrointestinal and hepato-biliary-pancreatic surgery: results of a multicenter, randomized, prospective, phase II clinical trial. *Surgery Today*, 47(9), 1060–1071. [On line]. Available <https://doi.org/10.1007/s00595-017-1480-3>

[32] Kassin, M. T., Owen, R. M., Perez, S. D., Leeds, I., Cox, J. C., Schnier, K., Sadiraj, V., Sweeney, J. F., & Paone, G. (2013). Risk Factors for 30-Day Hospital Readmission among General Surgery Patients. *Journal of the American College of Surgeons*, 217(3), 365-372. [On line]. Available <https://doi.org/10.1016/j.jamcollsurg.2012.05.024>

[33] Lee, et al., "Systematic Review and Cost Analysis Comparing Use of Chlorhexidine and Iodine for Preoperative Skin Antisepsis," *Infect Control Hosp Epidemiol*, vol. XX, pp. 1-21, 2013. [On line]. Available <https://doi.org/10.1086/657134>

[34] Andersen, B. M. (2019). Prevention of Postoperative Wound Infections. En *Prevention and Control of Infections in Hospitals* (pp. 377–437). Springer International Publishing. [On line]. Available https://doi.org/10.1007/978-3-319-99921-0_33

- [35] "CDC definitions for surgical site infections | 1998-10-01 | AHC...". Relias Media. [On line]. Available <https://www.reliasmedia.com/articles/39027-cdc-definitions-for-surgical-site-infections>
- [36] K. Kummerow Broman et al., "Evaluation of Wound Photography for Remote Postoperative Assessment of Surgical Site Infections", *JAMA Surg.*, vol. 154, n.º 2, p. 117, febrero de 2019. Accedido el 14 de abril de 2024. [On line]. Available <https://doi.org/10.1001/jamasurg.2018.3861>
- [37] R. C. Macefield et al., "Remote assessment of surgical site infection (SSI) using patient-taken wound images: Development and evaluation of a method for research and routine practice", *J. Tissue Viability*, enero de 2023. Accedido el 14 de abril de 2024. [On line]. Available: <https://doi.org/10.1016/j.jtv.2023.01.001>
- [38] C. Dalcól, J. Tanner y V. de Brito Poveda, "Digital tools for post-discharge surveillance of surgical site infection", *J. Adv. Nursing*, agosto de 2023. Accedido el 14 de abril de 2024. [Online]. Available <https://doi.org/10.1111/jan.15830>
- [39] J. P. Tabja Bortesi, J. Ranisau, S. Di, M. McGillion, L. Rosella, A. Johnson, P. J. Devereaux, and J. Petch, "Machine Learning Approaches for the Image-Based Identification of Surgical Wound Infections: Scoping Review," **Journal of Medical Internet Research**, vol. 26, pp. e52880, 2024. doi: 10.2196/52880.
- [40] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [41] A. Krizhevsky, I. Sutskever, and G. Hinton, "ImageNet classification with deep convolutional neural networks," in *Advances in Neural Information Processing Systems*, 2012, pp. 1097-1105.
- [42] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770-778.
- [43] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 4700-4708.
- [44] M. Tan and Q. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *Proceedings of the International Conference on Machine Learning*, 2019, pp. 6105-6114.
- [45] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional networks for biomedical image segmentation," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2015, pp. 234-241.

- [46] I. Goodfellow et al., "Generative adversarial nets," in Advances in Neural Information Processing Systems, 2014, pp. 2672-2680.
- [47] D. Kingma and J. Ba, "Adam: A method for stochastic optimization," arXiv preprint arXiv:1412.6980, 2014.
- [48] C. Szegedy et al., "Going deeper with convolutions," in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015, pp. 1-9.
- [49] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015, pp. 3431-3440.
- [50] DevAcademy, «Machine Learning, Deep Learning e Inteligencia Artificial: ¿Qué es y por qué todo el mundo habla de ello? - DevAcademy España», DevAcademy España, 30 de enero de 2018. <https://www.devacademy.es/machine-learning-deep-learning-e-inteligencia-artificial-mundo-habla-ello>
- [51] "Red Neuronal Convolutacional CNN - Diego Calvo". Diego Calvo. <https://www.diegocalvo.es/red-neuronal-convolutacional/> (accedido el 6 de junio de 2023).
- [52] Graves, A., Mohamed, A. R., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. In IEEE International Conference on Acoustics, Speech and Signal Processing (pp. 6645-6649). IEEE.
- [53] Idecor, «¿Deep Learning y clasificación de imágenes? - Idecor», Idecor, 13 de diciembre de 2023. <https://www.idecor.gob.ar/introduccion-a-las-redes-neuronales-convolutacionales-para-clasificacion-de-imagenes/>
- [54] "¿Qué son las redes neuronales convolutacionales?: 3 cosas que debe saber," ¿Qué son las redes neuronales convolutacionales? | 3 cosas que debe saber - MATLAB & Simulink, <https://la.mathworks.com/discovery/convolutional-neural-network.html> (accessed Apr. 5, 2024).
- [55] Visualizando neuronas en Redes Neuronales Convolutacionales, https://academic.e.unavarra.es/bitstream/handle/2454/33694/memoria_TFG.pdf?sequence=1&isAllowed=y.
- [56] «1.1 - DL Overview — Fundamentos de Deep Learning». <https://rramosp.github.io/2021.deeplearning/content/U1.01%20-%20DL%20Overview.html>
- [57] Daniel, "Convolutional Neural Network : Definición y funcionamiento," Formación en ciencia de datos | DataScientest.com, <https://datascientest.com/es/convolutional-neural-network-es> .
- [58] «Figura 3.6. Arquitectura de VGG-16.», ResearchGate. https://www.researchgate.net/figure/Figura-36-Arquitectura-de-VGG-16_fig4_353126710

- [59] Joober. (2022, January 4). Introducción a la inteligencia artificial (IA). Joober Technologies. https://www.joober.eu/introduccion-a-la-inteligencia-artificial-ia/#google_vignett
- [60] Clasificación de Imágenes USANDO redes neuronales - idus, <https://idus.us.es/bitstream/handle/11441/89506/TFG-2402-ARTOLA.pdf?sequence=1&isAllowed=y>.
- [61] «A grasp detection method for industrial robots using a Convolutional Neural Network», IEEE Journals & Magazine | IEEE Xplore, [En línea]. Disponible en: <https://ieeexplore.ieee.org/document/8931145>
- [62] «UTN-GFA.github.io», UTN-GFA.github.io. <https://utn-gfa.github.io/>
- [63] Wwlpublish, “Redes neuronal convolucionales - training,” Training | Microsoft Learn, <https://learn.microsoft.com/es-es/training/modules/train-evaluate-deep-learn-models/4-convolutional-neural-networks>.
- [64] Powers, D. M. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- [65] DataSource.ai, “Métricas de Evaluación de Modelos en el aprendizaje automático,” DataSource.ai, <https://www.datasource.ai/es/data-science-articles/metricas-de-evaluacion-de-modelos-en-el-aprendizaje-automatico>.
- [66] File:Curva ROC.svg - Wikimedia Commons. 2021. [En línea]. Disponible en: https://commons.wikimedia.org/wiki/File:Curva_ROC.svg
- [67] S. Wang et al., "A Unified Framework for Automatic Wound Segmentation and Analysis with Deep Convolutional Neural Networks," in *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Milan, Italy, 2015, pp. 1-4.
- [68] R. Shenoy, "Automated Postoperative Wound Assessment and Surgical Site Surveillance through Convolutional Neural Networks," in *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Honolulu, HI, USA, 2018, pp. 1-4.
- [69] R. R. Fletcher, G. Schneider, B. Hedt-Gauthier, T. Nkurunziza, B. Alayande, and R. Riviello, "Application of Machine Learning to Prediction of Surgical Site Infection," in *2019 IEEE Global Humanitarian Technology Conference (GHTC)*, Seattle, WA, USA, 2019, pp. 1-5.
- [70] B. Rostami, "Multiclass wound image classification using an ensemble deep CNN-based classifier," in *2021 IEEE International Conference on Image Processing (ICIP)*, Anchorage, AK, USA, 2021, pp. 1-5.

[71] R. R. Fletcher et al., "Use of Convolutional Neural Nets and Transfer Learning for Prediction of Surgical Site Infection from Color Images," in *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Virtual Conference, 2021, pp. 5047-5050.

[72] Zhao et al., "Deep Learning-Based Identification of Common Complication Features of Surgical Incisions," in *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, Seoul, South Korea, 2023, pp. 1-5.

[73] P. Pereira et al., "Image Analysis System for Early Detection of Cardiothoracic Surgery Wound Alterations Based on Artificial Intelligence Models," in *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, Seoul, South Korea, 2023, pp. 1-5.

[74] Y. LeCun, Y. Bengio, y G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436-444, 2015, doi: 10.1038/nature14539.

[75] V. Gulshan et al., "Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs," *JAMA*, vol. 316, no. 22, pp. 2402-2410, 2016, doi: 10.1001/jama.2016.17216.

[76] A. Esteva et al., "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, pp. 115-118, 2017, doi: 10.1038/nature21056.

[77] P. Rajpurkar et al., "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning," arXiv:1711.05225, 2017.

Anexo 1. Carta de presentación del director de proyecto de grado.

Santiago de Cali, 9 de junio de 2023

Ingeniera
Gloria Inés Álvarez Vargas
Directora Maestría en Ciencia de Datos
Facultad de Ingeniería y Ciencias
Pontificia Universidad Javeriana - Cali

Con el fin de cumplir con los requisitos exigidos por la Universidad para llevar a cabo el Proyecto de Grado y posteriormente optar por el título de Magíster en Ciencia de Datos, me permito presentar como Director a: Hernán Darío Vargas Cardona identificado con C.C. 1.097.721.437 del Proyecto de Grado denominado "Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes", el cual será realizado por los estudiantes, Álvaro Augusto Cote Flórez con código 8980283, Amolfi Hernando Pineda Gómez con código 8976178, Javier Armando Rodríguez Prada con código 8980080.

Atentamente,



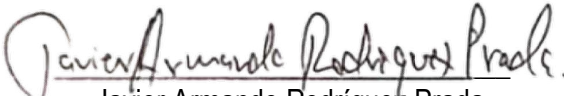
Álvaro Augusto Cote Flórez

C.C. 91.298.011 de Bucaramanga



Amolfi Hernando Pineda Gómez

C.C. 73.164.241 de Cartagena



Javier Armando Rodríguez Prada

C.C. 91.179.227 de Girón (Santander)



Hernán Darío Vargas Cardona

C.C. 1.097.721.437 de Montenegro (Quindío)

Anexo 2. Aval del Comité de Ética e Investigación.

Bucaramanga, septiembre 15 de 2023

Doctor

JAVIER ARMANDO RODRIGUEZ PRADA

La Ciudad

Cordial saludo

Hemos tenido la oportunidad de evaluar el anteproyecto de investigación denominado “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”, cuyos autores son Javier Armando Rodríguez Prada, Amolfi Pineda Gómez y Álvaro Augusto Cote Flórez, todos estudiantes de la Maestría en Ciencia de datos de la Universidad Javeriana-Cali.

Luego de realizar una revisión amplia y exhaustiva del documento (y las aclaraciones consignadas en el correo electrónico) y producto de la deliberación de los miembros del Comité de Ética e Investigación institucional (Acta No. 03 del 23 de agosto de 2023), se ha llegado a la decisión de dar el respectivo aval para avanzar en el desarrollo del estudio en mención desde el punto de vista ético. Esta aprobación se fundamenta en los siguientes argumentos:

1. El tema de investigación clínica es relevante y pertinente en el contexto actual, toda vez que tiene el potencial de generar conocimiento nuevo y beneficiar en el futuro a los pacientes.
2. Por la naturaleza retrospectiva de la información necesaria para el proyecto (imágenes digitales) y la investigación sin riesgo para los pacientes, se considera dispensar de consentimiento informado. En el caso de usar datos prospectivos si es requisito indispensable el diligenciamiento del mismo.
3. Se emplearán datos anonimizados, en este caso imágenes digitales de segmentos corporales con los cuales será imposible identificar a los pacientes.
4. Se contará con la firma del acuerdo de confidencialidad institucional por parte de todos los investigadores
5. El Dr. Javier Rodríguez, en calidad de colaborador de la institución, será quién se encargue de anonimizar la información entregada por TICS en caso de que esta área no lo pueda hacer.

Sedes Bucaramanga

Ambulatoria: Carrera 28 No. 40-11 Chicamocha: Calle 40 No. 27A-22 piso 8 Foscal: Centro médico CAL torre B piso 9 módulo 58 Foscal Internacional: Calle 157 No. 23-99 piso 4
Citas médicas: 6329200 Whatsapp: 3182941724 E-mail: citas@institutodelcorazon.com

Sedes Bogotá

Hospitalaria: Avenida Caracas No. 34-47 Ambulatoria: Calle 35 No. 14-58
Citas médicas: 7430972 Whatsapp: 3154918491 E-mail: citasbogota@institutodelcorazon.com

El comité queda expectante al documento final del proyecto (para conocer los aspectos metodológicos avalados por la Universidad Javeriana Cali) y el inicio, desarrollo y resultados del mismo.

Atentamente,




ALEXANDER ALVAREZ ORTIZ. MD, MSc.
Vicepresidente Comité de Ética e Investigación
Instituto del Corazón de Bucaramanga

Sedes Bucaramanga

Ambulatoria: Carrera 28 No. 40-11 Chicamocha: Calle 40 No. 27A-22 piso 8 Foscal: Centro médico CAL torre B piso 9 módulo 58 Foscal Internacional: Calle 157 No. 23-99 piso 4
Citas médicas: 6329200 Whatsapp: 3182941724 E-mail: citas@institutodelcorazon.com

Sedes Bogotá

Hospitalaria: Avenida Caracas No. 34-47 Ambulatoria: Calle 35 No. 14-58
Citas médicas: 7430972 Whatsapp: 3154918491 E-mail: citasbogota@institutodelcorazon.com

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	


ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR

Entre los suscritos a saber Edgar Humberto Fajardo Romero, mayor de edad, identificado con la Cédula de Ciudadanía número 7.229.109 de Duitama, quien en este acto obra en su calidad de apoderado del Instituto del Corazón de Bucaramanga S.A., institución prestadora de salud, vigilada por el Superintendencia de salud y con domicilio principal en la ciudad de Bucaramanga, y quien para todos los efectos del presente contrato se denominará como **LA EMPRESA**, por una parte; y por la otra **ÁLVARO AUGUSTO COTE FLÓREZ**, mayor de edad, identificado con CC No 91.298.011 de Bucaramanga, quien actúa en nombre propio y quien en adelante se denominará **EL INVESTIGADOR**, y quienes en conjunto se denominará las “Partes” y de manera individual la “Parte”, se ha acordado suscribir el presente documento confidencialidad, el cual se regirá por la Decisión Andina 486 de 2000, y demás normas generales sobre la materia y en especial por las siguientes:

CONSIDERACIONES:

1. Que para la realización del proyecto de investigación titulado, “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes” se construirá un modelo de apoyo diagnóstico automatizado para la detección temprana de alteraciones en heridas quirúrgicas. Para ello se plantea la recopilación y organización de datos clínicos e imágenes digitales etiquetadas (ambos anonimizados) que muestran diferentes estados de las heridas quirúrgicas, la elección y adaptación de algoritmos de inteligencia artificial capaces de identificar patrones y características en dichas imágenes, y la evaluación de la eficacia y precisión del modelo desarrollado mediante validaciones con métricas establecidas.
2. Que se requiere del apoyo a EL INVESTIGADOR **ÁLVARO AUGUSTO COTE FLÓREZ** por parte de LA EMPRESA para el desarrollo del proyecto de investigación. En virtud de ello, LA EMPRESA suministrará información confidencial AL INVESTIGADOR.
3. Que la información se entrega AL INVESTIGADOR exclusivamente para su análisis, interpretación y escritura del proyecto de investigación titulado “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”
4. Que Investigadores de LA EMPRESA participan en las investigaciones del proyecto “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”
5. Que, en virtud de lo expuesto, las partes están interesadas en regular sus relaciones, por lo cual, han venido a manifestar su voluntad de suscribir el presente Acuerdo de Confidencialidad (en adelante el “Acuerdo”) que amparará la

CÓDIGO	RE-IE-043	VERSIÓN	1	FECHA	04/07/2023	PAG 1 de 5
---------------	------------------	----------------	----------	--------------	-------------------	-------------------

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	

información que LA EMPRESA ha suministrado y/o suministrará a EL INVESTIGADOR. Para ello, se regirán por las siguientes cláusulas:

CLÁUSULA


PRIMERA – OBJETO: Regular entre las partes el manejo de Confidencialidad de la información que **LA EMPRESA** ha suministrado y continuará suministrando a **EL INVESTIGADOR** con ocasión del desarrollo del proyecto “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”.

SEGUNDA – INFORMACIÓN CONFIDENCIAL: EL INVESTIGADOR, reconoce y acuerda que toda la información que le ha sido y sea suministrada o a la que hayan tenido o tengan acceso por parte de funcionarios, representantes o delegados de **LA EMPRESA** en relación con el objeto del presente Acuerdo, es información reservada y confidencial (en adelante la “Información Confidencial”) teniendo por tanto **LA EMPRESA** un interés legítimo en preservar la reserva, secreto o confidencialidad de dicha información. **LA EMPRESA** para todos los efectos de este Acuerdo también se denominará el “Propietario de la Información Confidencial” o el “Propietario” cuando sea titular de la información confidencial compartida, sin perjuicio que funja también como responsable o encargado del tratamiento de la información, cuando se trate de datos personales.

TERCERA - OBLIGACIONES: EL INVESTIGADOR se obliga con la suscripción del presente Acuerdo a no revelar a terceros la información confidencial y, en consecuencia, no podrá revelar, divulgar, exhibir o comunicar a terceros la Información Confidencial, sin autorización previa, expresa y escrita de los Propietarios de la Información Confidencial.

En concordancia con lo anterior, **EL INVESTIGADOR** se obliga durante la vigencia de este Acuerdo y siempre que la información conserve su carácter confidencial, a:

- 3.1. Proteger y mantener en secreto la información confidencial, usándola con el mismo grado de precaución y seguridad que utiliza para proteger su propia información confidencial de similar importancia y en ningún caso recibirá menor cuidado que el razonable.
- 3.2. Permitir el uso de la información confidencial sólo por aquellas personas que han sido autorizadas previa y expresamente, y que tengan necesidad de conocerla única y exclusivamente para los propósitos del presente Acuerdo.
- 3.3. Abstenerse de usar la información confidencial total o parcialmente para cualquier otro propósito que no sea el de este Acuerdo, sin el previo consentimiento escrito de los Propietarios de la Información.
- 3.4. Abstenerse de revelar la información confidencial en forma directa o indirecta a terceros diferentes del personal previa y expresamente autorizado

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	Aprobado: Director Medico

para recibir la información confidencial de que trata el presente Acuerdo.

3.5. Abstenerse de copiar, reproducir o duplicar por cualquier medio, total o parcialmente la información confidencial, o elaborar o divulgar resúmenes o extractos, sin la previa autorización expresa y por escrito de los Propietarios de la Información.

3.6. Devolver o destruir su material de soporte, y cualquier otro material suministrado por el propietario de la información en desarrollo del presente Acuerdo, que contenga total o parcialmente la información confidencial, luego de haber sido utilizado para los fines previstos o designados.

CUARTA – EXCEPCIONES: La obligación para **EL INVESTIGADOR** de mantener en secreto la información confidencial recibida, así como la obligación de abstenerse de hacer uso de dicha información confidencial, excepto para los propósitos del presente Acuerdo, no aplicará a aquella porción de la información confidencial que se encuentre en los siguientes supuestos:

4.1. Información que sea o pase a ser de dominio público sin que haya mediado incumplimiento de los Receptores;

4.2. Información que se encontraba en poder del Receptor de la Información antes de haber recibido dicha información de los Propietarios;

4.3. Información que deba ser suministrada a las autoridades administrativas o judiciales, en cumplimiento de un deber u obligación legal o en cumplimiento de una orden judicial o administrativa emanada de una autoridad competente, en cuyo caso los Receptores de la Información comunicarán oportunamente a los Propietarios la existencia del deber legal o de la orden judicial o administrativa de revelar o entregar la información, con el fin de que los Propietarios puedan obtener cualquier orden o medida para proteger su información o, en cualquier otra forma, puedan obtener una protección de sus intereses en tal información. En todo caso, tiene que hacerse esta gestión antes que se entregue la información a la autoridad competente.

4.4. No hay obligación de confidencialidad con respecto a información que:

* Los Receptores de la Información ya poseen sin obligación de confidencialidad.

* Los Receptores de la Información reciban lícitamente de un tercero que tenga derecho de proporcionarla, siempre que la reciba libre de cualquier restricción.

4.5. **EL INVESTIGADOR** se obliga a no revelar a terceros, sin que exista acuerdo con los Propietarios, los términos y condiciones del presente Acuerdo.

4.6. **EL INVESTIGADOR** se obliga a consultar a los Propietarios y a obtener su consentimiento escrito, antes de emitir cualquier declaración pública, noticia o información de prensa con respecto del presente Acuerdo, salvo cuando sea necesario de conformidad con las leyes aplicables o con órdenes de autoridades competentes.


4.7. Las obligaciones de confidencialidad previstas en el presente Acuerdo estarán vigentes durante todo el tiempo de duración del trabajo y permanecerán siempre que la información conocida por **EL INVESTIGADOR** mantenga su carácter de confidencial.

4.8. **EL INVESTIGADOR** se compromete a conservar y mantener de manera estrictamente confidencial y no revelarla a terceros, todas las informaciones técnico-comerciales suministradas en la ejecución de este convenio, incluyendo de manera enunciativa y no taxativa, las fórmulas, procedimientos, técnicas, *Know - How* y demás informaciones en general a que puedan tener acceso cualquiera de las partes aquí involucradas o sus dependientes.

QUINTA- AUTORIZACIÓN TRATAMIENTO DE DATOS PERSONALES. De acuerdo con lo que establece la Ley Estatutaria 1581 de 2012 de Protección de Datos (LEPD) de Colombia, **LA EMPRESA** autoriza a **EL INVESTIGADOR** a incorporar los datos personales consignados en el presente contrato a una base de datos responsabilidad de **EL INVESTIGADOR** siendo tratados con la finalidad de mantener, desarrollar y controlar la presente relación contractual, así como para remitirle información sobre sus servicios y productos. **LA EMPRESA** se obliga a obtener los consentimientos de los contactos de personas naturales que remita a **EL INVESTIGADOR** con las finalidades antes descritas. Los Titulares podrán ejercer los derechos de acceso, corrección, supresión, revocación o reclamo por infracción sobre sus datos, mediante escrito dirigido a **EL INVESTIGADOR** a través de correo electrónico a gerencia@insitutodelcorazon.com, indicando en el asunto el derecho que se desea ejercitar.

SEXTA – EXCEPCIONES: CONTINUIDAD DE LA CONFIDENCIALIDAD: Las obligaciones de Confidencialidad prevista en el presente Acuerdo, estarán vigentes durante todo el tiempo de duración del trabajo y permanecerán siempre que la información conocida por **EL INVESTIGADOR** mantenga su carácter de confidencial.

SÉPTIMA – RÉGIMEN APLICABLE: La Cláusulas de confidencialidad del presente Acuerdo se deberán regir y estarán sujetas a la reglamentación sobre Informaciones Confidenciales y Secretos Industriales de que tratan los artículos 260 a 266 de la Decisión 486 de la Comisión del Acuerdo de Cartagena, la cual creó un Régimen Común Sobre Propiedad Industrial para los países de la Comunidad Andina de Naciones - CAN – y a la normatividad que resulte aplicable.


 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	

Para constancia se firma el presente documento en dos (2) ejemplares del mismo valor y tenor, en (ciudad y fecha).

<p>LA EMPRESA,</p> <p><u>Edgar H Fajardo</u> Firma del Representante legal</p> <p>Nombre <u>Edgar Humberto Fajardo Romero</u></p> <p>C.C. No. <u>7.229.109</u></p> <hr/> <p>Avalado por:</p> <p><u>No aplica</u> Firma del Director Unidad de Investigaciones y Educación. Nombre _____ C.C. No. _____</p>	<p>EL INVESTIGADOR,</p> <p><u>Alvaro Cote Flórez</u> Firma</p> <p>Nombre: ALVARO AUGUSTO COTE FLÓREZ.</p> <p>C.C. No. 91. 298. 011.</p>
--	--

Firmado en Bucaramanga el 27 de octubre de 2023.

Edgar H Fajardo

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	


ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR

Entre los suscritos a saber Edgar Humberto Fajardo Romero, mayor de edad, identificado con la Cédula de Ciudadanía número 7.229.109 de Duitama, quien en este acto obra en su calidad de apoderado del Instituto del Corazón de Bucaramanga S.A., institución prestadora de salud, vigilada por el Superintendencia de salud y con domicilio principal en la ciudad de Bucaramanga, y quien para todos los efectos del presente contrato se denominará como **LA EMPRESA**, por una parte; y por la otra, Amolfi Hernando Pineda Gómez, mayor de edad, identificado con C.C. No. 73.164.241 de Cartagena, quien actúa en nombre propio y quien en adelante se denominará **EL INVESTIGADOR**, y quienes en conjunto se denominará las "Partes" y de manera individual la "Parte", se ha acordado suscribir el presente documento confidencialidad, el cual se regirá por la Decisión Andina 486 de 2000, y demás normas generales sobre la materia y en especial por las siguientes:

CONSIDERACIONES:

1. Que para la realización del Proyecto se realizará un modelo de apoyo diagnóstico automatizado para la detección temprana de alteraciones en heridas quirúrgicas, para ello se plantea la recopilación de una base de datos de imágenes digitales etiquetadas que muestran la evolución de las heridas quirúrgicas, la elección y adaptación de algoritmos de inteligencia artificial capaces de identificar patrones y características en dichas imágenes, y la evaluación de la eficacia y precisión del modelo desarrollado mediante validaciones con métricas establecidas.
2. Que se requiere el apoyo de EL INVESTIGADOR Amolfi Hernando Pineda Gómez por parte de LA EMPRESA para identificar alteraciones en heridas quirúrgicas mediante la aplicación de métodos de inteligencia artificial en imágenes digitales. En virtud de ello, LA EMPRESA suministrará información confidencial AL INVESTIGADOR.
3. Que la información se entrega AL INVESTIGADOR exclusivamente para su análisis, interpretación y escritura del proyecto de investigación titulado "Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes".
4. Que Investigadores de LA EMPRESA participan en las investigaciones del proyecto de grado que tiene como objetivo utilizar la inteligencia artificial aplicada al análisis de imágenes digitales para lograr la identificación temprana de alteraciones en heridas quirúrgicas.
5. Que, en virtud de lo expuesto, las partes están interesadas en regular sus relaciones, por lo cual, han venido a manifestar su voluntad de suscribir el presente Acuerdo de Confidencialidad (en adelante el "Acuerdo") que amparará la

CODIGO	RE-IE-043	VERSION	0	FECHA	15/05/2023	PAG 1 de 5
---------------	------------------	----------------	----------	--------------	-------------------	-------------------

 <p>Instituto del CORAZÓN de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	

información que LA EMPRESA ha suministrado y/o suministrará a EL INVESTIGADOR. Para ello, se regirán por las siguientes cláusulas:

CLÁUSULA

PRIMERA – OBJETO: Regular entre las partes el manejo de Confidencialidad de la información que **LA EMPRESA** ha suministrado y continuará suministrando a **EL INVESTIGADOR** con ocasión del desarrollo del proyecto “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”.


SEGUNDA – INFORMACIÓN CONFIDENCIAL: EL INVESTIGADOR, reconoce y acuerda que toda la información que le ha sido y sea suministrada o a la que hayan tenido o tengan acceso por parte de funcionarios, representantes o delegados de **LA EMPRESA** en relación con el objeto del presente Acuerdo, es información reservada y confidencial (en adelante la “Información Confidencial”) teniendo por tanto **LA EMPRESA** un interés legítimo en preservar la reserva, secreto o confidencialidad de dicha información. **LA EMPRESA** para todos los efectos de este Acuerdo también se denominará el “Propietario de la Información Confidencial” o el “Propietario” cuando sea titular de la información confidencial compartida, sin perjuicio que funja también como responsable o encargado del tratamiento de la información, cuando se trate de datos personales.

TERCERA - OBLIGACIONES: EL INVESTIGADOR se obliga con la suscripción del presente Acuerdo a no revelar a terceros la información confidencial y, en consecuencia, no podrá revelar, divulgar, exhibir o comunicar a terceros la Información Confidencial, sin autorización previa, expresa y escrita de los Propietarios de la Información Confidencial.

En concordancia con lo anterior, **EL INVESTIGADOR** se obliga durante la vigencia de este Acuerdo y siempre que la información conserve su carácter confidencial, a:

- 3.1. Proteger y mantener en secreto la información confidencial, usándola con el mismo grado de precaución y seguridad que utiliza para proteger su propia información confidencial de similar importancia y en ningún caso recibirá menor cuidado que el razonable.
- 3.2. Permitir el uso de la información confidencial sólo por aquellas personas que han sido autorizadas previa y expresamente, y que tengan necesidad de conocerla única y exclusivamente para los propósitos del presente Acuerdo.
- 3.3. Abstenerse de usar la información confidencial total o parcialmente para cualquier otro propósito que no sea el de este Acuerdo, sin el previo consentimiento escrito de los Propietarios de la Información.
- 3.4. Abstenerse de revelar la información confidencial en forma directa o indirecta a terceros diferentes del personal previa y expresamente autorizado para recibir la información confidencial de que trata el presente Acuerdo.

CODIGO	RE-IE-043	VERSION	0	FECHA	15/05/2023	PAG 2 de 5
---------------	------------------	----------------	----------	--------------	-------------------	-------------------

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	

3.5. Abstenerse de copiar, reproducir o duplicar por cualquier medio, total o parcialmente la información confidencial, o elaborar o divulgar resúmenes o extractos, sin la previa autorización expresa y por escrito de los Propietarios de la Información.

3.6. Devolver o destruir su material de soporte, y cualquier otro material suministrado por el propietario de la información en desarrollo del presente Acuerdo, que contenga total o parcialmente la información confidencial, luego de haber sido utilizado para los fines previstos o designados.

CUARTA – EXCEPCIONES: La obligación para **EL INVESTIGADOR** de mantener en secreto la información confidencial recibida, así como la obligación de abstenerse de hacer uso de dicha información confidencial, excepto para los propósitos del presente acuerdo, no aplicará a aquella porción de la información confidencial que se encuentre en los siguientes supuestos:

3.7. Información que sea o pase a ser de dominio público sin que haya mediado incumplimiento de los Receptores;

3.8. Información que se encontraba en poder del Receptor de la Información antes de haber recibido dicha información de los Propietarios;

3.9. Información que deba ser suministrada a las autoridades administrativas o judiciales, en cumplimiento de un deber u obligación legal o en cumplimiento de una orden judicial o administrativa emanada de una autoridad competente, en cuyo caso los Receptores de la Información comunicarán oportunamente a los Propietarios la existencia del deber legal o de la orden judicial o administrativa de revelar o entregar la información, con el fin de que los Propietarios puedan obtener cualquier orden o medida para proteger su información o, en cualquier otra forma, puedan obtener una protección de sus intereses en tal información. En todo caso, tiene que hacerse esta gestión antes que se entregue la información a la autoridad competente.


4.1. No hay obligación de confidencialidad con respecto a información que:

4.2. Los Receptores de la Información ya poseen sin obligación de confidencialidad.

4.3. Los Receptores de la Información reciban lícitamente de un tercero que tenga derecho de proporcionarla, siempre que la reciba libre de cualquier restricción.

4.4. **EL INVESTIGADOR** se obliga a no revelar a terceros, sin que exista acuerdo con los Propietarios, los términos y condiciones del presente Acuerdo.

4.5. **EL INVESTIGADOR** se obliga a consultar a los Propietarios y a obtener su consentimiento escrito, antes de emitir cualquier declaración pública, noticia o

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	Aprobado: Director Medico

información de prensa con respecto del presente Acuerdo, salvo cuando sea necesario de conformidad con las leyes aplicables o con órdenes de autoridades competentes.

- 4.6. Las obligaciones de confidencialidad previstas en el presente Acuerdo estarán vigentes durante todo el tiempo de duración del trabajo y permanecerán siempre que la información conocida por **EL INVESTIGADOR** mantenga su carácter de confidencial.
- 4.7. **EL INVESTIGADOR** se compromete a conservar y mantener de manera estrictamente confidencial y no revelarla a terceros, todas las informaciones técnico-comerciales suministradas en la ejecución de este convenio, incluyendo de manera enunciativa y no taxativa, las fórmulas, procedimientos, técnicas, *Know - How* y demás informaciones en general a que puedan tener acceso cualquiera de las partes aquí involucradas o sus dependientes.


QUINTA - AUTORIZACIÓN TRATAMIENTO DE DATOS PERSONALES. De acuerdo con lo que establece la Ley Estatutaria 1581 de 2012 de Protección de Datos (LEPD) de Colombia, **LA EMPRESA** autoriza a **EL INVESTIGADOR** a incorporar los datos personales consignados en el presente contrato a una base de datos responsabilidad de **EL INVESTIGADOR** siendo tratados con la finalidad de mantener, desarrollar y controlar la presente relación contractual, así como para remitirle información sobre sus servicios y productos. **LA EMPRESA** se obliga a obtener los consentimientos de los contactos de personas naturales que remita a **EL INVESTIGADOR** con las finalidades antes descritas. Los Titulares podrán ejercer los derechos de acceso, corrección, supresión, revocación o reclamo por infracción sobre sus datos, mediante escrito dirigido a **EL INVESTIGADOR** a través de correo electrónico a gerencia@insititutelcorazon.com, indicando en el asunto el derecho que se desea ejercitar.

SEXTA – EXCEPCIONES: CONTINUIDAD DE LA CONFIDENCIALIDAD: Las obligaciones de Confidencialidad prevista en el presente Acuerdo, estarán vigentes durante todo el tiempo de duración del trabajo y permanecerán siempre que la información conocida por **EL INVESTIGADOR** mantenga su carácter de confidencial.

SÉPTIMA – RÉGIMEN APLICABLE: La Cláusulas de confidencialidad del presente Acuerdo se deberán regir y estarán sujetas a la reglamentación sobre Informaciones Confidenciales y Secretos Industriales de que tratan los artículos 260 a 266 de la Decisión 486 de la Comisión del Acuerdo de Cartagena, la cual creó un Régimen Común Sobre Propiedad Industrial para los países de la Comunidad Andina de Naciones - CAN – y a la normatividad que resulte aplicable.

Para constancia se firma el presente documento en dos (2) ejemplares del mismo valor y tenor, en Bucaramanga – Santander, el 28 de Junio de 2023.


CODIGO	RE-IE-043	VERSIÓN	0	FECHA	15/05/2023	PAG 4 de 5
---------------	------------------	----------------	----------	--------------	-------------------	-------------------

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	

<p>LA EMPRESA,</p> <p><u>Edgar H. Fajardo</u> Firma del Representante legal</p> <p>Nombre <u>Edgar Humberto Fajardo Romero</u></p> <p>C.C. No. <u>7.229.109</u></p> <p>Avalado por:</p> <p><u>No aplica</u></p> <p>Firma del Director Unidad de Investigaciones y Educación.</p> <p>Nombre _____</p> <p>C.C. No. _____</p>	<p>EL INVESTIGADOR,</p> <p><u>Amolfi H. Pineda Gómez</u> Firma</p> <p>Nombre <u>Amolfi H. Pineda Gómez</u></p> <p>C.C. No. <u>73.164.241 de Cartagena</u></p>
--	--

Firmado en Bucaramanga el 27 de octubre
de 2023

Edgar H. Fajardo

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	


ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR

Entre los suscritos a saber Edgar Humberto Fajardo Romero, mayor de edad, identificado con la Cédula de Ciudadanía número 7.229.109 de Duitama, quien en este acto obra en su calidad de apoderado del Instituto del Corazón de Bucaramanga S.A., institución prestadora de salud, vigilada por el Superintendencia de salud y con domicilio principal en la ciudad de Bucaramanga, y quien para todos los efectos del presente contrato se denominará como **LA EMPRESA**, por una parte; y por la otra **JAVIER ARMANDO RODRIGUEZ PRADA** de edad, identificado con CC No 91.179.227 de Girón quien actúa en nombre propio y quien en adelante se denominará **EL INVESTIGADOR**, y quienes en conjunto se denominará las “Partes” y de manera individual la “Parte”, se ha acordado suscribir el presente documento confidencialidad, el cual se regirá por la Decisión Andina 486 de 2000, y demás normas generales sobre la materia y en especial por las siguientes:

CONSIDERACIONES:

1. Que para la realización del proyecto de investigación titulado, “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes” se construirá un modelo de apoyo diagnóstico automatizado para la detección temprana de alteraciones en heridas quirúrgicas. Para ello se plantea la recopilación y organización de datos clínicos e imágenes digitales etiquetadas (ambos anonimizados) que muestran diferentes estados de las heridas quirúrgicas, la elección y adaptación de algoritmos de inteligencia artificial capaces de identificar patrones y características en dichas imágenes, y la evaluación de la eficacia y precisión del modelo desarrollado mediante validaciones con métricas establecidas.
2. Que se requiere del apoyo a **EL INVESTIGADOR JAVIER ARMANDO RODRIGUEZ PRADA** por parte de **LA EMPRESA** para el desarrollo del proyecto de investigación. En virtud de ello, **LA EMPRESA** suministrará información confidencial **AL INVESTIGADOR**.
3. Que la información se entrega **AL INVESTIGADOR** exclusivamente para su análisis, interpretación y escritura del proyecto de investigación titulado “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”
4. Que Investigadores de **LA EMPRESA** participan en las investigaciones del proyecto “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”
5. Que, en virtud de lo expuesto, las partes están interesadas en regular sus relaciones, por lo cual, han venido a manifestar su voluntad de suscribir el presente Acuerdo de Confidencialidad (en adelante el “Acuerdo”) que amparará la

CÓDIGO	RE-IE-043	VERSIÓN	1	FECHA	04/07/2023	PAG 1 de 5
---------------	------------------	----------------	----------	--------------	-------------------	-------------------

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	

información que LA EMPRESA ha suministrado y/o suministrará a EL INVESTIGADOR. Para ello, se regirán por las siguientes cláusulas:

CLÁUSULA


PRIMERA – OBJETO: Regular entre las partes el manejo de Confidencialidad de la información que **LA EMPRESA** ha suministrado y continuará suministrando a **EL INVESTIGADOR** con ocasión del desarrollo del proyecto “Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes”.

SEGUNDA – INFORMACIÓN CONFIDENCIAL: EL INVESTIGADOR, reconoce y acuerda que toda la información que le ha sido y sea suministrada o a la que hayan tenido o tengan acceso por parte de funcionarios, representantes o delegados de **LA EMPRESA** en relación con el objeto del presente Acuerdo, es información reservada y confidencial (en adelante la “Información Confidencial”) teniendo por tanto **LA EMPRESA** un interés legítimo en preservar la reserva, secreto o confidencialidad de dicha información. **LA EMPRESA** para todos los efectos de este Acuerdo también se denominará el “Propietario de la Información Confidencial” o el “Propietario” cuando sea titular de la información confidencial compartida, sin perjuicio que funja también como responsable o encargado del tratamiento de la información, cuando se trate de datos personales.

TERCERA - OBLIGACIONES: EL INVESTIGADOR se obliga con la suscripción del presente Acuerdo a no revelar a terceros la información confidencial y, en consecuencia, no podrá revelar, divulgar, exhibir o comunicar a terceros la Información Confidencial, sin autorización previa, expresa y escrita de los Propietarios de la Información Confidencial.

En concordancia con lo anterior, **EL INVESTIGADOR** se obliga durante la vigencia de este Acuerdo y siempre que la información conserve su carácter confidencial, a:

- 3.1. Proteger y mantener en secreto la información confidencial, usándola con el mismo grado de precaución y seguridad que utiliza para proteger su propia información confidencial de similar importancia y en ningún caso recibirá menor cuidado que el razonable.
- 3.2. Permitir el uso de la información confidencial sólo por aquellas personas que han sido autorizadas previa y expresamente, y que tengan necesidad de conocerla única y exclusivamente para los propósitos del presente Acuerdo.
- 3.3. Abstenerse de usar la información confidencial total o parcialmente para cualquier otro propósito que no sea el de este Acuerdo, sin el previo consentimiento escrito de los Propietarios de la Información.
- 3.4. Abstenerse de revelar la información confidencial en forma directa o indirecta a terceros diferentes del personal previa y expresamente autorizado

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	

para recibir la información confidencial de que trata el presente Acuerdo.

3.5. Abstenerse de copiar, reproducir o duplicar por cualquier medio, total o parcialmente la información confidencial, o elaborar o divulgar resúmenes o extractos, sin la previa autorización expresa y por escrito de los Propietarios de la Información.

3.6. Devolver o destruir su material de soporte, y cualquier otro material suministrado por el propietario de la información en desarrollo del presente Acuerdo, que contenga total o parcialmente la información confidencial, luego de haber sido utilizado para los fines previstos o designados.

CUARTA – EXCEPCIONES: La obligación para **EL INVESTIGADOR** de mantener en secreto la información confidencial recibida, así como la obligación de abstenerse de hacer uso de dicha información confidencial, excepto para los propósitos del presente Acuerdo, no aplicará a aquella porción de la información confidencial que se encuentre en los siguientes supuestos:

4.1. Información que sea o pase a ser de dominio público sin que haya mediado incumplimiento de los Receptores;

4.2. Información que se encontraba en poder del Receptor de la Información antes de haber recibido dicha información de los Propietarios;


4.3. Información que deba ser suministrada a las autoridades administrativas o judiciales, en cumplimiento de un deber u obligación legal o en cumplimiento de una orden judicial o administrativa emanada de una autoridad competente, en cuyo caso los Receptores de la Información comunicarán oportunamente a los Propietarios la existencia del deber legal o de la orden judicial o administrativa de revelar o entregar la información, con el fin de que los Propietarios puedan obtener cualquier orden o medida para proteger su información o, en cualquier otra forma, puedan obtener una protección de sus intereses en tal información. En todo caso, tiene que hacerse esta gestión antes que se entregue la información a la autoridad competente.

4.4. No hay obligación de confidencialidad con respecto a información que:

* Los Receptores de la Información ya poseen sin obligación de confidencialidad.

* Los Receptores de la Información reciban lícitamente de un tercero que tenga derecho de proporcionarla, siempre que la reciba libre de cualquier restricción.

4.5. **EL INVESTIGADOR** se obliga a no revelar a terceros, sin que exista acuerdo con los Propietarios, los términos y condiciones del presente Acuerdo.

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	Aprobado: Director Medico

4.6. **EL INVESTIGADOR** se obliga a consultar a los Propietarios y a obtener su consentimiento escrito, antes de emitir cualquier declaración pública, noticia o información de prensa con respecto del presente Acuerdo, salvo cuando sea necesario de conformidad con las leyes aplicables o con órdenes de autoridades competentes.

4.7. Las obligaciones de confidencialidad previstas en el presente Acuerdo estarán vigentes durante todo el tiempo de duración del trabajo y permanecerán siempre que la información conocida por **EL INVESTIGADOR** mantenga su carácter de confidencial.


4.8. **EL INVESTIGADOR** se compromete a conservar y mantener de manera estrictamente confidencial y no revelarla a terceros, todas las informaciones técnico-comerciales suministradas en la ejecución de este convenio, incluyendo de manera enunciativa y no taxativa, las fórmulas, procedimientos, técnicas, *Know - How* y demás informaciones en general a que puedan tener acceso cualquiera de las partes aquí involucradas o sus dependientes.

QUINTA- AUTORIZACIÓN TRATAMIENTO DE DATOS PERSONALES. De acuerdo con lo que establece la Ley Estatutaria 1581 de 2012 de Protección de Datos (LEPD) de Colombia, **LA EMPRESA** autoriza a **EL INVESTIGADOR** a incorporar los datos personales consignados en el presente contrato a una base de datos responsabilidad de **EL INVESTIGADOR** siendo tratados con la finalidad de mantener, desarrollar y controlar la presente relación contractual, así como para remitirle información sobre sus servicios y productos. **LA EMPRESA** se obliga a obtener los consentimientos de los contactos de personas naturales que remita a **EL INVESTIGADOR** con las finalidades antes descritas. Los Titulares podrán ejercer los derechos de acceso, corrección, supresión, revocación o reclamo por infracción sobre sus datos, mediante escrito dirigido a **EL INVESTIGADOR** a través de correo electrónico a gerencia@insititutodelcorazon.com, indicando en el asunto el derecho que se desea ejercitar.

SEXTA – EXCEPCIONES: CONTINUIDAD DE LA CONFIDENCIALIDAD: Las obligaciones de Confidencialidad prevista en el presente Acuerdo, estarán vigentes durante todo el tiempo de duración del trabajo y permanecerán siempre que la información conocida por **EL INVESTIGADOR** mantenga su carácter de confidencial.

SÉPTIMA – RÉGIMEN APLICABLE: La Cláusulas de confidencialidad del presente Acuerdo se deberán regir y estarán sujetas a la reglamentación sobre Informaciones Confidenciales y Secretos Industriales de que tratan los artículos 260 a 266 de la Decisión 486 de la Comisión del Acuerdo de Cartagena, la cual creó un Régimen Común Sobre Propiedad Industrial para los países de la Comunidad Andina de Naciones - CAN – y a la normatividad que resulte aplicable.

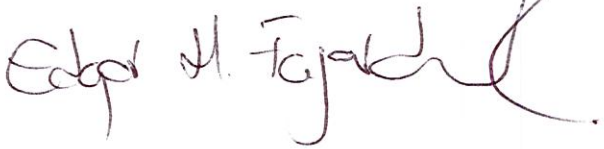
CÓDIGO	RE-IE-043	VERSIÓN	1	FECHA	04/07/2023	PAG 4 de 5
---------------	------------------	----------------	----------	--------------	-------------------	-------------------

 <p>Instituto del Corazón de Bucaramanga <i>Un compromiso de Vida</i></p>	INVESTIGACIÓN Y EDUCACIÓN	Elaborado: Director Estudios Clínicos Actualizado: Coord. Gestión del Mejoramiento Aprobado: Director Medico
	ACUERDO DE CONFIDENCIALIDAD ENTRE INSTITUTO DEL CORAZÓN DE BUCARAMANGA E INVESTIGADOR	

Para constancia se firma el presente documento en dos (2) ejemplares del mismo valor y tenor, en (ciudad y fecha).

<p>LA EMPRESA ,  Firma del Representante legal</p> <p>Nombre <u>Edgar Humberto Fajardo Romero</u></p> <p>C.C. No. <u>7.229.109</u></p>	<p>EL INVESTIGADOR,  Signer ID: UHEGMA7T10...</p> <p>Firma</p> <p>Nombre: JAVIER ARMANDO RODRIGUEZ PRADA</p>
<p>Avalado por: <u>No aplica</u> Firma del Director Unidad de Investigaciones y Educación. Nombre _____ C.C. No. _____</p>	<p>C.C. No. 91. 179. 227.</p>

Firmado en Bucaramanga el 27 de octubre de 2023



Anexo 3. Autorización de cambio de título del proyecto aplicado.

RE: Propuesta de cambio de título del proyecto aplicado

Gloria Ines Alvarez Vargas <galvarez@javerianacali.edu.co>

Sáb 13/01/2024 9:49

Para: Alvaro Augusto Cote Florez <alvarocote@javerianacali.edu.co>; Javier Armando Rodriguez Prada <javerianoropra22@javerianacali.edu.co>; Amolfi Hernando Pineda Gomez <apinedag@javerianacali.edu.co>
CC: Hernan Dario Vargas Cardona <hernan.vargas@javerianacali.edu.co>; Asistente Maestria Ingenieria <asistentemaestriaing@javerianacali.edu.co>

Cordial saludo Alvaro,

Les confirmo que el comité autorizó el cambio en el título del proyecto en su reunión de ayer. La asistente dejará registro del cambio en la carpeta de su proyecto.

Atentamente,

Gloria Inés Alvarez V.

Directora de la Maestría en Ciencia de Datos

Pontificia Universidad Javeriana Cali

De: Alvaro Augusto Cote Florez <alvarocote@javerianacali.edu.co>**Enviado:** miércoles, 6 de diciembre de 2023 16:29**Para:** Gloria Ines Alvarez Vargas <galvarez@javerianacali.edu.co>**Cc:** Hernan Dario Vargas Cardona <hernan.vargas@javerianacali.edu.co>; Javier Armando Rodriguez Prada <javerianoropra22@javerianacali.edu.co>; Amolfi Hernando Pineda Gomez <apinedag@javerianacali.edu.co>**Asunto:** Re: Propuesta de cambio de título del proyecto aplicado

Muchas gracias profesora Gloria por su apoyo en este proceso.

Quedamos a la espera de la confirmación sobre la aprobación del cambio.

Atentamente.

Amolfi, Javier, Álvaro

De: Gloria Ines Alvarez Vargas <galvarez@javerianacali.edu.co>**Enviado:** miércoles, 6 de diciembre de 2023 16:07**Para:** Alvaro Augusto Cote Florez <alvarocote@javerianacali.edu.co>**Cc:** Hernan Dario Vargas Cardona <hernan.vargas@javerianacali.edu.co>; Javier Armando Rodriguez Prada <javerianoropra22@javerianacali.edu.co>; Amolfi Hernando Pineda Gomez <apinedag@javerianacali.edu.co>**Asunto:** RE: Propuesta de cambio de título del proyecto aplicado

Cordial saludo Álvaro,

En principio no veo problema con su solicitud. La llevaré al comité de maestría que se realizará a comienzos de enero, les estaremos confirmando cuando el cambio sea oficial.

Atentamente,

Gloria Inés Alvarez V.

Directora de la Maestría en Ciencia de Datos

Pontificia Universidad Javeriana Cali

De: Alvaro Augusto Cote Florez <alvarocote@javerianacali.edu.co>**Enviado:** miércoles, 6 de diciembre de 2023 15:10**Para:** Gloria Ines Alvarez Vargas <galvarez@javerianacali.edu.co>**Cc:** Hernan Dario Vargas Cardona <hernan.vargas@javerianacali.edu.co>; Javier Armando Rodriguez Prada

<javerianopra22@javerianacali.edu.co>; Amolfi Hernando Pineda Gomez <apinedag@javerianacali.edu.co>;
Alvaro Augusto Cote Florez <alvarocote@javerianacali.edu.co>

Asunto: Propuesta de cambio de título del proyecto aplicado

Estimada profesora Gloria,

Esperamos que se encuentre muy bien.

Nos dirigimos a usted con el fin de proponer un cambio de título para el proyecto aplicado titulado ***"Identificación temprana de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes"***.

Consideramos que la palabra "**temprana**" en el título puede generar confusión, ya que no se define claramente qué significa "temprano" en el contexto de las heridas quirúrgicas. ¿Qué es temprano? ¿Quién lo define? ¿Cómo se mide?

Estos interrogantes pueden dificultar la comprensión del propósito del proyecto y, pueden generar confusión al momento de ser evaluado, porque no tenemos información en el contexto clínico de cómo se puede justificar esa palabra.

Por esta razón, proponemos eliminar la palabra "temprana" del título, ya que así no dejaría lugar a dudas sobre el objetivo del proyecto, que es identificar alteraciones en heridas quirúrgicas.

La propuesta para el nuevo título sería la siguiente: ***"Identificación de alteraciones en heridas quirúrgicas mediante la aplicación de inteligencia artificial en imágenes"***

De acuerdo con sus conocimientos, queremos saber su opinión sobre la viabilidad de la propuesta. En caso de que la propuesta sea viable, solicitamos información sobre el procedimiento para realizar el cambio.

Agradecemos su atención y quedamos atentos a cualquier inquietud.

Atentamente,

Amolfi, Javier , Álvaro