



Escuela de Administración de Tecnologías de Información

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Trabajo Final de Graduación para optar al grado de Licenciatura en Administración de Tecnología de Información

Modalidad Proyecto de Graduación

Elaborado por: Stephanie Dayana Valverde Vizcaino

Prof. Tutor: Dr. Isaac Alpízar Chacón

Cartago, Costa Rica

II semestre

Septiembre, 2024



Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de *Deep Learning*. © 2024 by Stephanie Dayana Valverde Vizcaíno is licensed under CC BY-NC-SA 4.0. To view a copy of this license, visit <https://creativecommons.org/licenses/by-nc-sa/4.0/>

INSTITUTO TECNOLÓGICO DE COSTA RICA
ESCUELA DE ADMINISTRACIÓN DE TECNOLOGÍAS DE INFORMACIÓN
GRADO ACADÉMICO: LICENCIATURA

Los miembros del Tribunal Examinador de la Escuela de Administración de Tecnologías de Información, recomendamos que el siguiente informe del Trabajo Final de Graduación de la estudiante **Stephanie Dayana Valverde Vizcaíno** sea aceptado como requisito parcial para obtener el grado académico de Licenciatura de Tecnología de Información.

Isaac Alpízar Chacón - Profesor Tutor

Federico Torres Carballo - Lector externo

Juan Andrés Segreda Johanning - Lector académico

Yarima Sandoval Sánchez – Coordinación Trabajo Final de Graduación

Dedicatoria

A Dios, por brindarme la bendición, fuerza y determinación para realizar este proyecto, y por estar en cada etapa de mi camino universitario.

A mis padres, por su sacrificio para brindarme una educación universitaria y su apoyo no solo a nivel económico, sino también emocional durante todo mi tiempo en la universidad; además de ser ese lugar seguro durante las incontables noches largas realizando diferentes proyectos finales.

A mis hermanos Carmen, Wendy y Daniel, por ser una fuente importante de ayuda y comprensión durante todo este gran camino, y por ser esas personas que me han impulsado a ser la mejor versión de mí misma.

A mis cuñados y cuñada, por siempre prestarme un oído para contarles todos mis problemas y buenas noticias académicas.

A mi compañera inseparable de la universidad, Daniela, por nunca soltarme y siempre estar ahí al pie del cañón conmigo en todos los proyectos y trabajos que realizamos a lo largo de la carrera.

A mi mejor amiga Wen, por estar a mi lado mandándome mensajes de apoyo y estar pendiente de todos los avances de este proyecto.

A la profesora Sonia, por ser una guía profesional-personal durante mi carrera universitaria, y por creer en mí y brindarme tantas oportunidades para crecer profesionalmente.

Al profesor Isaac, por ser el mejor tutor de TFG y ayudarme con todas mis crisis existenciales a lo largo de la elaboración de este proyecto final.

Al profesor Karteek, por aceptarme en su laboratorio, ayudarme en todos los pasos del proyecto y por abrirme las puertas a nuevos conocimientos y personas alrededor del mundo.

A Daniela, Maribi, Payton y todas las personas que conocí en el intercambio que siempre estuvieron atentos a mis avances y me desearon lo mejor con el proyecto, aunque no comprendían muy bien de que se trataba.

A mis amigos, por siempre estar pendientes de cómo van mis proyectos y mi vida universitaria.

A todos mis compañeros de proyectos a lo largo de los cursos, por enseñarme tantas cosas sobre la carrera y la vida profesional.

Resumen

Valverde, S. (2024) *Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning*. (Trabajo Final de Graduación). Escuela de Administración de Tecnologías de Información. Tecnológico de Costa Rica.

El objetivo de esta investigación es desarrollar una herramienta de escritorio basada en la ejecución de un modelo de *Deep Learning*, utilizando la metodología CRISP-DM, para la automatización del proceso de análisis e interpretación de un TAC por medio de su clasificación. Con esto se pretende impactar el flujo de trabajo del personal médico canadiense al automatizar la clasificación de TAC, y al mismo tiempo agilizar el proceso de análisis para el diagnóstico y tratamiento médico.

La investigación se realiza bajo la modalidad de movilidad estudiantil, donde el estudiante investigador desarrolla su investigación en el laboratorio o departamento de una universidad extranjera. En este caso, el laboratorio escogido fue el laboratorio del Grupo de Análisis de Datos e Imágenes (DIAG, siglas en inglés) del departamento de Ciencias de la Computación en la Universidad Memorial en Canadá. Este laboratorio se encarga de implementar tecnologías emergentes como la inteligencia artificial para automatizar procesos médicos y crear modelos de *Deep Learning* que permiten clasificar imágenes médicas como TAC, resonancias magnéticas, entre otros, con el fin de atacar el retraso en la atención y diagnóstico de los pacientes.

Para abordar esta problemática, se plantea la creación de una herramienta de escritorio al implementar un modelo anteriormente desarrollado por un miembro del laboratorio para clasificar las siguientes regiones del cuerpo en un TAC con formato iniciativa de tecnología informática de neuroimagen (NiFTi, por sus siglas en inglés): Pecho, Abdomen, Pelvis, Pecho-Abdomen, Abdomen-Pelvis, Pecho-Abdomen-Pelvis; para obtener este resultado se utiliza una metodología con enfoque cuantitativo y un diseño de investigación experimental. Esto implica la evaluación del modelo de clasificación, así como la creación de la herramienta que integra dicho modelo. Los datos necesarios fueron recopilados al aplicar revisión documental, diseños experimentales, encuestas y tablas de registro.

Posterior al análisis de resultados, se obtuvieron porcentajes de desempeño general mayores a 75% en todas las pruebas realizadas al modelo base, lo que permitió continuar con su uso para su debida integración con la aplicación de escritorio. Sin embargo, de igual forma se identificó un patrón de error con la clasificación que presenta dos principales funcionalidades: clasificación individual y clasificación grupal de TAC, elaboradas utilizando *Electron* para el *Fronend*, *Onnxruntime* para la comunicación modelo-aplicación y *Python* para la lógica del modelo. Por último, se presenta una discusión para mejoras del modelo en términos de realizar mayor cantidad de pruebas con otras bases de datos, modificar parámetros de entrenamiento o modificar la arquitectura; mientras que para la herramienta se proponen mejoras en su distribución y funcionalidades.

Palabras clave: Inteligencia Artificial, *Deep Learning*, Redes Convolucionales, ResNet50, imágenes médicas, clasificación, métricas de evaluación, tomografía axial computarizada (TAC).

Abstract

Valverde, S. (2024). *Development of a desktop tool for automating the analysis and interpretation process of computed axial tomography (CT scan) scans through the application of a Deep Learning model*. (Final Graduation Project). School of Information Technology Management. Technological Institute of Costa Rica.

The objective of this research is to develop a desktop tool based on the execution of a Deep Learning model, using the CRISP-DM methodology, for the automation of the analysis and interpretation process of a CT scan through its classification. This is intended to impact the workflow of Canadian medical personnel by automating the classification of CT scans, and at the same time streamlining the analysis process for medical diagnosis and treatment.

The research is carried out under the modality of student mobility where the student researcher develops his research in the laboratory or department of a foreign university. In this case, the laboratory chosen was the Data and Image Analysis Group (DIAG) laboratory of the computer science department at Memorial University. This laboratory is responsible for implementing emerging technologies such as artificial intelligence to automate medical processes and create Deep Learning models that allow classifying medical images such as CT scans, MRIs, among others; in order to attack the delay in patient care and diagnosis.

To address this problem, the creation of a desktop tool is proposed that, by implementing a model previously developed by a colleague in the laboratory to classify the following regions of the body in a CT with Neuroimaging Informatics Technology Initiative (NiFTi) format: Chest, Abdomen, Pelvis, Chest-Abdomen, Abdomen-Pelvis, Chest-Abdomen-Pelvis; To obtain this result, a methodology with a quantitative approach and an experimental research design is used. This involves the evaluation of the classification model, as well as the creation of the tool that integrates said model. The necessary data were collected by applying documentary review, experimental designs, surveys and recording tables.

Considering the analysis of the results, general performance percentages greater than 75% were obtained in all the tests carried out on the base model, which allowed its use to continue for proper integration with the desktop application. However, an error pattern was also identified with the classification that presents two main functionalities: individual classification and group classification of a CT scan developed using Electron for the Frondend, Onnxruntime for the model-application communication and Python for the model logic. Finally, a discussion is presented for model improvements in terms of performing more tests with other databases, modifying training parameters or modifying the architecture; while for the tool, improvements are proposed in its distribution and functionalities.

Keywords: Artificial Intelligence, Deep Learning, Convolutional Networks, ResNet50, medical images, classification, evaluation metrics, Ct scan

Tabla de Contenidos

1.	Introducción.....	1
1.1.	Descripción general.....	1
1.2.	Antecedentes	2
1.2.1.	Modalidad del proyecto	2
1.2.2.	Descripción de la organización.....	2
1.2.3.	Trabajos similares realizados dentro y fuera de la organización	6
1.3.	Planteamiento del problema.....	7
1.3.1.	Situación problemática.....	7
1.3.2.	Justificación del proyecto	11
1.3.3.	Beneficios esperados del Trabajo Final de Graduación.....	12
1.4.	Objetivos del Trabajo Final de Graduación	13
1.4.1.	Objetivo general.....	13
1.4.2.	Objetivos específicos	13
1.5.	Alcance	14
1.5.1.	Fase 1 – Entendimiento del negocio	14
1.5.2.	Fase 2 – Comprensión y preprocesamiento de datos	14
1.5.3.	Fase 3 - Modelaje.....	15
1.5.4.	Fase 4 – Integración	15
1.5.5.	Fase 5 - Despliegue.....	15
1.5.6.	Exclusiones	15
1.6.	Supuestos	16
1.7.	Entregables.....	17
1.7.1.	Gestión del proyecto	18
1.8.	Limitaciones.....	18
2.	Marco Conceptual.....	19
2.1.	Conceptos generales.....	20
2.1.1.	Imágenes médicas	20
2.1.2.	Algoritmos de <i>Machine Learning</i>	29
2.1.3.	Herramientas para el desarrollo	35
2.1.4.	Metodología CRISP-DM	36
2.2.	Trabajos relacionados	38

2.2.1.	Métodos de automatización de tareas médicas	38
2.2.2.	Retos de los datos en los modelos de <i>Machine Learning</i>	38
2.2.3.	Metodología CRISP-DM: desarrollo de modelos de <i>Deep Learning</i>	38
2.2.4.	Comparación de modelos de redes convolucionales (CNN)	39
2.2.5.	Métricas de evaluación de modelos	40
2.2.6.	Contribución del proyecto.....	40
3.	Marco Metodológico	43
3.1.	Tipo de investigación	43
3.2.	Enfoque y diseño de la investigación.....	43
3.3.	Fuentes de datos de información.....	45
3.3.1.	Fuentes primarias	45
3.3.2.	Fuentes secundarias	46
3.4.	Sujetos de investigación.....	48
3.5.	Variables o categorías de la investigación	49
3.6.	Técnicas e instrumentos de recolección de datos	51
3.6.1.	Revisión documental.....	51
3.6.2.	Tabla de registro	51
3.6.3.	Encuesta	51
3.6.4.	Diseños experimentales	51
3.6.5.	Instrumentos mecánicos o electrónicos	51
3.6.6.	Matriz de cobertura de las variables	52
3.7.	Procedimiento metodológico de la investigación	53
3.7.1.	Fase 1 – Entendimiento del negocio	53
3.7.2.	Fase 2 – Compresión y preprocesamiento de datos	54
3.7.3.	Fase 3 – Modelaje	55
3.7.4.	Fase 4 – Integración	55
3.7.5.	Fase 5 – Despliegue	56
3.8.	Operacionalización de las variables o categorías.....	57
3.9.	Tabla resumen del procedimiento metodológico de la Investigación.....	61
4.	Análisis de Resultados.....	63
4.1.	Fase 1 – Entendimiento del negocio	63
4.1.1.	Comprensión de las necesidades.....	63

4.1.2.	Comprensión del flujo de trabajo.....	64
4.1.3.	Comprensión de la estructura del modelo base.....	67
4.1.4.	Selección de la base de datos de trabajo	68
4.2.	Fase 2 - Comprensión y preprocesamiento de datos	68
4.2.1.	Etiquetado manual de la imagen médica	68
4.2.2.	Preprocesamiento de las imágenes médicas	71
4.2.3.	Resaltado de inconsistencias.....	72
4.3.	Fase 3 – Modelaje	73
4.3.1.	Definición del ambiente de pruebas.....	73
4.3.2.	Selección del conjunto de datos para pruebas.....	74
4.3.3.	Ejecución de pruebas	74
4.3.4.	Registro de las métricas de evaluación	75
4.3.5.	Modificación y entrenamiento del modelo	77
4.4.	Discusión de análisis de resultados.....	78
5.	Propuesta de Solución	79
5.1.	Fase 4 – Integración	79
5.1.1.	Preparación del modelo y aplicación para integración	79
5.1.2.	Integración modelo-herramienta.....	80
5.2.	Fase 5 – Despliegue.....	82
5.2.1.	Diseño de la interfaz gráfica.....	82
5.2.2.	Diseño de la arquitectura	84
5.2.3.	Desarrollo de la herramienta.....	86
5.2.4.	Pruebas de funcionalidad	92
5.2.5.	Paso a producción	98
5.3.	Análisis de la viabilidad.....	102
5.3.1.	Consideraciones para los cálculos	102
5.3.2.	Cálculo de costos.....	103
5.3.3.	Beneficios esperados	103
6.	Conclusiones.....	104
6.1.	Objetivo específico uno	104
6.2.	Objetivo específico dos.....	104
6.3.	Objetivo específico tres.....	105

6.4.	Objetivo específico cuatro	105
6.5.	Objetivo general.....	106
6.6.	Conclusiones sobre la modalidad del proyecto.....	106
7.	Recomendaciones	107
8.	Referencias	109
9.	Apéndices	117
	Apéndice A. Cronograma.....	117
	Apéndice B. Plantilla de minutas	118
	Apéndice C. Plantilla de hoja de cambios.....	120
	Apéndice D. Plantilla de encuesta de satisfacción	121
	Apéndice E. Plantilla de encuesta de usabilidad	124
	Apéndice F. Minuta 1 – Recolección de requerimientos	127
	Apéndice G. Minuta 2 – Primera entrega de productos	128
	Apéndice H. Minuta 3 – Segunda entrega de productos.....	130
	Apéndice I. Cronograma de desarrollo de la herramienta.....	134
	Apéndice J. Plantilla de revisión documental.	135
	Apéndice K. Plantilla de tabla de registro.....	136
10.	Anexos	137
	Anexo I. Detalle de las clasificaciones erróneas	137
	Anexo II. Matrices de confusión	140
	Anexo III. Detalle de prueba: recursos computacionales.....	144
	Anexo IV. Respuestas encuesta de satisfacción.....	149
	Anexo V. Respuestas de encuesta de usabilidad.....	153
	Anexo VI. Carta de revisión filológica.	158

Índice de Figuras

Figura n.º 1 Expertos de dudas técnicas	4
Figura n.º 2 Información del profesor supervisor.....	4
Figura n.º 3 Organigrama del trabajo	5
Figura n.º 4 Diagrama de flujo interpretación manual de TAC.....	8
Figura n.º 5 Árbol del problema	10
Figura n.º 6 Fases del proyecto.....	14
Figura n.º 7 Estructura del marco conceptual.....	19
Figura n.º 8 Procedimiento radiológico.....	21
Figura n.º 9 Tipos de imágenes médicas.	22
Figura n.º 10 Fases de TAC con contraste.....	23
Figura n.º 11 TAC Sin contraste.....	24
Figura n.º 12 Imagen de TAC en formato DICOM	25
Figura n.º 13 Imagen de TAC en formato NiFTi.	25
Figura n.º 14 Imagen de TAC en formato MIP.	26
Figura n.º 15 Ejemplo conversión de imagen DICOM a 2D.....	27
Figura n.º 16 Secciones del cuerpo humano para modelo	28
Figura n.º 17 Algoritmos de Machine Learning	29
Figura n.º 18 Arquitectura de ResNet.....	31
Figura n.º 19 Fórmula de la precisión.....	33
Figura n.º 20 Fórmula de la exactitud.....	33
Figura n.º 21 Fórmula de la recall	34
Figura n.º 22 Fórmula del F1-Score	34
Figura n.º 23 Fórmula del desempeño	35
Figura n.º 24 Metodología CRIPS-DM	37
Figura n.º 25 Resumen de conceptos.....	37
Figura n.º 26 Cantidad de datos utilizados, según base de datos.....	41
Figura n.º 27 Resultados de la evaluación de desempeño	41
Figura n.º 28 Procedimiento metodológico de investigación	53
Figura n.º 29 Flujo del trabajo del laboratorio	65
Figura n.º 30 Ejemplo de un quickcheck.....	69
Figura n.º 31 Flujo de etiquetado manual.....	70
Figura n.º 32 Proceso de ejecución de pruebas	74
Figura n.º 33 Distribución del proyecto.....	79
Figura n.º 34 Código para preparar modelo.....	80
Figura n.º 35 Proceso de integración del modelo	80
Figura n.º 36 Archivo del modelo	80
Figura n.º 37 Validación en Netron	81
Figura n.º 38 Modelo en proyecto principal	81
Figura n.º 39 Skecth de las interfaces gráficas	82
Figura n.º 40 Página "About ClassiCTMed"	83
Figura n.º 41 Página "Single classification"	83

Figura n.º 42	Página "Bulk Classification"	84
Figura n.º 43	Arquitectura de la aplicación	85
Figura n.º 44	Evidencia de desarrollo de la herramienta	91
Figura n.º 45	Mostrar una vista previa del TAC.....	93
Figura n.º 46	Resultado de la clasificación individual	93
Figura n.º 47	Proceso de clasificación grupal.....	94
Figura n.º 48	Resultados de la clasificación grupal	95
Figura n.º 49	Zip con los resultados de la clasificación	95
Figura n.º 50	Resultados de la prueba de calidad	96
Figura n.º 51	Proceso de paso a producción.....	98
Figura n.º 52	Proyecto en servidor "cedar"	100
Figura n.º 53	Proyecto en GitHub	101
Figura n.º 54	Proyecto en GitLab	101
Figura n.º 55	Cronograma de trabajo.....	117
Figura n.º 56	Encuesta de satisfacción - Parte I	121
Figura n.º 57	Encuesta de satisfacción - Parte II	122
Figura n.º 58	Encuesta de satisfacción - Parte III.....	123
Figura n.º 59	Encuesta de usabilidad - Parte I.....	124
Figura n.º 60	Encuesta de usabilidad - Parte II.....	125
Figura n.º 61	Encuesta de usabilidad - Parte III	126
Figura n.º 62	Minuta - Recolección de requerimientos	127
Figura n.º 63	Minuta - Primera entrega de productos.....	128
Figura n.º 64	Minuta - Entrega final de productos	130
Figura n.º 65	Cronograma de desarrollo de la herramienta	134
Figura n.º 66	Detalle de las clasificaciones erróneas en las pruebas 2 y 3.	137
Figura n.º 67	Detalle de las clasificaciones erróneas en la prueba 4.	138
Figura n.º 68	Detalle de las clasificaciones erróneas en prueba 5	139
Figura n.º 69	Matriz de confusión de Prueba 2	140
Figura n.º 70	Matriz de confusión de la prueba 3.....	141
Figura n.º 71	Matriz de confusión de prueba 4.....	142
Figura n.º 72	Matriz de confusión de prueba 5.....	143
Figura n.º 73	Resumen de respuestas - Encuesta de satisfacción.....	149
Figura n.º 74	Resumen de respuestas - Encuesta usabilidad	153
Figura n.º 75	Carta de revisión de la filóloga.	158

Índice de Tablas

Tabla n.º 1. Entregables del proyecto.	17
Tabla n.º 2. Fuentes primarias	45
Tabla n.º 3. Fuentes secundarias.....	46
Tabla n.º 4. Sujetos de investigación	48
Tabla n.º 5. Variables de investigación.....	49
Tabla n.º 6. Matriz de cobertura de las variables.	52
Tabla n.º 7. Operacionalización de las variables.	57
Tabla n.º 8. Tabla de resumen del proceso metodológico	61
Tabla n.º 9. Requerimientos del proyecto.....	63
Tabla n.º 10. Consideraciones del flujo de trabajo	66
Tabla n.º 11. Estructura del modelo base.....	67
Tabla n.º 12. Selección de base de datos	68
Tabla n.º 13. Cantidad de imágenes etiquetadas.....	71
Tabla n.º 14. Cantidad de imágenes preprocesadas	71
Tabla n.º 15. Inconsistencias en la base de datos.....	72
Tabla n.º 16. Configuración del ambiente de pruebas	73
Tabla n.º 17. Resumen de los datasets utilizados en pruebas	74
Tabla n.º 18. Fechas de ejecución de pruebas.....	75
Tabla n.º 19. Resultados generales de las métricas de evaluación	75
Tabla n.º 20. Resultados de las métricas de evaluación por clase	76
Tabla n.º 21. Cantidad de errores de clasificación, según prueba	76
Tabla n.º 22. Tareas para el desarrollo de la herramienta.....	87
Tabla n.º 23. Dificultades del desarrollo de la herramienta.....	88
Tabla n.º 24. Ambiente de pruebas de la herramienta	92
Tabla n.º 25. Uso de recursos computacionales.....	96
Tabla n.º 26. Tiempos de procesamiento	97
Tabla n.º 27. Características de las encuestas de usabilidad y satisfacción	97
Tabla n.º 28. Resultados de encuesta de satisfacción y usabilidad.....	98
Tabla n.º 29. Dificultades del paso a producción	99
Tabla n.º 30. Trazabilidad de los requerimientos	100
Tabla n.º 31. Desglose de costos.....	103
Tabla n.º 32. Plantilla de minuta en español.....	118
Tabla n.º 33. Plantilla de minuta en inglés	119
Tabla n.º 34. Plantilla de hoja de cambios	120
Tabla n.º 35. Bitácora de reuniones	132
Tabla n.º 36. Plantilla de revisión documental	135
Tabla n.º 37. Plantilla de tabla de registro: métricas de evaluación	136
Tabla n.º 38. Plantilla de tabla de registro: información de pruebas	136

1. Introducción

1.1. Descripción general

Los sistemas de salud pública canadiense han sido abatidos por cortes de presupuesto así como la falta de personal especializado que ayuden con las listas de espera de los pacientes, como lo menciona la Agencia Canadiense de Medicamentos y Tecnologías en Salud (2023) en su artículo llamado *Wait List Strategies for CT and MRI Scans*, por esto el laboratorio de análisis de imágenes médicas del departamento de Ciencias de la Computación en la Universidad Memorial de Canadá se ha dedicado los últimos 15 años a investigar y crear herramientas que permitan automatizar diferentes tareas del proceso de atención médica, como tratamiento, diagnóstico y pronóstico.

En este caso, el problema expuesto es la cantidad de tiempo que le toma a los radiólogos revisar las imágenes médicas, específicamente las tomografías axiales computarizadas (TAC), causando así atrasos en los procesos médicos y desgaste en el personal médico, como lo expone y menciona Sanders (2024) en su artículo *'Reckless' decision to end task force behind huge increase in CT wait times*. En este artículo, Sanders menciona como cada vez hay una mayor cantidad de médicos realizando horas extra para lograr abarcar la cantidad de TAC que se deben realizar y examinar.

El objetivo de este proyecto es la creación de una herramienta por medio de la aplicación de un modelo de *Deep Learning*, previamente desarrollado por un supervisor del laboratorio y mejorado por la estudiante, que se encarga de clasificar de imágenes médicas (TAC) en seis categorías distintas: Pecho, Pelvis, Abdomen, Pecho-Abdomen, Abdomen-Pelvis y Pecho-Abdomen-Pelvis, con esto se pretende impactar de manera positiva los tiempos de trabajo de los radiólogos y descartar aquellas imágenes o registros que presentan algún problema o son ilegibles.

Por otro lado, la metodología por seguir dentro del proyecto es integral con actividades investigativas y experimentales siempre bajo la supervisión de integrantes del laboratorio junto con el supervisor de este para asegurar la calidad y eficacia del producto final.

Por último, el presente proyecto se estructura en ocho principales capítulos: el capítulo II presenta el estado del arte y conceptos básicos, el capítulo III expone el marco metodológico, el capítulo IV contiene el análisis de resultados, el capítulo V detalla la propuesta de solución planteada por el estudiante, el capítulo VI incluye las conclusiones junto con el cumplimiento de los objetivos planteados y, finalmente, el capítulo VII presenta recomendaciones para investigaciones futuras relacionadas con el tema.

1.2. Antecedentes

En este apartado se detalla información con respecto a la organización donde se estará desarrollando el proyecto, así como se menciona los trabajos similares realizados tanto dentro como fuera de la organización.

1.2.1. Modalidad del proyecto

El presente proyecto fue realizado bajo la modalidad llamada movilidad estudiantil en la Universidad Memorial de San Juan de Terranova en Canadá. Este intercambio tenía una duración de un semestre y consistía en participar como una estudiante investigadora dentro de alguno de los laboratorios o departamentos pertenecientes a la universidad, que se alinearan con los conocimientos adquiridos en la carrera. Esta movilidad fue apoyada por la Vicerrectoría de Investigación y Extensión, la escuela de Administración de Tecnologías de Información, el gobierno canadiense y la Universidad Memorial, específicamente el laboratorio DIAG del departamento de Ciencias de la Computación.

1.2.2. Descripción de la organización

En este apartado, se realiza una descripción detallada del laboratorio donde se lleva a cabo el TFG. Se mencionan datos generales que ofrecen un contexto claro sobre el entorno donde se llevará a cabo el proyecto.

El Laboratorio de análisis de imágenes y datos del Departamento de Ciencias de la Computación¹ de la Universidad Memorial de Terranova en Canadá fue establecida alrededor del 2009. Desde su fundación se ha encargado de trabajar en el análisis automatizado de imágenes médicas como lo son resonancias magnéticas y tomografías axiales computarizadas (TAC) utilizadas en el sector médico para diferentes tareas relacionadas con la atención de pacientes.

El laboratorio cuenta con alrededor de cien artículos publicados referentes a los trabajos de colaboración y en solitario que se han realizado en el laboratorio; en temas de análisis de imágenes, inteligencia artificial, *Machine Learning* y visión computarizada. Por ejemplo: el artículo que propone un modelo de *Deep Learning* para la clasificación de resonancias magnéticas que permita el diagnóstico de la demencia en el lobo frontotemporal del cerebro (Ma et al., 2024) y el artículo que presenta un modelo de predicción del progreso del Alzheimer en pacientes sanos o con síntomas tempranos (Mirabnahrzham et al., 2022).

Entre sus creaciones se encuentran tecnologías nuevas que contribuyen con la atención de pacientes, en diversos sistemas de salud, como lo son el diagnóstico, tratamiento, pronóstico, planeación de tratamiento, monitoreo de tratamiento postoperatorio, entre otros. Además, para asegurar que las herramientas desarrolladas se apeguen a la realidad de los procesos, el laboratorio colabora con personal médico que ayuda el proceso con su experiencia en el sector. Por ejemplo: el artículo donde se expone la creación de un modelo que permite detectar y diagnosticar de manera temprana el Alzheimer por medio del entrenamiento de una red neuronal (Jefrey Petrella et al., 2018).

¹ <https://diaglab.cs.mun.ca/>

Además, el laboratorio ofrece posiciones de investigación para estudiantes de diferentes grados como *undergraduates* (estudiante no licenciado/universitario), maestrías y PhD (doctorados). Con esto crea un ambiente para el intercambio de conocimientos interdisciplinarios en el desarrollo de proyectos integrales y de interés común.

Por último, el laboratorio cuenta con un total de 17 personas trabajando en diferentes investigaciones y proyectos, inclusive algunos realizando colaboración con estudiantes de la Universidad Simón Fraser.

1.2.2.1. Misión

Según la página web oficial del laboratorio, se define la misión como: “Contribuir a mejorar la prestación de atención médica mediante el desarrollo de tecnologías automatizadas de interpretación de imágenes médicas altamente precisas y confiables y su empleo para el descubrimiento de biomarcadores de enfermedades específicos del paciente.”²

1.2.2.2. Enfoques de investigación

Actualmente, el laboratorio se encuentra enfocado en los siguientes temas de investigación:

- Modelos precisos y eficientes enfocados en el procesamiento de imágenes médicas.
- Procesamiento datos en imágenes médicas, por medio de Big Data e Inteligencia Artificial (IA).
- Desarrollo de herramientas automatizadas de análisis de imágenes médicas en los dominios médicos de enfermedades neurológicas, por ejemplo: Alzheimer, Parkinson y demencia; y enfermedades oculares, por ejemplo: glaucoma, degeneración por edad y retinopatía por diabetes.

1.2.2.3. Equipo de trabajo

Actualmente, el laboratorio cuenta con 17 personas, clasificadas según el trabajo principal que realizan, por ejemplo: procesamiento de imágenes médicas o neurológicas, desarrolladores *full-stack*, diseño de base de datos para imágenes médicas, etiquetado de imágenes y alimentación-entrenamiento de modelos. Según lo discutido con el director del laboratorio, la estudiante estará trabajando integralmente con todos los integrantes del laboratorio, a pesar de ello, tiene asignados dos expertos como primer punto de atención de dudas técnicas que se encargaran de guiar directamente el desarrollo del proyecto.

En la **Figura n.º 1**, se adjunta una breve descripción de los expertos como primer punto de atención de dudas técnicas que surjan a lo largo del desarrollo del proyecto.

² <https://diaglab.cs.mun.ca/>

Figura n.º 1 Expertos de dudas técnicas

Morteza Golzan <i>Master's Student, working on Medical Image Analysis</i> • M.Sc, Electrical Engineering, University of Tabriz, Tabriz, Iran, 2014 - 2017	Mohammed Balfaqih <i>Full-stack software developer</i> • B.Sc, Computer Science, Memorial University of Newfoundland, 2021 - present
---	--

Nota: Información extraída de Team, por Diag Lab, 2024.

Por otra parte, el tutor directo de la estudiante será el actual director del laboratorio de investigación. Él será a quien se le presenten los entregables del proyecto para su debida revisión.

En la **Figura n.º 2**, se presenta una pequeña descripción del profesor tutor dentro del laboratorio en la universidad canadiense.


Figura n.º 2 Información del profesor supervisor

Karteek Popuri <i>Assistant professor</i> • Research Associate, Simon Fraser University, 2015 - 2021 • Postdoc, Simon Fraser University, 2013 - 2015 • PhD, Computing Science, University of Alberta, 2008 - 2013 • MSc, Chemical Engineering, University of Alberta, 2005 - 2009 • B.Tech, Chemical Engineering, Indian Institute of Technology Madras, 2001 - 2005
--

Nota: Información extraída de Team, por Diag Lab, 2024.

Por último, en la **Figura n.º 3** se adjunta un organigrama simplificado que expone el flujo de las comunicaciones dentro del laboratorio. Esto debido a que la estudiante no pertenece a un equipo específico de trabajo; sin embargo, realizando una clasificación solamente relacionada con el proyecto por desarrollar la estudiante pertenece al equipo de desarrolladores *full-stack*.

Figura n.º 3 Organigrama del trabajo



Nota: Elaboración propia (2024).

Con respecto a cada uno de los equipos mencionados, seguidamente se brinda una pequeña descripción de sus funciones:

- **Equipo de análisis de imágenes médicas:** Son aquellos estudiantes que se encuentran realizando su maestría específicamente en el análisis de imágenes médicas por medio de visión computarizada.
- **Desarrolladores *full-stack*:** Participan en alguna o todas las siguientes fases del desarrollo de una aplicación o plataforma:
 - Diseño y desarrollo web.
 - Diseño de base de datos.
 - Infraestructura para el procesamiento de *Big Data*.
- **Herramientas de etiquetado manual de imágenes médicas:** Son aquellos estudiantes enfocados en conocer a fondo términos y definiciones médicas que luego utilizan para manualmente identificarlas en la imagen.
- **Estudiantes de la Universidad *Simón Fraser*:** Este es un grupo de colaboración donde se recibe y envía información de relevancia para ambos laboratorios.

1.2.3. Trabajos similares realizados dentro y fuera de la organización

En este apartado se realiza una explicación de proyectos similares al interior del negocio; así como, del exterior que van a funcionar como insumo dentro del presente proyecto.

1.2.3.1. Proyectos internos

Dentro de los proyectos similares realizados de manera interna del laboratorio se tiene:

- **Una herramienta de escritorio para identificar las fases en una imagen de TAC abdominal con contraste (Pavadaisamy, 2024):** El proyecto consistía en el desarrollo de una herramienta de escritorio que fuera capaz de identificar y clasificar la fase de un TAC. En otras palabras, la herramienta se encargaba de analizar la imagen médica para indicar si esta se encontraba en fase “No contraste”, “Arterial” o “Venosa”, usando como insumo una larga base de datos pública de personas con padecimientos abdominales. Este modelo obtuvo resultados en sus métricas de evaluación de exactitud 81,7%, precisión 78,7% *recall* 78,9% y *F1 Score* 80,8%.
- ***Automatic CT Scan Field of View (FOV) Detection Using Deep Learning (Golzan et al., s.f.)*³:** Este proyecto consistía en la creación de diferentes modelos de *Deep Learning* que ayudaran a clasificar tomografías axiales computarizadas (TAC) según la parte del cuerpo que se muestra dentro de las imágenes médicas, para esto se definieron seis tipos de imágenes llamadas pecho, abdomen, pelvis, abdomen-pecho, abdomen-pelvis, pecho-abdomen-pelvis e imagen no legible.

1.2.3.2. Proyectos externos

Con respecto a proyectos externos, se presenta el siguiente proyecto:

- **Reconocimiento de fases en tomografías computarizadas con contraste basado en aprendizaje profundo y muestreo aleatorio (Muhamedrahimov et al., 2022):** Proyecto relacionado con el reconocimiento de fases en tomografías axiales computarizadas con contraste por medio de modelos de *Deep Learning* y utilizando un muestreo aleatorio; donde se buscaba encontrar un modelo con latencia optimizada y complejidad reducida para la clasificación de imágenes médicas, contrastando con los modelos previamente enfocados en redes neuronales (CNN) 3D.

³ Artículo en proceso de revisión interna, no accesible públicamente.

1.3. Planteamiento del problema

En esta sección se describe la situación problemática identificada dentro de los enfoques de investigación del laboratorio, lo cual motiva el desarrollo del proyecto, así como la mención de la justificación del proyecto junto con los beneficios esperados del producto final.

1.3.1. Situación problemática

Los sistemas de salud pública canadiense han sido afectados por diferentes situaciones que han resultado en el deterioro de diferentes áreas de la salud, específicamente en las listas de espera para realizarse un TAC y recibir su respectiva interpretación, como lo menciona la Agencia Canadiense de Medicamentos y Tecnologías en Salud (2023) en su artículo llamado *Wait List Strategies for CT and MRI Scans*, dentro del artículo también se destaca como después de la pandemia los centros médicos han sufrido de aumento de demanda, problemas con los médicos, falta de equipamiento o actualización del existente, problemas de presupuesto, entre otros, que han contribuido al aumento en las listas de espera.

Deloitte & Canadian Medical Association (2021) comentan, en su informe respecto al impacto de la pandemia dentro del sector salud, cómo el impacto de los atrasos por motivo de pandemia va a impactar a los trabajadores de salud que al 2021 había un 72,9% de ellos que sentían algún grado de *burnout*⁴. Además, dentro de este informe se destaca la necesidad de acudir a nuevas tecnologías y herramientas que ayuden con la gestión de la capacidad de los diferentes centros médicos, ya que, por el paro de la pandemia se tiene un *back-log* en aumento por personas con enfermedades crónicas y pacientes con nuevos padecimientos por causa de la pandemia. Por último, este informe hace hincapié en la suma elevada de dinero que tendría que invertir el gobierno canadiense para estabilizar el sector de salud a niveles prepandémicos.


Profundizando en el tema de “problemas con los médicos”, no solo se debe tomar en cuenta el agotamiento que los médicos padecen por tomar una mayor cantidad de turnos, con tal de revisar la mayor cantidad de exámenes posibles; sino que también hay que tomar en cuenta que muchos de estos médicos emigran para otros centros de salud donde les ofrecen mejores y más estables condiciones de trabajo, según lo mencionado por Axelrod (2024) en su artículo *More MRI techs needed to combat wait times as burnout figures rise, association says*.

Por otro lado, según lo indicado por K. Popuri (comunicación personal, 23 de abril del 2024), se adjunta la **Figura n.º 4** donde se presenta un diagrama de flujo con el proceso para la interpretación de un TAC manualmente.

⁴ El síndrome de *burnout* o del quemado es definido como “respuesta al estrés laboral crónico integrado por actitudes y sentimientos negativos hacia las personas con las que se trabaja y hacia el propio rol profesional” (P. Gil-Monte, 1999).

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Figura n.º 4 Diagrama de flujo interpretación manual de TAC



Nota: El flujo de trabajo presentan los pasos a seguir por el personal médico para analizar e interpretación de una imagen médica, por K.Popuri, comunicación personal, 2024.

Después de lo visualizado, se ha decidido para este proyecto centrarse en lo encerrado por la línea punteada con el afán de agilizar el proceso de análisis de las imágenes médicas, específicamente los TAC.

Además, Pavadaisamy (2024) detalla otros de los inconvenientes y problemáticas identificadas dentro del sector de salud canadiense como lo son:

- **Proceso manual de selección de TAC:** Cuando un doctor necesita hacer la respectiva revisión e interpretación de una imagen médica específica (TAC), este debe abrir una por una para encontrar aquella que sea la correcta y además validar que esta sea de calidad, lo cual causa un retraso en tiempo de espera para tomar una decisión y sobretrabajo.
- **Demanda de interpretación:** El TAC es uno de los primeros exámenes que se les realizan a las personas en aras de realizar el diagnóstico o tratamiento de la mayoría de las enfermedades a nivel mundial, por lo que los médicos se encuentran con una gran cantidad de exámenes pendientes de analizar e interpretar.
- **Limitación de recursos humanos y económicos:** En zonas alejadas o con recursos limitados, se tiene personal de base general (doctor general) que se encarga de realizar dicho análisis sin un conocimiento en la correcta interpretación de los TAC.
- **Escasez de herramientas tecnológicas enfocadas en el etiquetado o clasificación de imágenes médicas:** Se han presentado dentro del mercado soluciones tecnológicas que apoyan con el análisis de imágenes médicas, sin embargo, suelen ser rígidas y costosas en temas de operabilidad y mantenimiento.

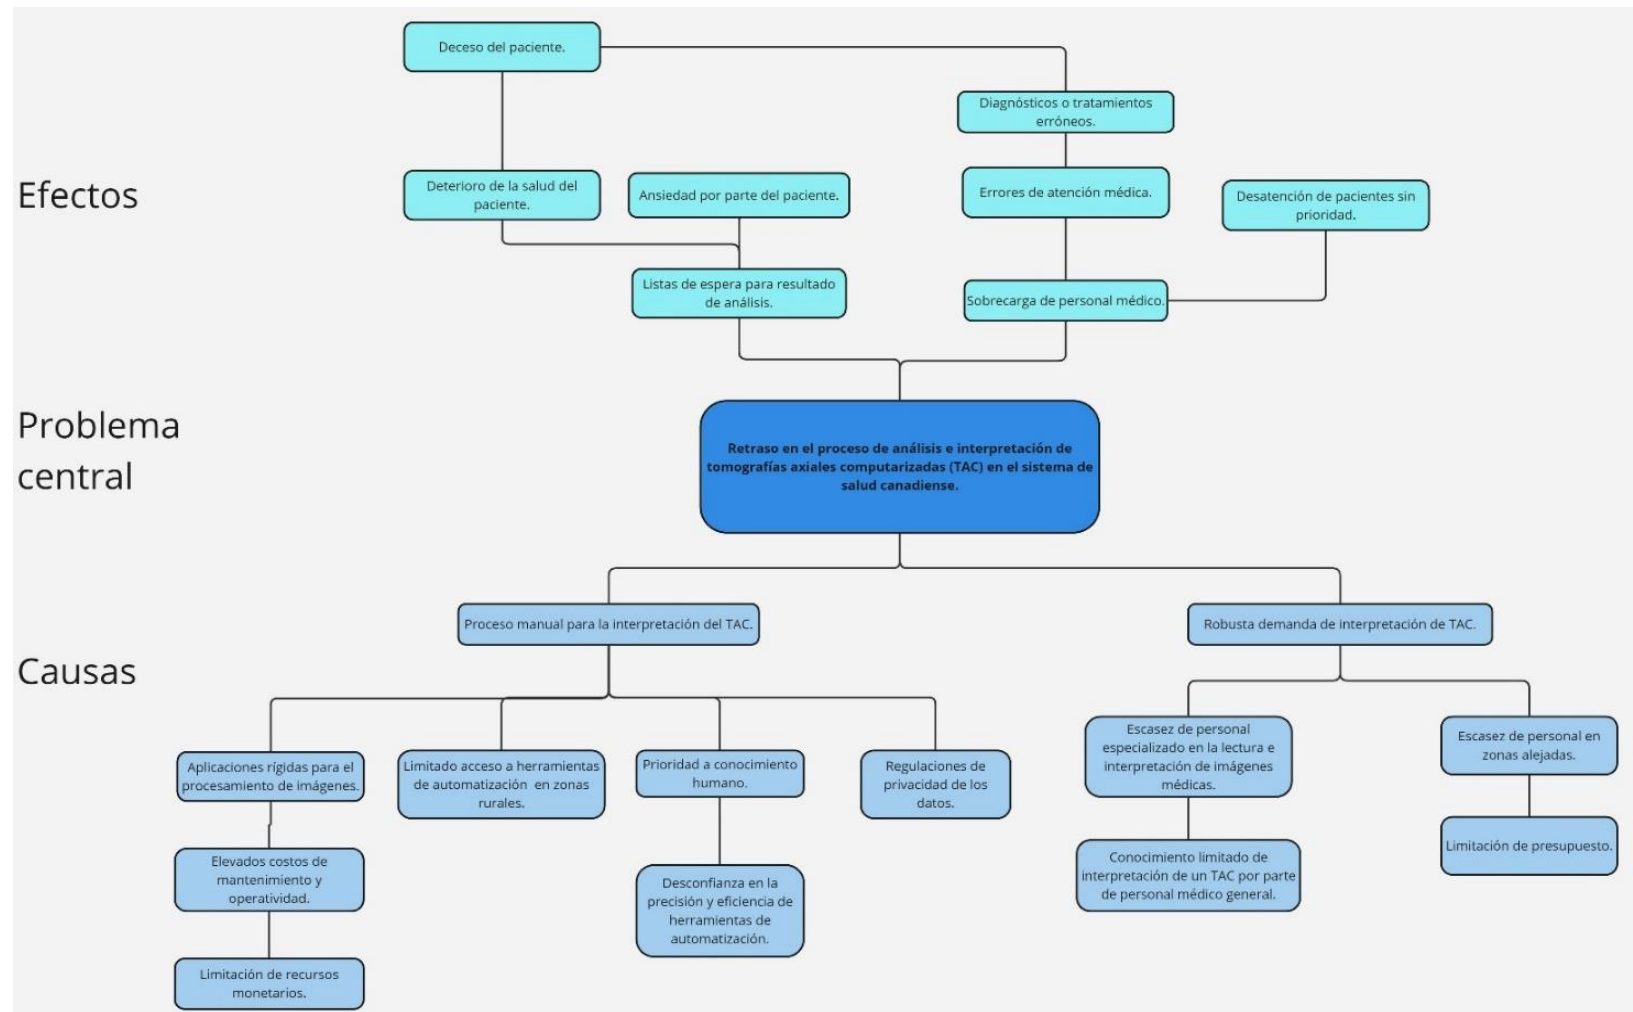
Finalmente, se identifican otros factores que contribuyen al proceso manual de interpretación de imágenes médicas, los cuales incluyen:

- **Limitado acceso a herramientas de automatización en zonas rurales:** la Canadian Association of Radiologists (2019) ha mencionado la necesidad de nivelación al acceso de máquinas para interpretación de imágenes médicas en las diferentes provincias del país.
- **Prioridad a conocimiento humano:** aunque se han comenzado a desarrollar y proponer herramientas de automatización, el personal médico aún muestra cierto grado de desconfianza en cuanto a su precisión y eficiencia. Como resultado, realizan 'dobles chequeos', llevando a cabo un escaneo manual para confirmar los resultados (Lakhani et al., 2017).
- **Regulaciones de privacidad de los datos:** existen diversas regulaciones que rigen la manipulación y el suministro de datos o historiales médicos para su procesamiento en aplicaciones o herramientas de automatización. Por ejemplo, la ley reguladora en la provincia de Ontario establece disposiciones sobre la recolección, uso y transferencia de datos para proteger la salud del paciente, siendo uno de sus principales artículos. (Personal Health Information Protection Act, 2004).

Por ello, tomando en cuenta las anteriores causas se ha llegado a la conclusión de que la situación problemática por atacar es: “**Retraso en el proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) en los sistemas de salud canadiense**”.

En la **Figura n.º 5**, se presenta el árbol del problema del proyecto, donde se detalla problema, causas (ramas inferiores) y efectos (ramas superiores).

Figura n.º 5 Árbol del problema



Nota: Elaboración propia (2024).

1.3.2. Justificación del proyecto

Este apartado pretende explicar la importancia que esta investigación presenta para la carrera de Administración de Tecnologías de Información; así como para el desarrollo profesional de la estudiante.

Según el artículo 14 del Reglamento Específico del Trabajo Final de Graduación de ATI (RETFG-ati), donde se presentan las diferentes áreas de desarrollo del trabajo final de graduación, se mencionan 14, pero este proyecto aplica las siguientes tres: Análisis diseño y programación de sistemas de información; Administración de procesos de negocio; e Inteligencia de negocios., las cuales, tienen un impacto directo en la ejecución del proyecto.

Primero, el área del análisis, diseño y programación de sistema de información se encuentra relacionado con el proyecto, ya que, dentro de las actividades por realizar, se encuentra el desarrollo de una aplicación gráfica que permita al personal médico acceder a las funcionalidades creadas de manera fácil y rápida. Además, se ve involucrado este conocimiento dentro del diseño y construcción del modelo de *Deep Learning* para la clasificación de las imágenes médicas; donde se ven envuelto el uso de diferentes librerías de *software* como lo es *pytorch* junto con lenguajes de programación como *Python*, *JavaScript*, *Electron*, entre otros. Sumado a esto se encuentra el conocimiento adquirido en la disminución de la deuda técnica a la hora de programar; y los principios de diseño y las buenas prácticas del programador que optimizan el desarrollo de *software*.

Segundo, el área de analítica empresarial dota al estudiante con los conocimientos esenciales para realizar el preprocesamiento de datos para asegurar la calidad de la información, así como la generación de las pruebas y entrenamientos aplicados a modelos de *Deep Learning*, los cuales serán de gran ayuda dentro de la elaboración y mejora de modelos para el análisis de imágenes médicas TAC. Adicionalmente, estos conceptos permiten que la estudiante lleve a cabo las debidas evaluaciones, en dicho modelo(s), para obtener la exactitud y porcentaje de error esperados, por medio de la aplicación de la metodología CRISP-DM para asegurar la calidad y relación con el problema de estos.

Tercero, la última área, de administración de procesos de negocio, provee al estudiante con los conocimientos necesarios para evaluar un proceso de negocio de principio a fin, identificando los cuellos de botella y oportunidades de mejora como lo es la metodología Gestión de Procesos de Negocio (BPM, por sus siglas en ingles). Gracias a estos conocimientos la estudiante será capaz de presentar la manera de optimizar el proceso de análisis e interpretación de imágenes médicas.

Por otra parte, este proyecto tiene importancia para la escuela, pues introduce una propuesta innovadora que aprovecha las tecnologías contemporáneas aplicadas a un ámbito de relevancia universal, como es el sector de la salud. Además, ofrece la oportunidad de diversificar las áreas de investigación y aplicar los conocimientos adquiridos durante la carrera en diferentes campos de acción. Por otra parte, la oportunidad de desarrollar el proyecto en una institución extranjera presenta una oportunidad que refuerza el afán de la escuela por buscar futuras colaboraciones de la carrera con organismos nacionales e internacionales, también el

hecho de la internacionalización del proyecto presenta una oportunidad de colaboración con expertos y profesionales de diferentes dominios de conocimiento que nutran los conocimientos del área y la estudiante.

Por último, el laboratorio de investigación se ve beneficiado por este proyecto al desarrollarse una herramienta de interpretación y clasificación de imágenes médicas no existente en el mercado y que está diseñada para ser accedida de manera conveniente y con interfaz fácil de navegar.

1.3.3. Beneficios esperados del Trabajo Final de Graduación

En esta sección se detallan tanto los beneficios directos como los indirectos que se espera obtener con la ejecución del proyecto propuesto.

1.3.3.1. Beneficios directos

1. Facilitación del trabajo del personal médico al poseer una herramienta de escritorio conveniente y útil para la clasificación de las tomografías computarizadas (TAC).
2. Incremento en la precisión para la clasificación de imágenes médicas, con respecto al estado del arte.
3. Optimización de tareas repetitivas y manuales dentro del sector salud, como lo es la clasificación de imágenes médicas.
4. Agilización en el proceso de descarte de imágenes médicas con defectos o incompletas.

1.3.3.2. Beneficios indirectos

1. Optimización de la productividad del personal médico al reducir el tiempo dedicado a tareas de análisis manuales.
2. Reducción del volumen de trabajo para el personal médico.
3. Prevención de diagnósticos, tratamientos o pronósticos por imágenes médicas defectuosas.
4. Aprovechamiento de la herramienta por parte de diferentes sectores de salud alrededor del mundo.
5. Posibilidad de integración con otras herramientas desarrolladas dentro del laboratorio.

1.4. Objetivos del Trabajo Final de Graduación

En esta sección, se definen el objetivo general, así como los objetivos específicos que serán los resultados esperados al completar el proyecto. Los objetivos están planteados de manera que den respuesta a la problemática planteada anteriormente.

1.4.1. Objetivo general

Desarrollar una herramienta de escritorio basada en la ejecución de un modelo de *Deep Learning*, utilizando la metodología CRISP-DM, para la automatización del proceso de análisis e interpretación de un TAC por medio de su clasificación; dentro del II semestre del 2024.

1.4.2. Objetivos específicos


1. Seleccionar los datos correctos dentro de las bases de datos, para la prueba y entrenamiento del modelo de *Deep Learning*, por medio de la limpieza y clasificación de los registros.
2. Desarrollar un modelo de *Deep Learning* que mejore el estado del arte, con el fin de definir el modelo óptimo.
3. Evaluar el modelo de *Deep Learning* para la selección del modelo óptimo en términos de precisión, eficiencia y desempeño.
4. Implementar una herramienta de escritorio (beta) integrando el modelo de *Deep Learning* seleccionado, que sea accesible y útil al personal médico, para la agilización del proceso de análisis e interpretación de los TAC.

1.5. Alcance

El objetivo principal de este proyecto es desarrollar una herramienta de escritorio que implemente un modelo de *Deep Learning* para realizar un análisis y clasificación de tomografías axiales computarizadas (TAC).

Para lograr este propósito, se consideran varios aspectos fundamentales de las tareas por realizar junto con los pasos descritos en la metodología CRISP-DM, derivando en el planteamiento de cinco grandes fases, visualizadas en la **Figura n.º 6**.

Figura n.º 6 Fases del proyecto.



Nota: Elaboración propia (2024).

1.5.1. Fase 1 – Entendimiento del negocio

La primera fase está relacionada con la comprensión de cómo funciona el flujo de trabajo dentro del laboratorio, la identificación de las necesidades y expectativas del proyecto, familiarización con el ambiente de desarrollo y comprensión del modelo base, en términos de tipo de modelo utilizado, estructura del modelo, fuente de datos, funcionalidad, entre otros; así como la selección de la base de datos disponible con las imágenes médicas por utilizar para realizar las debidas pruebas de funcionalidad del modelo. Al finalizar estas actividades se obtiene la base de datos que fungirá como insumo de la siguiente fase.

1.5.2. Fase 2 – Comprensión y preprocesamiento de datos

La segunda fase se centra en el preprocesamiento de la base de datos seleccionada en la fase 1, por lo que se llevan a cabo procesos de limpieza, eliminando registros inexistentes, depuración, ignorando registros que no tienen valor, selección y etiquetado manual de las imágenes médicas dentro de esta. Esto con la finalidad de obtener conjunto de datos de prueba de calidad, que permita obtener resultados apegados a la realidad, expandir el conocimiento del modelo y disminuir la probabilidad de clasificaciones erróneas. Al finalizar esta fase se obtienen las imágenes etiquetadas con su respectiva clase depuradas para ser utilizadas para la prueba del modelo.

1.5.3. Fase 3 - Modelaje

La tercera fase está enfocada en la manipulación del modelo base, tomando como insumo las imágenes preprocesadas en la fase anterior. Dentro de las actividades se encuentra la selección de los conjuntos de datos de entrada para las pruebas del modelo, la definición del ambiente de pruebas, la ejecución de pruebas de funcionalidad, análisis de las métricas de evaluación obtenidas, identificación de patrones de error y, por último, decisión de reentrenar o modificar el modelo. Al cierre de esta fase, se obtiene el modelo que será utilizado para la integración con la aplicación de clasificación de TAC.

1.5.4. Fase 4 – Integración

En la cuarta fase se toma el modelo seleccionado en la fase 3 y se procede a prepararlo para ser guardado tomando en cuenta sus configuraciones de entrada y salida, después se valida que este fue almacenado con todas sus características completas utilizando la herramienta *Netron*⁵; y posteriormente se gestiona la integración y comunicación modelo-aplicación. Al terminar esta fase el modelo está guardado y es funcional dentro de la lógica de la aplicación de clasificación de TAC.

1.5.5. Fase 5 - Despliegue

La fase 5 se centra en el desarrollo de aplicación de clasificación de TAC donde se llevan a cabo actividades como el diseño gráfico de las interfaces gráficas, el diseño de la arquitectura de la aplicación y la distribución de las funcionalidades, las respectivas pruebas de caja negra de las funcionalidades y, por último, el paso a producción de la versión de escritorio (beta) dentro del contexto del laboratorio. Al concluir esta fase se tiene el producto final del proyecto.

1.5.6. Exclusiones

En esta sección se indican aquellos entregables o productos que podrían esperarse del proyecto pero que por alguna razón específica quedarán fuera del alcance.

- Realización de una prueba de campo con personal médico, debido a no disponibilidad de este.
- Resultados de pruebas con personal médico específico, esto debido al tiempo designado para el desarrollo del proyecto.
- Exclusión de la implementación web inicial, dado que se comenzará con la versión de escritorio.
- Integración de la aplicación a elaborar con otras herramientas que se están desarrollando o se han desarrollado dentro del el laboratorio, debido al tiempo estipulado para la completitud de este proyecto junto con la diferencia de cronogramas de desarrollo de las otras herramientas.

⁵ <https://netron.app/>

1.6. Supuestos

En esta sección se indica explícitamente cuáles serán los factores o elementos que la estudiante asume se cumplirán o serán ciertos en la realización del proyecto.

- La herramienta será desarrollada con el siguiente *stack* tecnológico:
 - *Front-end*: Electron y Onnx.
 - *Back-end*: Python.
 - Pruebas y evaluación del modelo: CRISP-DM.
- Se tienen todos los permisos para acceder a los programas de desarrollo de aplicaciones y los modelos de *Deep Learning*.
- Las bases de datos suministradas por el laboratorio se encuentran disponibles para la descarga y manipulación.
- El laboratorio provee a la estudiante con todos los insumos computacionales para desarrollar el proyecto.
- El laboratorio provee al estudiante con conocimientos básicos, con respecto a la utilización de los recursos asignados.
- Las personas que trabajan en el laboratorio están dispuestas a brindar apoyo a la estudiante con dudas, información y capacitación para el desarrollo del proyecto.

1.7. Entregables

En la **Tabla n.º 1.** se expone la lista de entregables planteados para la completitud del proyecto asociados con su respectivo objetivo, al cual dan respuesta.

Tabla n.º 1. *Entregables del proyecto.*

Nombre entregable	Descripción de entregable	Objetivo
Análisis y selección de las características y elementos relevantes dentro de los TAC.	Subsección dentro del documento de reporte donde se realiza una revisión documental de los elementos del TAC que se necesita identificar por medio del modelo de <i>Deep Learning</i> .	OBJ. 1: Seleccionar los datos correctos dentro de las bases de datos, para la prueba y entrenamiento del modelo de <i>Deep Learning</i> , por medio de la limpieza y clasificación de los registros.
Modelo de Deep Learning para reconocimiento y clasificación de imágenes médicas de tipo TAC.	Se refiere al código relacionado con el modelo que se encargará de analizar y clasificar las imágenes médicas.	OBJ. 2: Desarrollar un modelo de <i>Deep Learning</i> que mejoren el estado del arte, con el fin de definir el modelo óptimo.
Resultados de la evaluación del modelo de Deep Learning.	Subsección del documento de reporte donde se presenta la información de las pruebas realizadas al modelo y sus respectivos resultados; en términos de precisión, eficiencia, <i>recall</i> , entre otros.	OBJ. 3: Evaluar el modelo de <i>Deep Learning</i> para la selección del modelo óptimo en términos de precisión, eficiencia y desempeño.
Herramienta de escritorio para la clasificación de imágenes médicas.	Se refiere al programa donde se encuentra el modelo de <i>Deep Learning</i> encargado de la clasificación y análisis de las imágenes médicas, implementado de manera gráfica para su respectiva utilización por parte del personal médico.	OBJ. 4: Implementar una herramienta de escritorio (beta) integrando el modelo de <i>Deep Learning</i> seleccionado, que sea accesible y útil al personal médico, para la agilización del proceso de análisis e interpretación de los TAC.
Reporte final con todos los hallazgos y resultados del proyecto.	Documento resumen de la metodología utilizada dentro del proyecto junto con sus respectivos resultados y hallazgos.	Responde a todos los objetivos específicos: 1, 2, 3 y 4.

Nota: Sitio web oficial del laboratorio.

1.7.1. Gestión del proyecto

En esta sección se describen aquellos documentos relacionados con la gestión general del proyecto.

1.7.1.1. Minutas

En el **Apéndice B. Plantilla de minutas** se encuentra la plantilla de minuta que será utilizada a lo largo del proyecto para documentar las informaciones recibidas por medio de reuniones de equipo, con otros miembros del laboratorio, con el profesor tutor externo y el profesor tutor de la carrera.

1.7.1.2. Gestión de cambios

En el **Apéndice C. Plantilla de hoja de cambios** se encuentra la plantilla que será utilizada para realizar la gestión de cambios dentro del proyecto.

1.8. Limitaciones

En esta sección se indica explícitamente cuáles serán los factores y elementos que en alguna medida restringen la realización del proyecto.


- Limitación en la información del modelo de *Deep Learning*, específicamente de *ResNet50*.
- Limitación con la disponibilidad de las personas que están trabajando dentro del laboratorio, esto debido a que cada persona se encuentra trabajando en su propio proyecto, lo que daría como resultado conflictos para adquirir información o capacitación.
- Limitación de presupuesto monetario para obtener acceso a retroalimentación y comentarios por parte de personal médico canadiense.

2. Marco Conceptual

En este apartado se definen y explican los diferentes conceptos relacionados con el desarrollo del proyecto planteado. Para esto, se divide en dos secciones: la primera dedicada a conceptos y la segunda dedicada a soluciones o proyectos similares; ambas secciones ordenadas de lo general a lo específico.

En la **Figura n.º 7** se muestra la estructura del marco conceptual por medio de un mapa con los conceptos abordados en la sección dividido en dos grandes apartados: conceptos generales y trabajos relacionados.

Figura n.º 7 Estructura del marco conceptual



Nota: Elaboración propia (2024).

2.1. Conceptos generales

En este apartado serán abordados conceptos generales relacionados con el desarrollo, implementación y evaluación de modelos de *Deep Learning* aplicados, específicamente para la clasificación de tomografías axiales computarizadas (TAC).

2.1.1. Imágenes médicas

2.1.1.1. Procedimiento radiológico


Comenzando es necesario brindar una definición de procedimiento, según la Clínica Universidad de Navarra (s.f.), “es un método o conjunto de operaciones llevadas a cabo para realizar una actividad o proceso” (párr. 1).

Por otro lado, la Real Academia Española (s.f.) define a la radiología como “estudio de la aplicación terapéutica de los distintos tipos de radiaciones, como los rayos X, los rayos gamma o los ultrasonidos, y de su utilización en el diagnóstico y tratamiento de las enfermedades” (párr. 1).

Por ende, se define al procedimiento radiológico como un conjunto de operaciones que utiliza la interpretación y análisis de distintos tipos de radiaciones, como los rayos X, gamma o los ultrasonidos, para el diagnóstico y tratamiento de las enfermedades.

Por último, se adjunta en la **Figura n.º 8** un procedimiento radiológico general, resaltando con rojo los pasos del proceso que son afectados por la elaboración del presente proyecto.

Figura n.º 8 Procedimiento radiológico.



*Nota: En la figura se resalta de color rojo los pasos dentro del proceso impactados por el proyecto.
Elaboración propia (2024).*


2.1.1.2. Imágenes médicas

Por imagen médica se entiende

... aquella que procede del conjunto de técnicas y proceso usados para crear imágenes del cuerpo humano, o partes de él, con propósitos clínicos, esto es, procedimientos médicos que buscan revelar, diagnosticar o examinar enfermedades, o bien con propósitos científicos, tales como el estudio de la anatomía física y metabólica. (García Fenoll, 2010, p. 15)

En la **Figura n.º 9** se adjunta un esquema resumen de los tipos principales de imágenes médicas, según Huérfano et al. (2016), y se resalta en rojo el tipo de imagen médica por analizar en este proyecto.

Figura n.º 9 Tipos de imágenes médicas.



Nota: En la figura se resalta de color rojo el tipo de imagen médica utilizada por el proyecto.

Elaboración propia (2024).

2.1.1.3. Tipos de imágenes médicas: TAC

El Instituto Nacional de Imágenes Biomédicas y Bioingeniería de los Estados Unidos (2022) definió una Tomografía Axial Computarizada (TAC) como

Un procedimiento computarizado de toma de imágenes con rayos X en el que se proyecta un haz angosto de rayos X a un paciente y se gira rápidamente alrededor del cuerpo, produciendo señales que son procesadas por la computadora de la máquina para generar imágenes transversales, o "cortes". Estos cortes se llaman imágenes tomográficas y pueden brindar al médico información más detallada que las radiografías convencionales. Una vez que la computadora de la máquina recopila varios cortes sucesivos, estos se pueden "apilar" digitalmente para formar una imagen tridimensional del paciente que permite identificar más fácilmente las estructuras básicas, así como posibles tumores o anomalías. (párr. 1)

En el caso de este proyecto los TAC son el principal insumo de entrenamiento, validación y prueba del modelo de *Deep Learning* elaborados.

2.1.1.4. Características de un TAC


Como introducción, la Real Academia Española (s.f.), define una característica como una cualidad que sirve como insumo para distinguir a alguien o algo de sus semejantes. En este caso, dichas características ayudan a distinguir un TAC de las otras imágenes médicas. Además, algunas de estas son utilizadas como parámetros de clasificación en los modelos de *Deep Learning*.

2.1.1.4.1. Tipos de TAC

- **Con contraste:** Un TAC contrastado es un procedimiento que utiliza la ayuda de una solución de contraste intravenoso antes del escaneo. Esta sustancia ayuda a resaltar ciertas estructuras y tejidos en las imágenes, permitiendo así la fácil identificación de anomalías, lesiones y enfermedades. (Instituto Radiológico Providencia, 2023) Por otro lado, al suministrar la solución de contraste intravenoso, este se divide en diferentes fases según la parte del cuerpo en donde se encuentra la sustancia, entre ellas:
 - **Arterial:** Se presenta cuando la sustancia contrastante se encuentra en las arterias y no ha alcanzado los órganos u otros tejidos blandos. (Baba et al., 2023)
 - **Venoso:** Se presenta cuando se tiene un completo realce o resalte de las venas portas y las arterias hepáticas; así como del parénquima hepático. (Baba et al., 2023)
 - **Fase tardía:** Se presenta cuando hay un equilibrio o la sustancia ya ha perdido su efecto en la mayor parte del cuerpo. (Baba, 2021)

En la **Figura n.º 10** se expone un ejemplo de cómo se ven las diferentes fases de un TAC con contraste.

Figura n.º 10 Fases de TAC con contraste




Nota: Adaptado de *Contrast Enhancement Phases in Abdominal CT.*, de Muhamedrahimov et al., 2022, *Using Machine Learning to Identify Intravenous Contrast Phases on Computed Tomography*. Computer Methods and Programs in Biomedicine. 25. <https://doi.org/10.1016/j.cmpb.2021.106603>.

- **Sin contraste o TAC no contrastado:** Un TAC sin contraste es un procedimiento que no utiliza un agente de contraste para obtener imágenes de alta resolución de diferentes partes del cuerpo, es especialmente utilizado para huesos, órganos y tejidos blandos, proporcionando información de la morfología y características básicas de las estructuras evaluadas. (Instituto Radiológico Providencia, 2023)

En la **Figura n.º 11**, se expone un ejemplo de cómo se visualiza un TAC sin contraste.

Figura n.º 11 TAC Sin contraste.




Nota: Adaptado de Brain computed tomography at first emergency department visit, de Chia, Michael, 2020, Development of a delayed chronic subdural hematoma 2 months after mild traumatic brain injury with a normal initial brain computed tomography: A case report. Journal of the American College of Emergency Physicians Open. 1.

2.1.1.4.2. Formatos de las imágenes

- **Imagen digital y comunicación en medicina (DICOM, por sus siglas en inglés):** Es el estándar internacional para imágenes médicas e información relacionada. Este define los diferentes formatos utilizados en las imágenes médicas para intercambiar información que contenga los datos y calidad necesaria para uso médico. (DICOM, s.f.)

En la **Figura n.º 12** se expone un ejemplo de cómo se ve un TAC con formato DICOM y sus diferentes datos.

Figura n.º 12 Imagen de TAC en formato DICOM




Nota: Adaptado de *CT slice in DICOM format*, de Menaka, R. & Chellamuthu, Chinna & Ramamurthy, Karthik, 2011, Efficient 3D point cloud generation from medical images in frequency domain using discrete curvelet transform. European Journal of Scientific Research. 60. 305-315.

- **Iniciativa de la tecnología informática de neuroimágenes (NiFTi**, por sus siglas en inglés): Es un formato de imagen ampliamente utilizada en el campo médico y en gran variedad de *softwares* para almacenar información relevante de las imágenes médicas, en un solo archivo y utilizando meta-data en el encabezado para guardar mayor cantidad de datos importantes. (Encord, s.f.)

En la **Figura n.º 13** se presenta un ejemplo de imagen médica en formato NiFTi.

Figura n.º 13 Imagen de TAC en formato NiFTi.




Nota: Adaptado de *The proposed downsampling overview (Quantization Hiding)*, de Elhadad, A., Jamjoom, M. & Abulkasim, H, 2024, Reduction of NIFTI files storage and compression to facilitate telemedicine services based on quantization hiding of downsampling approach. Sci Rep 14, 5168.

- **Proyección de máxima intensidad (MIP**, por sus siglas en inglés): Es una herramienta de visualización tridimensional que se utiliza para mostrar

conjuntos de datos extraídos en un TAC. Estas imágenes no dependen de un umbral y conservan la información de atenuación. (Prokop et al., 1997)

En la **Figura n.º 14** se muestra un ejemplo de un TAC de cráneo en formato MIP.


Figura n.º 14 Imagen de TAC en formato MIP.



Nota: Adaptado de Maximum intensity projection (MIP) of 3-D time-of-flight MR Angiogram (MRA) of the brain, de Duker et al., 2021, Microcephalic osteodysplastic primordial dwarfism type II is associated with global vascular disease Orphanet Journal of Rare Diseases. 16. 10.1186/s13023-021-01852-y.

Por último, en la **Figura n.º 15** se presenta un ejemplo de cómo se va convirtiendo una imagen con formato DICOM a formato 2D para ser utilizada dentro de los modelos de *Deep Learning*. Por otro lado, en el caso del proyecto las imágenes contenidas en los diferentes *datasets*, ya se encuentran en formato NiFTi para ser procesadas a 2D por el modelo; así mismo, para el etiquetado manual estas se encuentran en su formato 2D.

Figura n.º 15 Ejemplo conversión de imagen DICOM a 2D




Nota: Adaptado de Flow of the preprocessing, de Zhao et al., 2024, Non-contrasted computed tomography (NCCT) based chronic thromboembolic pulmonary hypertension (CTEPH) automatic diagnosis using cascaded network with multiple instance learning. Physics in Medicine & Biology. 69.

2.1.1.4.3. Partes del cuerpo humano

En el caso de este proyecto, se define a las partes del cuerpo humano como aquellas secciones que serán utilizadas para la clasificación de las imágenes médicas, según la parte del cuerpo que muestran.

En la **Figura n.º 16** se presenta las diferentes secciones utilizadas dentro del proyecto para el modelo de clasificación.

Figura n.º 16 Secciones del cuerpo humano para modelo



Nota: Adaptado de Define ranges for each class, de Golzan et al., 2024, Automatic CT Scan Field of View (FOV) Detection Using Deep Learning.


2.1.2. Algoritmos de Machine Learning

De acuerdo con la empresa IBM (s.f.) un algoritmo de *Machine Learning* es:

Un conjunto de reglas o procesos utilizados por un sistema de inteligencia artificial para realizar tareas. Por lo general, se trata de descubrir nuevos datos y patrones, o de predecir valores de salida a partir de un conjunto determinado de variables de entrada. (párr. 1)

Además, en la **Figura n.º 17** estos algoritmos se dividen en diferentes tipos detallados por Holdsworth y Scapicchio (2024), se resalta con rojo el tipo de algoritmo aplicado en este proyecto.

Figura n.º 17 Algoritmos de Machine Learning



Nota: En la figura se resalta con rojo el tipo de algoritmo utilizado dentro del proyecto.
Elaboración propia (2024).

2.1.2.1. Deep Learning

Como señalan Holdsworth & Scapicchio (2024) el Deep Learning “es un subconjunto del *Machine Learning* que utiliza redes neuronales multicapa, llamadas redes neuronales profundas, para simular el complejo poder de toma de decisiones del cerebro humano” (párr. 1).

Además, mencionan cómo los modelos de aprendizaje supervisado sí o sí ocupan ser alimentados por datos estructurados y organizados, el *Deep Learning* acepta el aprendizaje no supervisado con el cual intenta comprender características o cualidades para obtener resultados precisos, sin la necesidad de datos estructurados.

Por otro lado, el *Deep Learning* es utilizado para la creación de diferentes tipos de modelos que permiten abordar problemas o conjuntos de datos específicos, los principales seis:

- **Redes neuronales convolucionales (CNN), modelo seleccionado para el proyecto.**
- Redes neuronales recurrentes (RNN).
- Autocodificadores y autocodificadores variacionales.
- Redes generativas antagónicas (GAN).
- Modelos de difusión.
- Modelos de transformadores

Por último, el proyecto es dirigido a la creación e implementación de un modelo de *Deep Learning*, específicamente el de tipo redes neuronales convolucionales (CNN), como se observa en negrita.

2.1.2.2. Modelo de CNN

Según lo descrito por Holdsworth & Scapicchio (2024), un modelo de redes neuronales convolucionales es utilizado principalmente en aplicaciones de visión artificial y clasificación de imágenes, ya que tiene la posibilidad de detectar características y patrones que permiten tareas como detección de objetos, reconocimiento de imágenes, facial y de patrones. Dentro de este modelo hay varios tipos de infraestructuras:

- **ResNet**
- Wide ResNet
- ResNeXt
- DenseNet
- NASNet
- SENet
- CaspNet


Sin embargo, este trabajo está enfocado en la aplicación del tipo ResNet, específicamente en su versión ResNet50, como se observa en negrita.

2.1.2.1. ResNet50

Cuando se habla de ResNet50, se entiende como infraestructura que cuenta con 50 capas de profundidad y 16 bloques residuales, que al mismo tiempo cuentan con varias capas convolucionales con conexiones residuales. Además, este presenta capas de agrupación, capas completamente conectadas y su respectiva capa de salida *softmax*-función de clasificación-para clasificación (Sharma, 2023).

Por otro lado, en la **Figura n.º 18** se adjunta una representación visual de cómo está diseñada la arquitectura.

Figura n.º 18 Arquitectura de ResNet



Nota: Adaptado de *Architecture of ResNet50* [Fotografía], por Tanish Sharma, 2023, Medium (<https://medium.com/@sharma.tanish096/detailed-explanation-of-residual-network-resnet50-cnn-model-106e0ab9fa9e>).

Sharma (2023) menciona los siguientes componentes:

- **Capas convolucionales:** Se entienden como los bloques que dan cimiento para las redes convolucionales, estas son algoritmos de *Deep Learning* normalmente utilizados para tareas de procesamiento de imágenes. Su funcionamiento radica en la extracción de características en las imágenes aplicando una serie de filtros convolucionales.
- **Conjunto de normalización:** Es una técnica utilizada para una rápida convergencia, un mejoramiento en la generalización y regularización. Además, es aplicado después de las primeras capas convolucionales, pero antes de la función de activación.
- **Activación ReLU:** Es una función de activación siendo una manera simple y efectiva de introducir no linealidad en la salida de una neurona. En otras palabras, es cambiar valores booleanos a números.
- **Máxima agrupación:** Es utilizado para reducir dimensiones espaciales en los mapas de características producidos por las capas convolucionales conservando la información importante. Esto contribuye a la reducción del costo computacional de la red y evitar el sobreajuste.
- **Capas aplanadas:** Son capas que se encargan de convertir la salida de la capa anterior en un vector unidimensional, que luego funciona como la entrada de la capa completamente conectada.
- **Capas conectadas:** Son capas donde todas las neuronas de la capa están conectadas a cada neurona de la capa anterior, estas son utilizadas típicamente como capas finales en una red neuronal y son las encargadas de las predicciones finales, donde cada neurona de la capa recibe entradas de capas anteriores.
- **Identificador del bloque:** Son utilizados para mantener la misma dimensión de entrada y salida. Estos identificadores constan de tres capas convolucionales, cada una seguida de conjuntos de normalización y su respectiva activación ReLU.

- **Promedio global de agrupación:** Es una operación que ayuda a realizar el cálculo del promedio de cada mapa de características con la misma cantidad de canales que la cantidad de filtros en la última capa convolucional.
- **Bloque de proyección:** Se utiliza en instancias donde las dimensiones de entrada y salida son diferentes, aplicando una red convolucional con un paso de (2,2) para reducir la entrada y un filtro de (1,1) para cambiar el tamaño de la entrada, y emparejarla con la salida.

Por otro lado, Sharma (2023) brinda una breve descripción de cada fase junto con sus respectivas actividades.

- **Fase 1:** En esta fase se toma la imagen sin procesar de entrada y se genera un mapa de características, utilizando filtros que ayudan a reducir la resolución de la imagen. Después, se aplica la capa de normalización, seguida de la función de activación ReLU. Finalmente se aplica una capa de agrupación para reducir nuevamente la muestra del mapa de características. Esto produce una salida en forma de mapa de características que sirve como entrada para los bloques convolucionales posteriores en la arquitectura.
- **Fase 2:** En esta fase se utiliza nueve capas de capa convolucional seguidas por un conjunto de normalización y una función de activación. Además, se crea una conexión residual donde se pasa la salida de la primera fase a una función de activación antes de las capas convolucionales.
- **Fase 3:** En esta fase se hace uso de 12 capas de capa convolucional seguidas nuevamente por un conjunto de normalización y función de activación. Asimismo, se utiliza un bloque de proyección para emparejar los valores de entrada, con respecto al valor esperado en la salida; después se envía dicha salida a la función de activación ReLU antes de la siguiente fase.
- **Fase 4:** En esta fase se aplican 18 capas de capa convolucional cada una seguida por un conjunto de normalización y su respectiva función de activación ReLU. La salida de dicha función se envía a la primera capa de la fase donde la dimensión del tamaño de la imagen es diferente, asimismo se aplica un bloque de proyección para coincidir los tamaños de entrada y salida con la segunda capa convolucional. Por último, se repite el mismo proceso que en las fases anteriores, la imagen va avanzando capa por capa, donde estas van comprendiendo características más profundas de la imagen.
- **Fase 5:** En esta fase se aplican nueve capas de capa convolucional cada una seguida por un conjunto de normalización y su respectiva función de activación ReLU. También, se utiliza el bloque de proyección y se termina con la salida de la función de activación como entrada en la agrupación promedio. Esto resulta en un vector que posee la misma cantidad de canales y de filtros.

2.1.2.2. Métricas de evaluación de los modelos

Siguiendo lo mencionado por Ramos (2020), las métricas de evaluación “son valores que permiten evaluar cuan bien se comporta un sistema al realizar la predicción, sea para una tarea de clasificación o para una tarea de regresión” (párr. 1). En el caso de este proyecto, las métricas de evaluación son fuente valiosa de información para tomar decisiones relacionadas con el modelo óptimo y que mejore el estado del arte. A continuación, se desglosan las medidas utilizadas dentro del proyecto.

2.1.2.2.1. Precisión

Definida como “valor que indica cuántas instancias, de todas las que han sido clasificadas como positivas, realmente son positivas” (Ramos, 2020, p. 2).

En la **Figura n.º 19**, se expone la fórmula utilizada para su cálculo.

Figura n.º 19 Fórmula de la precisión

$$P = \frac{TP}{\hat{n}_p} = \frac{TP}{TP + FP}$$

Nota: Elaboración propia (2024).

Donde se tiene:

- **TP:** Verdaderos positivos.
- **FP:** Falsos positivos.
- **$\hat{n}_p$:** Número total de instancias clasificadas como positivas.

2.1.2.2.2. Eficacia (exactitud)

Definida como “cantidad de instancias correctamente clasificadas con respecto al total de instancias” (Ramos, 2020, p. 2).

En la **Figura n.º 20**, se expone la fórmula utilizada para su cálculo.

Figura n.º 20 Fórmula de la exactitud

$$A = \frac{TP + TN}{n}$$

Nota: Elaboración propia (2024).

Donde se tiene:

- **TP:** Verdaderos positivos.
- **TN:** Verdaderos negativos.
- **n:** Cantidad total de instancias.

2.1.2.2.3. Recall

Definida como “cantidad de instancias que realmente son positivas y han sido clasificadas como positivas” (Ramos, 2020, p. 3).

En la **Figura n.º 21**, se expone la fórmula utilizada para su cálculo.

Figura n.º 21 Fórmula de la recall

$$R = \frac{TP}{n_p} = \frac{TP}{TP + FN}$$

Nota: Elaboración propia (2024).

Donde se tiene:

- **TP:** Verdaderos positivos.
- **FN:** Falsos negativos.
- **n_p :** Número total de instancias clasificadas como negativas.

2.1.2.2.4. F1-Score

Encargado de la “evaluación de cuán bien clasificadas están las instancias que fueron clasificadas como positivas. Se define como la media armónica de la precisión y el recall” (Ramos, 2020, p. 4).

En la **Figura n.º 22**, se expone la fórmula utilizada para su cálculo.

Figura n.º 22 Fórmula del F1-Score

$$F_1 = \frac{2}{\frac{1}{P} + \frac{1}{R}} = \frac{2PR}{P + R}$$

Nota: Elaboración propia (2024).

Donde se tiene:

- **P:** Resultado de la medida de precisión.
- **R:** Resultado de la medida de recall.

2.1.2.2.5. Desempeño

Se entiende la medida de desempeño como aquel promedio de todas las medidas de evaluación de los modelos de *Deep Learning*.

En la **Figura n.º 23**, se expone la fórmula utilizada para su cálculo.

Figura n.º 23 Fórmula del desempeño

$$Per = \frac{Precisión + Exactitud + F1 - Score}{3}$$

Nota: Elaboración propia (2024).

Donde se tiene:

- **Precisión:** Resultado de la medida de precesión.
- **Exactitud:** Resultado de la medida de exactitud.
- **F1-Score:** Resultado de la medida de F1-Score.

2.1.3. Herramientas para el desarrollo

La Real Academia Española (s.f.) define una herramienta como “un instrumento que sirve para algo o facilita el conseguir un fin” (párr. 1). En el caso del presente proyecto, las siguientes herramientas funcionan como insumo directo para conseguir crear los productos planteados en el alcance de este.

2.1.3.1. Python

Amazon AWS (s.f.) define a Python como “un lenguaje de programación ampliamente utilizado en las aplicaciones web, el desarrollo de software, la ciencia de datos y el *Machine Learning* (ML)” (párr. 1). En temas de *Machine Learning*, el lenguaje provee diferentes librerías que funcionan como insumo para desarrollar funcionalidades de ML, algunas de estas librerías son:

- **Pytorch:** Utilizada para la creación de redes neuronales.
- **Numpy:** Permite cálculos matemáticos complejos sobre *arrays* multidimensionales.
- **Pandas:** Utilizada para el tratamiento de datos.
- **SiPy:** Utilizada para resolver el cómputo de tareas científicas y analíticas.
- **TensorFlow:** Utilizada para la compilación y entrenamiento de modelos de ML de una forma sencilla utilizando API.
- **Matplotlib:** Utilizada para tareas de visualización.

2.1.3.2. Electron

Siguiendo lo descrito en la página oficial de Electron, este es “un *framework* para crear aplicaciones de escritorio usando JavaScript, HTML y CSS” (párr. 1). Brinda la posibilidad de mantener una base de código JavaScript y al mismo tiempo crear aplicaciones multiplataforma sin experiencia en el desarrollo nativo.

2.1.3.3. Onnxruntime

Según lo descrito en la página oficial de Onnx, Onnxruntime es un motor de inferencia que permite conectar o utilizar modelos de *Machine Learning* en diferentes plataformas de desarrollo, aprovechando sus beneficios:

- Compatible con los sistemas operativos macOS, Windows y Linux.
- Compatible con modelos de *Deep Learning*.
- Es un motor de alto rendimiento.
- Compatibilidad con diferentes librerías de hardware.
- Disponibilidad para ejecutar modelos desarrollados con PyTorch, TensorFlow/Keras, TFLite, entre otros.

2.1.3.4. Netron

Aplicación utilizada para verificar las características del modelo en formato Onnx.

2.1.4. Metodología CRISP-DM


De acuerdo con Shearer (2000), la metodología CRISP-DM es “una metodología de datos integral y un modelo de proceso que proporciona un plan completo para realizar un proyecto de minería de datos” (p. 13-14). Bajo la misma premisa, esta metodología consiste en un ciclo de vida de seis fases llamadas: entendimiento del negocio, comprensión de datos, preprocesamiento de los datos, modelado, evaluación e implementación.

A continuación, se brinda una breve descripción de cada fase del ciclo de vida explicado por Shearer (2000):

- **Entendimiento del negocio:** En esta fase se determinan los objetivos generales del negocio, se realiza una evaluación de la situación actual, se determina los objetivos del proyecto y, por último, se genera el plan del proyecto.
- **Comprensión de los datos:** Siguiendo el plan generado en la primera fase, se realiza la recolección de los primeros datos, se realiza una descripción y exploración de estos; por último, se realiza una verificación de su calidad.
- **Preprocesamiento de los datos:** Al verificar la calidad de los datos extraídos, se comienza con el preprocesamiento de los datos, que consiste en la selección, limpieza, construcción, integración y formateo de los datos.
- **Modelado:** Una vez preprocesados los datos, se continúa con el modelaje, donde se realiza una selección de la técnica para modelar, seguido de la generación de un modelo prueba para la posterior construcción del modelo y, por último, su evaluación.
- **Evaluación:** Ahondando en la evaluación de la fase anterior, se evalúan los resultados, asimismo se realiza un proceso de revisión y se determinan los siguientes pasos.
- **Despliegue:** Como última fase, se realiza un plan de despliegue, monitoreo y mantenimiento junto con la creación de un reporte final y una sesión de revisión del proyecto.

Por último, se adjunta, en la **Figura n.º 24**, el proceso de la metodología de manera gráfica.


Figura n.º 24 Metodología CRIPS-DM



Nota: Adaptado de El proceso de la Metodología CRISP-DM, por Sánchez, A. & Vidal, C., 2020, Factores asociados al éxito de los estudiantes en modalidad de aprendizaje en línea: un análisis en minería de datos, Formación universitaria 13(6):23-36, CC BY-NC 4.0

En resumen, en la **Figura n.º 25**, se adjunta un diagrama con las diferentes tecnologías, herramientas y programas que se estarán utilizando para el desarrollo del proyecto.

Figura n.º 25 Resumen de conceptos



Nota: Elaboración propia (2024).

2.2. Trabajos relacionados

En este apartado se realizará una exposición de diferentes temáticas relacionadas con el desarrollo de modelos de *Deep Learning* para la clasificación de imágenes médicas, comenzado desde proyectos básicos en el tema hasta el proyecto predecesor al presente.

2.2.1. Métodos de automatización de tareas médicas

Liu et al. (2020) plantean un modelo de redes neuronales profundas semisupervisado, donde pretenden aprovechar los retos de los diferentes modelos supervisados, con respecto a la necesidad de datos debidamente etiquetados para los modelos. Con esto generan un *framework* que permite ahorrar tiempo y esfuerzo médico para obtener datos de calidad para la generación y prueba de los diferentes modelos.

Yousif et al. (2020), en su trabajo de clasificación según la cantidad de células sanguíneas, por medio de la aplicación de un algoritmo especialmente mejorado que extrae y segmenta el recuento de glóbulos blancos o leucocitos (WBC, siglas en inglés), que luego es utilizado por algoritmos de ML para realizar la clasificación final. Entre de los algoritmos utilizados en el estudio se tienen clasificación K-Star, regresión aditiva, *bagging*, clasificador mapeado de entrada y árbol de decisión. En su estudio llegaron a la conclusión de que K-Star es el algoritmo con el mejor desempeño para la clasificación planteada.

2.2.2. Retos de los datos en los modelos de *Machine Learning*

Rouzrokh et al. (2022) exponen ciertos retos por considerar a la hora de procesar los datos que serán insumo para el entrenamiento, validación y prueba de los modelos, entre estos se encuentran: sesgo de selección (recolección de datos que no representan la muestra), sesgo de exclusión (se eliminan datos importantes), sesgo en la medición (favorecer un resultado en particular), etiquetar datos similares de manera inconsistente, información incompleta y algoritmo de ML que crea o amplifica el sesgo sobre los datos de entrenamiento.

Deshpande et al. (2021) mencionan cómo la resolución de las imágenes médicas es un factor que afecta el funcionamiento de los algoritmos y modelos de clasificación.

En conclusión, los retos presentados tienen directa relación con la calidad de las bases de datos para la generación de un modelo preciso y sin sesgos.

2.2.3. Metodología CRISP-DM: desarrollo de modelos de *Deep Learning*

Con respecto a la aplicación de la metodología CRISP-DM dentro del proceso de desarrollo de modelos de *Deep Learning*, se tiene a H. Sakly et al. (2022), quienes utilizaron la metodología para todo el proceso de creación de un modelo de clasificación, además destacan cómo la metodología es un insumo que permite asegurar la calidad de los datos con los cuales se entrena y prueba el modelo desarrollado, obteniendo resultados de exactitud que oscilan entre 62% y 88,72%.

Por otro lado, Zailan et al. (2022) proponen una comparativa de modelos de *Deep Learning* que les permite predecir un tumor cerebral al clasificar resonancias magnéticas en “maligno” o “benigno”. En la sección metodológica mencionan la aplicación de la metodología CRIPS-DM como base para el desarrollo y evaluación de los diferentes modelos, obteniendo

resultados de sensibilidad, especificidad, precisión, *recall*, *F1-Score* y exactitud que oscilan entre 62,07% a 97,87%.

Por último, A. Purbasari et al. (2021) plantean un modelo que pretende predecir el retraso del crecimiento en los bebés y niños pequeños, para esto utilizan la metodología CRISP-DM para asegurar la calidad de los datos que funcionaron como insumo de entrenamiento y prueba del modelo; obteniendo resultados oscilantes entre 51% y 91,9% tomando en cuenta todas métricas como lo son la exactitud, precisión, *recall* y *F1-Score*.

2.2.4. Comparación de modelos de redes convolucionales (CNN)

Primero, Yadav & Jadhav (2019) realizaron un experimento en el cual efectuaron una comparación de cuatro modelos: ORB y SVM, VGG16, INV3 y Caps Net, para la identificación de neumonía en los pulmones de una base estrecha de datos, llegando a la conclusión de que el ganador fue VGG16. Además, detallaron que aquellos modelos que utilizan métodos de CNN tienen un mejor desempeño que otros.

Ker et al. (2017) mencionan que las estructuras y modelos de CNN son utilizados la mayoría del tiempo para el análisis de imágenes médicas debido a su capacidad de preservar relaciones espaciales al filtrar las imágenes de entrada.

Huang et al. (2018) presentan la creación de un modelo de *Deep Learning* llamado *DenseNet*, con este obtienen métricas de evaluación similares a ResNet101, pero con la demanda computacional de ResNet50.

También, Sarwinda et al. (2020), en su estudio de la aplicación diferentes versiones de ResNet para la clasificación de cáncer colorrectal entre benigno y maligno, como conclusión, obtuvieron que ResNet50 es la variante con mejor porcentaje en exactitud, sensibilidad y especificada, con una configuración de 80% datos de entrenamiento y 20% datos de prueba.

Asimismo, Abd ElGhany et al. (2021) realizan la propuesta de un modelo de clasificación que permita el diagnóstico de siete diferentes tipos de cáncer de piel, resultando en un promedio de resultados de 98%, 98%, 97%, 98% y 100% en las medidas de evaluación exactitud, precisión, *recall*, sensibilidad y especificidad respectivamente. Estos promedios fueron comparados con otros modelos similares, específicamente InceptionV3 y VGG16, continuando ResNet50 siendo el mejor de los tres.

De igual modo, Deshpande et al. (2021) realizan una prueba de diferentes modelos de CNN: InceptionV3, AlexNet, GoogLeNet, VGG-16 y ResNet50, utilizando un sistema que permite la super resolución de las imágenes médicas para la clasificación de tumores cerebrales, obteniendo como resultado que al aplicar los sistemas de super resolución se obtiene una exactitud promedio de 91,1%, siendo ResNet50 el que mejor exactitud presenta con un 98,14%.

Por otro lado, Elpeltagy et al. (2021) propuso un modelo que pretendía ayudar a clasificar los casos de COVID-19, por medio TAC del pecho, al utilizar la arquitectura ResNet50 como base y agregando tres capas más de redes neuronales. Esto resultó en una exactitud del 97,7% que mejoró los resultados obtenidos con respecto a otros modelos como ResNet50 (original), ResNet101, GoogLetNet, AlexNet, DenseNet201, VGG16, VGG19, InceptionV3 y ResNet + SVM.

Por último, Rajguru et al. (2023) presentan un análisis comparativo para el diagnóstico temprano de cáncer de pulmón, por medio de la clasificación de TAC usando el modelo

ResNet50. Los autores resaltan su decisión de utilizar ResNet50 debido a su alta exactitud en la detección de cáncer de seno, detección de COVID-19, diagnóstico de enfermedades aviarias, entre otros. Además, los autores realizan una tabla comparativa donde agregan todos los métodos de clasificación que existen al momento de publicación para clasificar si hay algún tipo de cáncer de pulmón, estos tienen un promedio de exactitud de 87,88%; mientras que los modelos de ResNet50 tienen un promedio mayor a 90% en bases de datos medianas y entre 35% - 76% en bases de datos con mayor cantidad de imágenes médicas.

En conclusión, la arquitectura ResNet50 es sólida y robusta para las tareas de clasificación de varias imágenes médicas, al mismo tiempo que funciona como base para la invención de nuevas arquitecturas para problemas o situaciones específicas.

2.2.5. Métricas de evaluación de modelos

Primeramente, Liu et al. (2020) mencionan que para la evaluación de su modelo semisupervisado utilizaron las métricas: exactitud, sensibilidad y especificidad. Por otro lado, Wightman et al. (2021) utilizan la exactitud para medir el desempeño de los modelos de ResNet50 después de aplicar diferentes técnicas de entrenamiento.

También, Sarwinda et al. (2020), en su estudio de la aplicación diferentes versiones de ResNet para la clasificación de cáncer colorrectal entre benigno y maligno, utilizaron las métricas de exactitud, sensibilidad y especificidad para seleccionar la mejor variante.

Igualmente, Abd ElGhany et al. (2021) utilizan la precisión, *recall*, exactitud, sensibilidad y especificidad para evaluar el modelo de ResNet50 para el diagnóstico de siete diferentes tipos de cáncer de piel.

Por último, Deshpande et al. (2021) utilizan las métricas de exactitud, especificidad, sensibilidad y precisión para obtener el mejor modelo de CNN que permita clasificar tumores cerebrales.

En conclusión, las métricas de evaluación concurrentes son la exactitud, especificidad y sensibilidad para seleccionar el modelo óptimo.

2.2.6. Contribución del proyecto

2.2.6.1. Solución anterior


Golzan et al. (2024) proponen un modelo de ResNet50 modificado que permite la identificación y clasificación de seis secciones del cuerpo humano: CHE, ABD, PLV, CHA, CAP, ABP, por medio del análisis de TAC del cuerpo completo.

Con respecto al desarrollo del modelo se utilizaron un total de 5,485 imágenes provenientes de 45 bases de datos de diferentes centros médicos. Además, se utilizó la configuración de 60% de los datos para el entrenamiento, 20% de los datos para validación y 20% para pruebas.

En la **Figura n.º 25**, se adjunta la cantidad de datos utilizados de cada una de las bases de datos disponibles.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Figura n.º 26 Cantidad de datos utilizados, según base de datos



Nota: Adaptado de *Number of selected scans in each dataset*, de Golzan et al., 2024, *Automatic CT Scan Field of View (FOV) Detection Using Deep Learning*.

Con respecto a los resultados se realizaron cinco modelos diferentes para realizar la evaluación de las métricas de desempeño, los autores obtuvieron porcentajes de 97,36%, 97,2% y 97,2%, en exactitud, precisión y *recall* respectivamente en el modelo que mejores porcentajes obtuvo, siendo este ResNet50, de igual forma en la **Figura n.º 27** se adjunta un resumen de cada uno de los resultados obtenidos por cada uno de los modelos.

Figura n.º 27 Resultados de la evaluación de desempeño

Model	ACC (95% CI)	Precision (95% CI)	Recall (95% CI)	F1 (95% CI)
Vgg19	76.44 (73.92, 78.95)	76.6 (74.1, 79.1)	76.3 (73.7, 78.8)	75.7 (73.2, 78.2)
ViT16-224	89.80 (88.00, 91.59)	89.7 (87.9, 91.5)	89.6 (87.8, 91.4)	89.6 (87.8, 91.4)
MobileNetV3-Small	92.12 (90.52, 93.71)	92.3 (90.8, 93.9)	91.9 (90.3, 93.5)	91.8 (90.2, 93.4)
DenseNet121	95.60 (94.39, 96.81)	95.3 (94.1, 96.6)	95.3 (94.1, 96.6)	95.3 (94.1, 96.6)
ResNet50	97.30 (96.35, 98.26)	97.2 (96.2, 98.2)	97.2 (96.2, 98.2)	97.2 (96.2, 98.1)

Nota: Adaptado de *Comparison of different models' performance on Test dataset*, de Golzan et al., 2024, *Automatic CT Scan Field of View (FOV) Detection Using Deep Learning*.

2.2.6.2. Mejoras con respecto a los proyectos anteriores

El presente proyecto tiene como finalidad mejorar el modelo planteado por Golzan et al. (2024) al entrenar y probarlo con nuevos datos y así identificar patrones de error para lograr configurarlo para que sea sensible a diferentes características que por el momento no logra descifrar, como lo son las áreas transicionales en medio de las diferentes regiones. Además, se procede a desarrollar una herramienta gráfica que permita al personal médico utilizar el modelo desarrollado para obtener las clasificaciones de sus imágenes médicas de manera automatizada.

3. Marco Metodológico

Como introducción, Sampieri et al. (2014) definen la investigación como “un conjunto de procesos sistemáticos, críticos y empíricos que se aplican al estudio de un fenómeno o problema” (p. 4).

3.1. Tipo de investigación

En este apartado se describe brevemente los dos tipos de investigación definidos por Baena Paz (2017) para terminar mencionando el seleccionado para esta investigación y su respectiva razón.

Baena Paz (2017) define a la investigación pura o teórica como “el estudio de un problema, destinado a la búsqueda de conocimiento..., en términos abstractos y desarrollando principios generales” (p. 17).

Por otro lado, Baena Paz (2017) define a la investigación aplicada o práctica como “el planteamiento de problemas concretos que requieren soluciones inmediatas y específicas” (pp.17-18).

Por lo expuesto en las definiciones y tomando en cuenta las características del proyecto, se decide realizar una investigación de **tipo aplicada o práctica**, ya que se estará desarrollando y entregando un producto que tiene como objetivo atacar el problema identificado de manera concreta y específica.

3.2. Enfoque y diseño de la investigación

En este apartado se describe brevemente cada uno de los enfoques y diseños de investigación definidos por Sampieri et al. (2014) en el libro Metodología de la Investigación, para terminar, mencionando los seleccionados para esta investigación y su respectiva razón. En primer lugar, se define cada enfoque mencionado por Sampieri et al. (2014), siendo estos:

- **Enfoque cuantitativo:** Se fundamenta en el método hipotético deductivo. Establece teorías y preguntas iniciales de investigación, de las cuales se derivan hipótesis. Estas se someten a prueba utilizando diseños de investigación apropiados. Mide las variables en un contexto determinado, analiza las mediciones, y establece conclusiones. Si los resultados corroboran las hipótesis, se genera confianza en la teoría, si no es refutada y se descarta para buscar mejores. Reduccionista. Utiliza medición numérica, conteo, y estadística, encuestas, experimentación, patrones, recolección de datos.
- **Enfoque cualitativo:** Parte de un esquema inductivo. Expansivo. se utiliza para descubrir y refinar preguntas de investigación. Se basa en descripciones y observaciones. Parte de la premisa de toda cultura o sistema social para entender cosas y eventos. Su propósito es reconstruir la realidad, tal como la observan los investigadores. Se llama holístico, porque considera el todo, sin reducirlo a sus partes. Es individual. Método de análisis interpretativo, contextual y etnográfico.
- **Enfoque mixto:** Representa un conjunto de procesos sistemáticos, empíricos y críticos de investigación e implica la recolección y el análisis de datos cuantitativos y cualitativos, así como su integración y discusión conjunta, para realizar inferencias

producto de toda la información recabada (meta inferencias) y lograr un mayor entendimiento del fenómeno bajo estudio.

Después de analizar cada uno de los enfoques se llegó a la conclusión de que el tipo que se adapta a las características de la investigación es el **cuantitativo**, ya que el proyecto pretende obtener resultados específicos y números como lo son los resultados de la evaluación del modelo de *Deep Learning*, permitiendo tomar una posición objetiva dentro del proyecto, al mismo tiempo que se realiza un análisis numérico para la identificación de características y elementos relevantes dentro de las fases de entrenamiento o prueba planteados.

Por otro lado, Sampieri et al. (2014) definen dos diseños diferentes relacionados con el enfoque cuantitativo:

- **Experimentales:** Un estudio en el que se manipulan intencionalmente una o más variables independientes (supuestas causas antecedentes), para analizar las consecuencias que la manipulación tiene sobre una o más variables dependientes (supuestos efectos consecuentes), dentro de una situación de control para el investigador. Además, presentan los siguientes subtipos:
 - **Preexperimental:** Diseño de un solo grupo cuyo grado de control es mínimo. Generalmente es útil como un primer acercamiento al problema de investigación en la realidad.
 - **Experimentos puros:** Son aquellos que incluyen los grupos de comparación (manipulación de la variable independiente) y la equivalencia de los grupos para el control y validez interna.
 - **Diseño factorial:** Manipulan dos o más variables independientes e incluyen dos o más niveles o modalidades de presencia en cada una de las variables independientes. Se utilizan muy a menudo en la investigación experimental.
- **No experimentales:** Se trata de estudios en los que no se hace variar en forma intencional las variables independientes para ver su efecto sobre otras variables. Se observa los fenómenos en su estado natural. Además, se divide en dos subtipos:
 - **Longitudinales o evolutivos:** Recolectan datos en diferentes momentos o periodos para hacer inferencias respecto al cambio, sus determinantes y consecuencias. Tales puntos o periodos generalmente se especifican de antemano. Algunos ejemplos son: diseños de tendencia, análisis evolutivo de grupos o panel.
 - **Transeccionales o transversales:** Su propósito es describir variables y analizar su incidencia e interrelación en un momento dado. Algunos ejemplos son: Exploratorios, descriptivos o correlacionales-causales.

Por último, se decide seguir el tipo de diseño llamado **experimental “puro”- factorial** debido que se menciona que pretende “jugar” con los valores de las variables independientes para obtener diferentes resultados y analizarlos. En el caso del presente proyecto, se tiene planteado el análisis y evaluación del modelo y sus características planteadas para seleccionar el modelo óptimo según los resultados numéricos de las variables de desempeño.

3.3. Fuentes de datos de información

Esta sección recopila todas las fuentes de información preliminares que servirán de base para el desarrollo del proyecto. Incluye tanto fuentes primarias como secundarias, cada una acompañada de la relevancia dentro de la elaboración del proyecto.

3.3.1. Fuentes primarias

La Healey (2024) define a las fuentes primarias como “documentos u objetos que proporcionan información original o no interpretada, que son resultados de la observación, la experiencia, la encuesta o la experimentación” (párr. 1).

En la **Tabla n.º 2**, se enlista cada una de las fuentes primarias seleccionadas junto con su relevancia dentro del proyecto.

Tabla n.º 2. Fuentes primarias

Título de fuente	Referencia de la fuente	Relevancia para la investigación
<i>Maintaining and Operating a Public Information Repository.</i>	Clark et al. (2013).	Esta es la fuente primaria de datos, en ella, se encuentran miles de imágenes médicas; entre ellas los TAC que serán manipulados dentro del proyecto.
<i>TCIA Programmatic Interface REST API guides.</i>	The Cancer Imaging Archive (s.f.).	Esta fuente será utilizada para conocer sobre las diferentes utilidades y funciones relacionadas con el API de acceso a datos e información ofrecida por el <i>Cancer Imaging Archive</i> .
<i>Standardized Quantitative Radiomics for High-Throughput Image-based Phenotyping.</i>	Zwanenburg et al. (2020).	Este documento se utilizará como insumo para conocer sobre términos y definiciones estandarizadas con respecto a las imágenes médicas y sus características.
<i>Annotated Data for AI/ML.</i>	The Cancer Imaging Archive (s.f.).	Este documento proporciona información y consideraciones para utilizar los datos de las diferentes colecciones en aplicaciones de Inteligencia Artificial y <i>Machine Learning</i> .

Nota: Elaboración propia (2024).

3.3.2. Fuentes secundarias

Vogt & Johnson (2016) definen a las fuentes secundarias como "obras que interpretan o analizan información originada en otra fuente" (p. 134), como libros de texto, artículos de revisión, informes de investigación y bases de datos bibliográficas.

En la **Tabla n.º 3**, se enlista cada una de las fuentes secundarias seleccionadas junto con su relevancia dentro del proyecto.

Tabla n.º 3. Fuentes secundarias

Título de la referencia	Referencia de la fuente	Importancia del documento para la investigación
<i>Mitigating Bias in Radiology Machine Learning: 1. Data Handling.</i>	Rouzrokh et al. (2022).	Este documento servirá como una fuente de información y guía para comprender y manejar adecuadamente los datos obtenidos de la fuente primaria.
<i>Mitigating Bias in Radiology Machine Learning: 2. Model Development.</i>	Zhang et al. (2022).	Este documento proporcionará información clave sobre cómo desarrollar modelos de <i>Machine Learning</i> de manera imparcial, evitando sesgos en los resultados de rendimiento.
<i>Mitigating Bias in Radiology Machine Learning: 3. Performance Metrics.</i>	Faghani et al. (2022).	Este documento ofrecerá fundamentos y pautas sobre cómo gestionar y obtener métricas de evaluación de modelos de manera imparcial.
<i>Deep Learning Applications in Medical Image Analysis.</i>	Ker et al. (2018).	Este estudio pretende introducir temas de implementación de <i>Deep Learning</i> en el sector salud y cómo aplicarlo para obtener diferentes datos de las imágenes médicas analizadas.
<i>Deep Learning in Medical Image Analysis. Annual review of biomedical engineering.</i>	Shen et al. (2017).	Este estudio impone situaciones de importancia para evitar resultados de métricas dentro de los modelos y algoritmos de <i>Machine Learning</i> que se aplican para el análisis de imágenes médicas.
<i>Machine Learning for Medical Imaging.</i>	Erickson et al. (2017).	Este estudio pretende exponer consideraciones de cómo preprocesar la data ante el desarrollo y alimentación de un modelo de redes neuronales convolucionales.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Título de la referencia	Referencia de la fuente	Importancia del documento para la investigación
<i>Noise Reduction in Medical Images.</i>	Florez-Aroni et al. (2023).	Este artículo proporciona información de cómo reducir el ruido en las imágenes médicas para su posterior análisis.
<i>CT Noise-Reduction Methods for Lower-Dose Scanning: Strengths and Weaknesses of Iterative Reconstruction Algorithms and New Techniques.</i>	Mohammadinejad et al. (2021).	Este artículo abordará la identificación de diversas características relevantes en imágenes de tomografía axial computarizada (TAC) mediante el uso de modelos de <i>Deep Learning</i> .
<i>A review on CT image noise and its denoising.</i>	Diwakar et al. (2018).	Este artículo se centra en el tema del ruido en las imágenes de tomografía axial computarizada (TAC) y explora métodos para su reducción.
<i>Generative Adversarial Networks for Noise Reduction in Low-Dose CT.</i>	Wolterink et al. (2017).	Este artículo provee con un método concreto de cómo reducir el ruido en los TAC de dosis baja.
<i>Deep Residual Learning for Image Recognition.</i>	He et al. (2015).	Este artículo realiza una introducción a la estructura y características de ResNet, un subtipo de red neuronal convolucional junto con sus diferentes profundidades 50, 52, 100. Esto permite a la estudiante obtener más información sobre su funcionalidad y porcentaje de certeza a la hora de clasificar imágenes.
<i>Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer.</i>	Sarwinda et al. (2021).	Este artículo presenta un caso específico de clasificación de imágenes médicas con la red convolucional de tipo ResNet50 para conocer los resultados en métricas de rendimiento.

Nota: Elaboración propia (2024).

3.4. Sujetos de investigación

De acuerdo con Leedy & Ormrod (2015), “los sujetos de investigación son los individuos o elementos que son observados, medidos o manipulados en un estudio de investigación” (p. 123) Algunos ejemplos de estos son: Personas, animales, plantas, instituciones u otros elementos.

En la **Tabla n.º 4**, se detallan cada uno de los sujetos de investigación asociados al proyecto junto con su respectiva descripción y criterio de selección.

Tabla n.º 4. *Sujetos de investigación*

Sujeto de investigación	Descripción	Justificación de importancia
Imagen médica: Tomografías Axiales Computarizadas (TAC)	“Procedimiento para el que se usa una computadora conectada a una máquina de rayos X a fin de crear una serie de imágenes detalladas del interior del cuerpo. Las imágenes se toman desde diferentes ángulos y se usan para crear vistas tridimensionales (3D) de los tejidos y órganos. A veces se inyecta un tinte en una vena o se ingiere de modo que estos tejidos y órganos se destaquen de forma más clara” (Diccionario de Cáncer del NCI, s. f., párr. 1)	Son las imágenes médicas que constituirán el foco de la investigación, serán analizadas, caracterizadas, clasificadas e interpretadas.
Modelo de Deep Learning	Según Holdsworth y Scapicchio (2024), los modelos de <i>Deep Learning</i> son programas pertenecientes a un “subconjunto del <i>Machine Learning</i> que utiliza redes neuronales multicapa, llamadas redes neuronales profundas, para simular el complejo poder de toma de decisiones del cerebro humano” (párr. 5).	Son los métodos de análisis de las imágenes médicas que serán diseñados, desarrollados y evaluados para seleccionar el óptimo.
Usuarios expertos	De acuerdo con lo comentado por la empresa LinkedIn (2023) en su artículo llamado <i>What are the key differences between expert and novice users in interface usability testing?</i> , se considera un usuario experto “aquellas personas que tienen un alto nivel de familiaridad, conocimiento y habilidad con una interfaz o dominio específico” (párr. 1)	Son aquellas personas que estarán encargadas de realizar pruebas en la herramienta, así como de dar el visto bueno al modelo de <i>Deep Learning</i> integrado en esta.

Nota: Elaboración propia (2024).

3.5. Variables o categorías de la investigación

Fraenkel & Wallen (2006) definen las variables de investigación como “una propiedad o característica que puede asumir diferentes valores y que puede ser medida o manipulada en un estudio de investigación” (p. 32) y son fundamentales para el planteamiento de la hipótesis, el diseño de estudio y por último el análisis de los datos.

En la **Tabla n.º 5**, se proporciona las variables de investigación identificadas junto con su relevancia dentro del proyecto.

Tabla n.º 5. Variables de investigación

Objetivo	Nombre de la variable	Importancia
Seleccionar los datos correctos dentro de las bases de datos, para la prueba y entrenamiento del modelo de <i>Deep Learning</i> , por medio de la limpieza y clasificación de los registros.	Datos de entrenamiento y prueba.	Esta variable es considerada uno de los puntos de partida del proyecto, ya que, los modelos de <i>Deep Learning</i> son entrenados por diferentes fuentes de información para abarcar todos los diferentes tipos de imágenes médicas. Por ello, escoger los datos o bases de datos correctas es relevante para obtener las métricas de rendimiento esperadas.
	Datos preprocesados.	Esta variable es la entrada del modelo de clasificación; por lo que su análisis y preprocesamiento son relevantes para optimizar su el desempeño.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Objetivo	Nombre de la variable	Importancia
Desarrollar un modelo de Deep Learning que mejore el estado del arte, con el fin de definir el modelo óptimo.	Modelo de Deep Learning.	Esta variable es el foco central del proyecto. Mediante ella se desarrolla la herramienta de escritorio; así mismo, se requiere mejorar con respecto al estado del arte.
	Definición del modelo óptimo.	Es el modelo óptimo en términos de medidas de rendimiento y características, permite tener una lista de cualidades por seguir para mejorar el modelo del estado del arte.
Evaluar el modelo de Deep Learning para la selección del modelo óptimo en términos de precisión, eficiencia y desempeño.	Evaluación del modelo.	Es la recopilación de los resultados de las estadísticas del modelo, esto permite seleccionar el modelo que se adapte a las necesidades.
	Comparación con el estado del arte.	Con esta variable se pretende conocer las características del estado del arte que son utilizadas para la justificación de la selección del modelo óptimo.
Implementar una herramienta de escritorio (beta) integrando el modelo de Deep Learning seleccionado, que sea accesible y útil al personal médico, para la agilización del proceso de análisis e interpretación de los TAC.	Experiencia de usuario.	Esta variable permite obtener una idea de qué tan funcional y entendible es la herramienta seleccionada. Esto nos permite asegurar la calidad y utilidad de la herramienta para los diferentes usuarios.
	Impacto en la agilización de la clasificación de los TAC.	Esta variable permite obtener una idea cuantitativa del impacto real de la herramienta en el proceso de análisis e interpretación de los TAC por medio de la clasificación de estos.

Nota: Elaboración propia (2024).

3.6. Técnicas e instrumentos de recolección de datos

En esta sección, se realizará la definición de cada uno de los instrumentos de investigación que serán aplicados a lo largo del proceso de investigación.

3.6.1. Revisión documental

De acuerdo con Hernández Sampieri, et al., (2014), la revisión documental consiste en “detectar, consultar y obtener la bibliografía y otros materiales útiles para los propósitos del estudio, de los cuales se extrae y recopila información relevante y necesaria para el problema de investigación” (p.61).

3.6.2. Tabla de registro

Siguiendo con lo mencionado por Guzmán Arias (2015) donde define a la tabla de registro como “un instrumento por el cual se consignan una serie de aspectos, al mismo tiempo que se anotan los datos que generan en el campo y que son de primera línea para realizar cálculos en forma acumulativa en diferentes muestreos” (diapositiva 30).

3.6.3. Encuesta

Según lo expuesto por Narváez (2007) una encuesta “es un método utilizado para recabar información entre la población. Íntimamente relacionado con el enfoque cuantitativo, se utiliza para obtener datos en gran escala de una población determinada” (párr. 1).

3.6.4. Diseños experimentales

Con base en Guzmán Arias (2015) se comprende el diseño experimental como “un plan o estrategia concebidos para obtener información que se desea, el investigador analiza la certeza de la hipótesis” (diapositiva 32).

3.6.5. Instrumentos mecánicos o electrónicos

Basándose en lo expuesto por Guzmán Arias (2015) los instrumentos mecánicos o electrónicos son “sistemas de medición como por ejemplo un polígrafo, pistola láser, instrumentos de actividad cerebral, entre otros” (diapositiva 36).

3.6.6. Matriz de cobertura de las variables

En la **Tabla n.º 6.** Matriz de cobertura de las variables., se presenta una matriz que empareja los instrumentos de la investigación explicados anteriormente, con su respectiva variable con el objetivo de verificar la cobertura de estas.

Tabla n.º 6. Matriz de cobertura de las variables.

Variable	Revisión documental	Tabla de registro	Diseños experimentales	Instrumentos mecánicos o electrónicos	Encuestas
Datos de entrenamiento y prueba.	X				
Datos preprocesados.	X		X		
Modelo de Deep Learning.			X		
Definición del modelo óptimo.	X	X			
Evaluación del modelo.		X	X		
Comparación con el estado del arte.		X			
Experiencia de usuario.			X	X	X
Impacto en la agilización de la clasificación de los TAC.		X			X


Nota: Elaboración propia (2024).

3.7. Procedimiento metodológico de la investigación

En este apartado, se realizará la definición de las diferentes fases que poseerá la investigación en curso; esto con el fin de obtener un mayor conocimiento de qué se espera obtener de cada una de las fases estipuladas.

Además, en la **Figura n.º 28** se muestra un resumen de las fases definidas para el proceso metodológico y cómo estas se comportan dentro del proyecto.

Figura n.º 28 Procedimiento metodológico de investigación



Nota: Elaboración propia (2024).

3.7.1. Fase 1 – Entendimiento del negocio

La primera fase está relacionada con la comprensión del modelo predecesor, en términos de tipo de modelo utilizado, estructura del modelo, fuente de datos, funcionalidad, entre otros; así como la asignación de las imágenes médicas por utilizar para realizar pruebas de funcionalidad del modelo. Esto como el primer paso para realizar una mejora sobre el modelo base asignado.

3.7.1.1. Comprensión de las necesidades

Durante esta etapa se tiene una reunión con el profesor supervisor donde se discute la naturaleza del proyecto y las expectativas que se tienen, respecto a los trabajos que se realizan en el laboratorio. Además, el presente proyecto parte de un modelo de *Deep Learning* anteriormente desarrollado por otros estudiantes del laboratorio, por lo que este será el modelo por mejorar y modificar.

3.7.1.2. Comprensión del flujo de trabajo

Se realiza una revisión de los recursos disponibles dentro del laboratorio; así como se consulta a los compañeros del laboratorio cómo funciona el flujo de trabajo dentro del laboratorio y consideraciones generales.

3.7.1.3. Comprensión de la estructura del modelo base

Se consulta con el dueño del modelo base sobre la definición de las características de este y su respectiva funcionalidad. Además, se realiza una indagación de cómo funcionan las fases de prueba y entrenamiento dentro del contexto.

3.7.1.4. Selección de la base de datos de trabajo

Se navega en el repositorio de bases de datos del laboratorio para seleccionar la base de datos idónea para realizar las pruebas del modelo base.

Al terminar esta fase se tiene aprendida la lógica de trabajo dentro del laboratorio en caso de necesitar ayuda, estipulados los requerimientos del proyecto, comprendida la lógica del modelo base y seleccionada la base de datos de trabajo.

3.7.2. Fase 2 – Compresión y preprocesamiento de datos

La segunda fase responde directamente el primer objetivo específico, en esta se realiza un análisis, limpieza, transformación y preparación de una cierta cantidad de imágenes médicas para realizar su posterior prueba dentro del modelo. Dentro de las actividades de esta fase, se tiene:

3.7.2.1. Etiquetado manual de la imagen médica

Se realiza un análisis manual donde se revisa una a una las imágenes médicas y se descifra cuál de las seis regiones se muestra: CHE (sólo pecho), ABD (sólo abdomen), PLV (sólo pelvis), CHA (pecho-abdomen), ABP (abdomen-pelvis) o CAP (pecho-abdomen-pelvis). Después, se agrega su región en un documento de registro.

3.7.2.2. Preprocesamiento de las imágenes médicas

Una vez se tienen las imágenes debidamente etiquetadas, se procede a validar que las imágenes médicas existan, estén completas, entre otros aspectos. Además, se ejecutan procesos de cortado y depuración de registros vacíos.

3.7.2.3. Resaltado de inconsistencias

Se resaltan en un documento de Excel⁶ todas aquellas imágenes médicas que no fueron etiquetadas de manera satisfactoria por el modelo debido a su calidad, esto con la finalidad de identificar un posible patrón de error y asegurar un conjunto de datos de entrada depurado.

Con la finalización de esta fase, se obtiene el conjunto de datos que se utilizará para realizar las pruebas de funcionalidad del modelo y así lograr obtener las diferentes métricas de desempeño de este.

⁶ [Kaiser CT FOV Labels](#)

3.7.3. Fase 3 – Modelaje

La tercera fase responde al segundo y tercer objetivo específico, enfocándose en el análisis del modelo de *Deep Learning* y la gestión de su modificación o reentrenamiento de ser posible y necesario.

3.7.3.1. Selección del conjunto de datos para pruebas

En esta actividad se define la cantidad de TAC etiquetados de la fase 2 que son utilizados para cada prueba del modelo.

3.7.3.2. Definición del ambiente de pruebas

Una vez definidos los conjuntos de datos de prueba, se procede a definir el ambiente de pruebas, en términos de cantidad de pruebas, equipo de cómputo utilizado, porcentajes de distribución: entrenamiento, prueba y validación, *software* por utilizar, entre otros.

3.7.3.3. Ejecución de pruebas

Se toma los conjuntos de datos de la actividad 3.7.3.1 y se realiza las pruebas del modelo. Después de cada prueba se analizan los resultados para saber si es necesario clasificar otras imágenes de la fuente de datos y para identificar posibles patrones de errores.

3.7.3.4. Registro de las métricas de evaluación

Posterior a la ejecución de las pruebas, se registran las métricas de evaluación obtenidas en cada una de estas para analizar la posibilidad de modificar el modelo o ejecutar un proceso de entrenamiento.

3.7.3.5. Modificación y entrenamiento del modelo

Durante esta actividad se toma el modelo base y se modifican algunas de las configuraciones; así como, se agrega mayor sensibilidad a diferentes características de las imágenes médicas que fueron erróneamente clasificadas; por ejemplo: clasifica como “incompletas” imágenes médicas que tienen una esquina blanca. Posteriormente, se procede con el entrenamiento del modelo, donde se alimenta con aquellas imágenes médicas que fueron erróneamente clasificadas, para que este sea capaz de clasificarlas de manera correcta.

Con la finalización de esta fase, se tiene la base del modelo que es utilizado dentro de la herramienta para realizar la debida clasificación.

3.7.4. Fase 4 – Integración

La cuarta fase se relaciona directamente con al tercer y cuarto objetivos. Su enfoque está en la preparación del modelo a su versión estable y funcional para realizar la posterior integración con la herramienta de escritorio. Dentro de las principales actividades de la fase se tiene:

3.7.4.1. Preparación del modelo y aplicación para integrarlo a la herramienta

Durante esta actividad, se define el método utilizado para integrar la herramienta con el modelo seleccionado en la Fase 3. Además, se toma en cuenta la arquitectura planteada por Pavadaisamy (2024), en su proyecto de “Una herramienta de escritorio para identificar las fases en una imagen de TAC abdominal con contraste”.

3.7.4.2. Integración modelo-herramienta

Esta actividad está centrada en asegurar la calidad del modelo presentado, por lo que si se obtiene un modelo con mejores métricas de evaluación se realiza la debida actualización de este dentro de la herramienta; así como, al presentarse problemas o consideraciones con la herramienta se realiza su respectiva actualización para mejorar la experiencia de usuario.

3.7.5. Fase 5 – Despliegue

La quinta fase se relaciona directamente con el cuarto objetivo. Su enfoque está en el desarrollo de la herramienta de escritorio que permita al personal médico cargar sus imágenes y obtener su respectiva clasificación como resultado. Dentro de las principales actividades de la fase se tiene:

3.7.5.1. Diseño de la interfaz gráfica

Durante esta actividad, se realiza un bosquejo de cómo se deberían ver las diferentes interfaces gráficas estéticamente; así como, la navegación dentro de la herramienta, por ejemplo: cómo se va de la página principal a la página para la clasificación de las imágenes médicas.

3.7.5.2. Diseño de la arquitectura

Durante esta actividad, se establece cuáles son las capas y tecnologías que conforman la aplicación desde el *back-end* con todas las funcionalidades, incluyendo la comunicación con el modelo de *Deep Learning*, hasta las diferentes vistas que tendrá la herramienta en el *front-end*.

3.7.5.3. Desarrollo de la herramienta

Una vez se tenga la información de la actividad 3.7.5.1 y 3.7.5.2, se procede a escribir el código de la aplicación para ir integrando cada una de las capas con su respectiva funcionalidad.

3.7.5.4. Pruebas de funcionalidad

Al finalizar la actividad 3.7.5.3, se procede a realizar las pruebas de funcionalidad de tipo caja negra en la aplicación, con el objetivo de validar la calidad y eficacia de la herramienta desarrollada.

3.7.5.5. Paso a producción

Al terminar las pruebas de funcionalidad, la herramienta es presentada al supervisor del proyecto y se espera por su aprobación para realizar su debida puesta en producción.

Por último, es importante mencionar que las Fases 2, 3 y 4 serán repetidas las veces que sea necesario hasta mejorar el estado del arte del modelo de *Deep Learning* - en términos de sus métricas de desempeño- o por falta de tiempo dentro del proyecto.

3.8. Operacionalización de las variables o categorías.

En esta sección, se realiza encuentra la **Tabla n.º 7**, la cual, resume la operacionalización de las variables anteriormente definidas, donde se pueden ver temas de fase de investigación, objetivo al que responde, instrumentos utilizados, variables y sujetos de la investigación involucrados.

Tabla n.º 7. Operacionalización de las variables.

Fase de la investigación	Objetivo específico	Variable de investigación	Conceptualización	Instrumento(s) de investigación	Indicador	Sujeto(s) de investigación
Fase 1 – Entendimiento del negocio.	Seleccionar los datos correctos dentro de las bases de datos, para la prueba y entrenamiento o del modelo de <i>Deep Learning</i> , por medio de la limpieza y clasificación de los registros.	Datos de entrenamiento y prueba.	Conjunto o base de datos con tomografías axiales computarizadas que presentan el área que comprende el pecho-abdomen-pelvis.	Revisión documental.	- Selección de base de datos que presenten las partes del cuerpo necesarias y que no hayan sido usadas para entrenar el modelo. - Selección del formato correcto de las imágenes médicas en las bases de datos.	- Imágenes médicas. - Usuarios expertos.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Fase de la investigación	Objetivo específico	Variable de investigación	Conceptualización	Instrumento(s) de investigación	Indicador	Sujeto(s) de investigación
Fase 2 – Compresión y preprocesamiento de datos.	Seleccionar los datos correctos dentro de las bases de datos, para la prueba y entrenamiento del modelo de <i>Deep Learning</i> , por medio de la limpieza y clasificación de los registros.	Datos preprocesados.	Conjunto de datos que han sido modificados, validados, limpiados y transformados para ser fuente de entrenamiento y prueba para los modelos de <i>Deep Learning</i> .	• Diseño experimental. • Revisión documental.	• Registro de las diferentes imágenes médicas con su respectiva etiqueta según la parte del cuerpo resaltada. • Cantidad de imágenes médicas etiquetadas.	Imágenes médicas.
Fase 3 – Modelaje.	Desarrollar un modelo de <i>Deep Learning</i> que mejore el estado del arte, con el fin de definir el modelo óptimo.	Modelo de <i>Deep Learning</i> .	Método de programación que permiten simular el comportamiento humano, específicamente para clasificar imágenes por medio del aprendizaje supervisado.	• Diseño experimental.	• Código de programación del modelo. • Explicación de las características de la estructura del modelo.	• Modelo de <i>Deep Learning</i>. • Usuarios expertos.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Fase de la investigación	Objetivo específico	Variable de investigación	Conceptualización	Instrumento(s) de investigación	Indicador	Sujeto(s) de investigación
		Definición del modelo óptimo • Estado del arte.	Conjunto de características de desempeño del modelo de <i>Deep Learning</i> , según el estado del arte.	- Revisión documental. - Tabla de registro.	Cuadro donde se presente una comparación entre los valores obtenidos por el estado del arte y las pruebas realizadas.	Modelo de <i>Deep Learning</i> .
	Evaluar el modelo de <i>Deep Learning</i> para la selección del modelo óptimo en términos de precisión, eficiencia y desempeño.	Evaluación del modelo.	Conjunto de métricas que demuestran el desempeño general de del modelo, con respecto a la clasificación de imágenes médicas.	Diseño experimental.	- Porcentaje de precisión. - Porcentaje de eficiencia. - Porcentaje de desempeño. - Cantidad de clasificaciones erróneas.	Modelo de <i>Deep Learning</i> .
		Comparación con el estado del arte.	Evaluación de las métricas obtenidas con respecto al estado del arte.	Tabla de registro.	Cuadro comparativo de las métricas de evaluación del modelo versus el estado del arte.	Modelo de <i>Deep Learning</i> .

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Fase de la investigación	Objetivo específico	Variable de investigación	Conceptualización	Instrumento(s) de investigación	Indicador	Sujeto(s) de investigación
Fase 4 – Integración y Fase 5 – Despliegue.	Implementar una herramienta de escritorio (beta) integrando el modelo de <i>Deep Learning</i> seleccionado, que sea accesible y útil al personal médico, para la agilización del proceso de análisis e interpretación de los TAC.	Experiencia de usuario.	Facilidad con la que el usuario interactúa con la herramienta, en términos de navegación, facilidad de uso y correcta funcionalidad.	Diseño experimental.	- Nivel de satisfacción de los usuarios. - Nivel de usabilidad de la herramienta.	Usuarios expertos.
		Impacto en la agilización de la clasificación de los TAC.	Se refiere al tiempo de ejecución y espera que presente la herramienta para realizar la clasificación de N imágenes médicas.	- Tabla de registro. - Instrumentos electrónicos o mecánicos.	- Tiempo de ejecución de una imagen en N cantidad de registros. - Tiempo de respuesta de la herramienta.	No se aplican instrumentos a sujetos.

Nota: Elaboración propia (2024).

3.9. Tabla resumen del procedimiento metodológico de la Investigación

En la **Tabla n.º 8**, se presenta un resumen de cobertura de los objetivos específicos en las diferentes secciones del documento.

Tabla n.º 8. *Tabla de resumen del proceso metodológico*

Objetivo específico	Marco conceptual	Marco metodológico	Análisis resultados	Propuesta solución	Conclusiones
OBJ. 1: Seleccionar los datos correctos dentro de las bases de datos, para la prueba y entrenamiento del modelo de <i>Deep Learning</i> , por medio de la limpieza y clasificación de los registros.	Sección 2.1.1.2, 2.1.1.3 y 2.1.1.4.	Sección 3.7.1 y 3.7.2.	Sección 4.1. Fase 1 – Entendimiento del negocio y Fase 2 - Comprensión y preprocesamiento de datos	No tiene.	Sección Objetivo específico
OBJ. 2: Desarrollar un modelo de <i>Deep Learning</i> que mejore el estado del arte, con el fin de definir el modelo óptimo.	Sección 2.1.2.	Sección 3.7.3.	Sección Fase 3 – Modelaje	No tiene.	Sección Objetivo específico
OBJ. 3: Evaluar el modelo de <i>Deep Learning</i> para la selección del modelo óptimo en términos de precisión, eficiencia y desempeño.	Sección 2.1.2.2.	Sección 3.7.3.	Sección Fase 3 – Modelaje	No tiene.	Sección Objetivo específico

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Objetivo específico	Marco conceptual	Marco metodológico	Análisis resultados	Propuesta solución	Conclusiones
OBJ. 4: Implementar una herramienta de escritorio (beta) integrando el modelo de <i>Deep Learning</i> seleccionado, que sea accesible y útil al personal médico, para la agilización del proceso de análisis e interpretación de los TAC.	Sección 2.1.3.	Sección 3.7.4 y 3.7.5.	No tiene.	Sección Fase 4 – Integración y 5.2. Fase 5 – Despliegue	Sección Objetivo específico

Nota: Elaboración propia (2024).

4. Análisis de Resultados

En este apartado se exponen los resultados obtenidos en las primeras tres fases definidas en la **Sección 3.7**, referente al procedimiento metodológico. Estos resultados provienen de la aplicación de los instrumentos revisión documental, tablas de registro y diseños experimentales planteados en la **Sección** ;Error! No se encuentra el origen de la referencia..

4.1. Fase 1 – Entendimiento del negocio

Esta fase se centra en el descubrimiento del entorno de trabajo dentro del laboratorio y cómo este funciona para el desarrollo de los diferentes proyectos, además se realiza un recorrido por el flujo de trabajo por seguir, según las buenas prácticas de la institución, fungiendo como base de información para el primer objetivo específico. Debido a esto se realizó una revisión documental dentro de los recursos disponibles en el laboratorio, los resultados completos obtenidos de la aplicación de este instrumento son detallados en cada una de las subtarefas de la fase siguiendo la plantilla adjuntada en **Apéndice J. Plantilla de revisión documental**.

4.1.1. Comprensión de las necesidades

Con respecto a esta actividad, se realizó una reunión con el profesor supervisor del laboratorio, en la cual se discutió sobre el alcance y requerimientos que deben cumplirse dentro del proyecto.

En la **Tabla n.º 9**, se presenta un resumen de lo solicitado por el supervisor según lo mencionado en la Apéndice F. Minuta 1 – Recolección de requerimientos.

Tabla n.º 9. *Requerimientos del proyecto*

Requerimiento	Descripción
Análisis del modelo base.	Este requerimiento se refiere a la lectura y comprensión del modelo creado por Golzan et. al (2024), obteniendo información de su funcionamiento, entrenamiento y prueba.
Etiquetado manual de imágenes médicas.	Con respecto a este requerimiento, se refiere a la visualización de cada una de las imágenes médicas y su posterior etiquetado para realizar las pruebas del modelo base.
Depuración y preprocesamiento del dataset.	Este requerimiento está relacionado con todas las actividades referentes al preprocesamiento de las imágenes médicas, como lo son: corte, reubicación, modificación, entre otros.
Pruebas al modelo base.	Se refiere a la aplicación de pruebas al modelo base con imágenes que este nunca ha visto, para asegurarse de que los resultados de las métricas de desempeño son iguales o mejores que las obtenidas en sus primeras pruebas (estado del arte).

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Requerimiento	Descripción
Desarrollo del <i>front-end</i> de la herramienta.	Se refiere a la creación de una aplicación de escritorio que permita a los usuarios utilizar el modelo de clasificación por medio de la selección de un archivo zip con imágenes médicas para clasificar.
Integración modelo-frontend.	Está relacionado con la creación de “puente” de comunicación entre el modelo y la aplicación de escritorio desarrollada.

Nota: Elaboración propia (2024).


En conclusión, se necesita crear una herramienta que permita a los usuarios seleccionar un archivo zip con un grupo de imágenes médicas, específicamente de TAC, y que estas sean clasificadas por el modelo de *Deep Learning*, obteniendo un zip con las imágenes clasificadas según su categoría, así como se visualiza la exactitud de los resultados.

4.1.2. Comprensión del flujo de trabajo

En lo que respecta al flujo de trabajo, se realiza una revisión documental de diferentes proyectos pasados, así como se realiza una observación de cómo otros compañeros dentro del laboratorio manejan sus actividades, con la finalidad de comprender y establecer un flujo de trabajo para la elaboración del proyecto planteado.

Primero, en la **Figura n.º 29**, se detalla el flujo de trabajo por seguir para la elaboración del producto principal del proyecto como resultado de aplicar la revisión documental.

Figura n.º 29 Flujo del trabajo del laboratorio



Nota: Elaboración propia (2024).

Seguidamente, en la **Tabla n.º 10**, se expresan las consideraciones por tomar en cuenta en cada una de las actividades dentro del flujo de trabajo del proyecto como resultado de aplicar la plantilla de la revisión documental en el **Apéndice J. Plantilla de revisión documental**.

Tabla n.º 10. Consideraciones del flujo de trabajo

Parte del flujo	Hallazgo
Solicitud de acceso a recursos.	Se necesita solicitar acceso físico al laboratorio y virtual a los diferentes grupos donde se encuentra información, códigos y bases de datos que se utilizarán dentro del proyecto.
Acceso al servidor virtual “cedar”.	En esta actividad es necesario crear todos los archivos que permitan la conexión remota al servidor “cedar”, siendo estos: archivo de configuración, llave pública y privada; y archivo de almacenamiento de <i>hosts</i> conocidos. Asimismo, es necesario solicitar ayuda por parte de otros compañeros del laboratorio para crear los archivos con la información y formato correctos.
Creación de directorio de trabajo “cedar” y Gitlab.	Es necesario solicitar al supervisor la creación de una carpeta con permisos de administrador dentro del servidor “cedar” y <i>Gitlab</i> , con el objetivo de ir almacenando todos los códigos generados dentro del proyecto.
Desarrollo del proyecto.	Durante esta actividad se tiene disponible el apoyo de los diferentes compañeros dentro del laboratorio para realizar consultas. Además, se tiene la posibilidad de solicitar códigos u proyectos pasados para guiarse con el desarrollo propio.
Guardar en Gitlab – Github.	Cada vez que se llegue a un avance funcional del proyecto es necesario guardarlo dentro de <i>Gitlab - Github</i> para evitar pérdidas de información o documentos.
Generar el reporte escrito del proyecto.	Una vez terminado por completo el proyecto se procede a realizar un reporte escrito que contenga diferentes secciones como <i>literature review, methodology, results y conclusions</i> .
Recibir aprobación del supervisor.	Se solicita una reunión con el supervisor donde se presenta el proyecto terminado junto con su documento escrito y se recibe su aprobación para guardar los resultados.
Guardar en “cedar”.	Se realiza una última subida del proyecto dentro de la carpeta asignada por el supervisor para que otros compañeros del laboratorio tengan la posibilidad de mejorar o revisar los recursos.

Nota: Elaboración propia (2024).

En conclusión, el trabajo se lleva a cabo en un ritmo autodidacta, sin embargo, algunas actividades deben ser preaprobadas por parte del supervisor a cargo y gestionadas con tiempo para evitar los retrasos dentro del proyecto; así mismo se está sujeto a que el servidor u otros recursos no se encuentren disponibles por períodos de tiempo.

4.1.3. Comprensión de la estructura del modelo base

Con respecto a la estructura del modelo base, se utilizó la revisión documental para recolectar la información que permitiera comprender la estructura y funcionalidad del modelo; estos hallazgos se detallan en la **Tabla n.º 11**.

Tabla n.º 11. Estructura del modelo base

Concepto	Hallazgos
Configuraciones generales.	• Formato de las imágenes: NiFTi. • Tipo de imagen médica: TAC. • Arquitectura: ResNet50. • Función de error: Cross Entropy Loss. • Escala de color: Se refiere a que el modelo trabaja con imágenes en escales de grises. • Distribución del dataset: ○ Entrenamiento: 60% ○ Prueba: 20% ○ Validación: 20% • Regiones por clasificar: ○ CHE: Pecho. ○ ABD: Abdomen. ○ PLV: Pelvis. ○ CHA: Pecho – Abdomen. ○ ABP: Abdomen – Pelvis. ○ CAP: Pecho - Abdomen – Pelvis.
Proceso para preprocesamiento de las imágenes.	• Conversión 3D a 2D: MIP. • Hounsfield units (HU): ○ 0 = -1000 ○ 255 = 400 • Tamaño de imagen: 224x224 pixeles. Se refiere a que el modelo tiene como requerimiento que las imágenes que recibe tengan dimensiones de altura y ancho 224 x 224. • Normalización: ○ Volumen min: -1000 ○ Volumen máx.: 400
Proceso de entrenamiento.	• Learning rate: 0,001 • Epochs: 50. Se refiere a que se utilizan 50 iteraciones de los datos para entrenar el modelo. • Decay rate: 0,96
Proceso de prueba.	• Cantidad de procesamiento por batch: 16 imágenes. Se refiere a que el modelo clasifica las imágenes en grupos de 16.

Nota: Elaboración propia (2024).

La información presentada en la **Tabla n.º 11** será utilizada para realizar las pruebas y entrenamientos del modelo, así como, para realizar el debido preprocesamiento de las imágenes médicas.

4.1.4. Selección de la base de datos de trabajo

En relación con la selección de la base de datos para la ejecución de las pruebas del modelo, se tomaron en cuenta varias opciones; sin embargo, se escogió solo una para este proyecto. En la **Tabla n.º 12**, se presenta el nombre de la base de datos y la razones de su no escogencia o escogencia.

Tabla n.º 12. Selección de base de datos

Nombre de base de datos	Razones
Kaicer CT.	• La base de datos contiene más de 5000 registros. • El formato de las imágenes es NiFTi. • Cantidad balanceada de imágenes para más de tres de las clases clasificadas por el modelo.
TataMedicalCenter_CT.	• La base de datos contiene más de 5000 registros. • El formato de las imágenes es DICOM. • Necesita la conversión de DICOM a NiFTi. • Solo contiene imágenes de pecho y abdomen.
CrossCancerInstitute_CT.	• La base de datos contiene más de 5000 mil registros. • El formato de las imágenes es NiFTi. • Base de datos utilizada para el entrenamiento del modelo.

Nota: Elaboración propia (2024).

Tomando en cuenta las razones expuestas en la **Tabla n.º 12**, se selecciona la base de datos Kaiser CT para realizar las pruebas del modelo, ya que cumple con las necesidades planteadas.

4.2. Fase 2 - Comprensión y preprocesamiento de datos


La fase 2 tiene como objetivo la selección y manipulación de los datos que serán eventualmente utilizados para el entramiento y prueba del modelo, respondiendo directamente al primer objetivo específico. Al mismo tiempo, se analiza cómo funciona el etiquetado de las imágenes y cómo este forma parte dentro del proceso de entrenamiento y prueba del modelo. Por otro lado, en esta fase se recolecta información por medio de la aplicación de tablas de registro siguiendo la plantilla presentada en el **Apéndice K. Plantilla de tabla de registro**.

4.2.1. Etiquetado manual de la imagen médica

En este caso se realiza una inspección manual de cada una de las imágenes contenidas en la base de datos llamada *Kaiser CT Scans*, para realizarla de manera ágil se utiliza la versión 2D de las imágenes NiFTi originales llamadas *quickchecks*, estas fueron previamente preprocesadas por compañeros dentro del laboratorio.

En la **Figura n.º 30**, se presenta un ejemplo de las imágenes en su versión *quickchecks*, donde se analiza la fila encerrada con rojo para realizar el etiquetado, ya que son estos *slices* los que utiliza el modelo para realizar la clasificación.

Figura n.º 30 Ejemplo de un quickcheck




Nota: Elaboración propia (2024).

Además, para el análisis y clasificación de esta se utiliza las regiones del cuerpo humano delimitadas según la clase a la que pertenecen, en la **Figura n.º 16** detallada en la **Sección 2.1.1.4**.

Por otro lado, se sigue el flujo expuesto en la **Figura n.º 31** para mantener una trazabilidad y categorización de los datos analizados.

Figura n.º 31 Flujo de etiquetado manual



Nota: Elaboración propia (2024).

Asimismo, en la **Tabla n.º 13**, se presenta un resumen de la cantidad de imágenes etiquetadas para cada una de las pruebas realizadas al modelo junto con la base de datos a la que pertenecen.

Tabla n.º 13. Cantidad de imágenes etiquetadas

Número de prueba	Imágenes	Fuente
Prueba 2	1880	Kaiser CT Scans
Prueba 3	1900	Kaiser CT Scans
Prueba 4	435	Kaiser CT Scans
Prueba 5	1309	Kaiser CT Scans

Total de imágenes etiquetadas:	5524
---------------------------------------	-------------

Nota: Elaboración propia (2024).

Con respecto al total de imágenes etiquetadas, este se acerca a la cantidad utilizada para realizar las primeras pruebas del modelo, por lo que, es una cantidad importante de datos que son utilizados para realizar las pruebas sobre el modelo. Además, es necesario aclarar que la cantidad de imágenes etiquetadas difiere de prueba a prueba porque se busca el balance de las clases clasificadas; por lo que, se etiquetaba solo cierta cantidad para balancear dichas clases y mantener las etiquetadas anteriormente.

4.2.2. Preprocesamiento de las imágenes médicas

Durante el proceso de prueba y entrenamiento se da la necesidad de transformar, cortar o girar las imágenes de la base de datos para tener la posibilidad de utilizarlas.

Debido a esto se utiliza un código en Python para acomodar y cortar las imágenes para obtener imágenes de una clase en específico, donde se utiliza un porcentaje de corte dependiendo de la región que se necesita; por ejemplo: para pelvis es mantener el 20% inferior de una imagen de cuerpo completo, abdomen eliminar el 20% inferior de una imagen que mostraba solo el abdomen y pelvis; y para abdomen-pelvis era mantener el 40% superior de una imagen de cuerpo completo.

En la **Tabla n.º 14** se presenta la cantidad total de imágenes preprocesadas, dividido por clases, para ser utilizadas en las pruebas.

Tabla n.º 14. Cantidad de imágenes preprocesadas

Número de prueba	Clase	Cantidad de imágenes
Prueba 5	PLV	520
	ABD	315
	CHA	390
Total de imágenes preprocesadas		1225

Nota: Elaboración propia (2024).

Como resultado de los números brindados, se logra apreciar que hubo 1225 imágenes que se sometieron a preprocesamiento adicional, lo que representa un 22,17% del total de imágenes utilizadas para las pruebas realizadas.

Por último, es importante mencionar que se tomó esta medida para conseguir una mayor cantidad de imágenes de cada clase por límites de tiempo y disponibilidad de base de datos con TAC en formato NiFTi.

4.2.3. Resultado de inconsistencias

Por último, en el proceso de preprocesamiento de datos se obtienen diferentes inconsistencias a la hora del etiquetado de los datos, por lo cual, en la **Tabla n.º 15** se presenta un resumen de estas con su respectivo tipo.

Tabla n.º 15. *Inconsistencias en la base de datos*

Tipo de inconsistencia	Cantidad
Imagen cortada	60
Imagen oscura ilegible	13
Imagen clara ilegible	9
Imagen inexistente	10
Total de inconsistencias	92

Nota: Elaboración propia (2024).

Como resultado de los números brindados se logra ver que la base de datos utilizada para las pruebas es de calidad, ya que el número de imágenes provechosas versus las defectuosas representan apenas un 1,65%.

4.3. Fase 3 – Modelaje

Esta fase se centra en la manipulación y prueba del modelo desarrollado por Golzan et al. (2024) para obtener las métricas de evaluación que ayuden con la posible identificación de patrones de error. Asimismo, esta fase responde directamente a los objetivos 2 y 3 del presente proyecto. Además, los resultados presentados en esta fase fueron recolectados por medio de la aplicación de dos instrumentos de investigación las tablas de registro siguiendo la plantilla presentada en **Apéndice K. Plantilla de tabla de registro.** y los diseños experimentales para presentar los resultados completos. A continuación, se presenta la nomenclatura por utilizar en las tablas y figuras de este apartado:

- **CHE:** Pecho.
- **ABD:** Abdomen.
- **PLV:** Pelvis.
- **CHA:** Pecho-abdomen.
- **ABP:** Abdomen-Pelvis.
- **CAP:** Pecho-Abdomen-Pelvis.

4.3.1. Definición del ambiente de pruebas

En cuanto a la definición del ambiente de pruebas se utilizan ciertas configuraciones y tecnologías detalladas en la **Tabla n.º 16.**

Tabla n.º 16. Configuración del ambiente de pruebas

Concepto	Detalle
Cantidad de pruebas.	4.
Distribución del dataset.	• Entrenamiento: 60%. • Prueba: 20%. • Validación: 20%.
Hardware.	Samsung Galaxy Book 4: • RAM: 16 GB. • SSD: 512 GB. • Procesador: Intel iCore 7.
Procesador virtual.	NVIDIA GeForce RTX GPU.
Sistema operativo.	Windows 11.
Lenguaje de programación.	Python 3.12.
Librerías.	• Pytorch. • Pandas. • Numpy. • Scipy. • SimpleITK. • Nibabel. • Matplotlib.

Nota: Elaboración propia (2024).

Por último, se utiliza el procesador virtual para correr el código debido a su capacidad computacional, ya que tanto las pruebas como el entrenamiento de modelos de *Deep Learning* necesitan de dicha capacidad para desempeñarse correctamente.

4.3.2. Selección del conjunto de datos para pruebas

Con respecto a la selección del conjunto de datos para pruebas, en la **Tabla n.º 17**, se detalla la cantidad de datos utilizada en cada una de las pruebas y cómo esta cantidad fue dividida en cada una de las clases. Asimismo, se resalta de color verde la distribución del *dataset* utilizado para realizar el primer entrenamiento/prueba del modelo con la base de datos utilizada para la creación del modelo.

Tabla n.º 17. Resumen de los datasets utilizados en pruebas

Número de prueba	Dataset	CHE	ABD	PLV	CHA	ABP	CAP
1	5485	200	200	186	109	200	200
2	1850	72	8	1	2	186	103
3	1880	72	11	3	2	191	104
4	2270	88	37	11	22	190	106
5	3620	92	104	115	118	193	109


Nota: Elaboración propia (2024).

Como se presenta en la **Tabla n.º 17**, se apuntó a utilizar un *dataset* balanceado para lograr obtener una vista detalla del desempeño del modelo.

4.3.3. Ejecución de pruebas

Con respecto a la ejecución de pruebas, en la **Figura n.º 32** se presentan los pasos seguidos para realizar la prueba y en la **Tabla n.º 18**, se presenta un resumen del número de prueba y la fecha en la que esta se realizó.

Figura n.º 32 Proceso de ejecución de pruebas



Nota: Elaboración propia (2024).

Tabla n.º 18. Fechas de ejecución de pruebas

Prueba	Fecha de ejecución
Prueba 1	29-10-2024
Prueba 2	06-11-2024
Prueba 3	11-11-2024
Prueba 4	12-11-2024
Prueba 5	09-12-2024

Nota: Elaboración propia (2024).

4.3.4. Registro de las métricas de evaluación

Con respecto a la evaluación del modelo, en la **Tabla n.º 19**, se muestran los resultados obtenidos en las diferentes pruebas realizadas, en términos de precisión, exactitud, *recall* y F1-Score; según las fórmulas planteadas en la **Sección 2.1.2.2**. Igualmente, se resalta con amarillo datos relevantes obtenidos y en verde se resalta los valores del estado del arte.

Tabla n.º 19. Resultados generales de las métricas de evaluación

Número de prueba	Dataset	Exactitud	Precisión	Recall	F1 score	Desempeño	Pérdida de prueba
1	5485	97,30%	97,20%	97,20%	97,20%	97,23%	0,0965
2	1850	97,50%	96,80%	97,30%	97%	97,1%	0,1808
3	1880	93,83%	95,60%	93,90%	94,50%	94,64%	0,2328
4	2270	91,14%	90%	90,70%	89,60%	90,25%	0,3660
5	3620	77,50%	83,30%	77,90%	76,30%	79,03%	0,9377

Nota: Elaboración propia (2024).

Como se ve resaltado, en la **Tabla n.º 19**, la pérdida de prueba fue aumentando conforme se fue agrandando el *dataset*, esto se presenta por varias situaciones:

- La calidad de las imágenes no es la esperada, dando como resultado que el modelo no logre analizar correctamente la imagen, por ejemplo: las imágenes de prueba son más oscuras comparadas con las imágenes de entrenamiento.
- Al utilizar *Cross Entity Function* para el cálculo de la pérdida de prueba, se tiene la posibilidad de obtener un resultado elevado debido a que esta función penaliza los *datasets* no balanceados.
- También, los resultados obtenidos presentan una sospecha de *Overfitting*.

Además, en términos generales se genera la preocupación que las imágenes que fueron cortadas y alineadas de manera masiva sean parte de la razón para los resultados bajos obtenidos en la prueba #5.

Además, en la **Tabla n.º 20**, se detalla las métricas de evaluación para cada una de las clases, divididas por la prueba a la que pertenecen. Asimismo, en el **Anexo II. Matrices de confusión** se adjunta las matrices de confusión resultantes de las pruebas y que ayudaron con el cálculo presentado en la tabla.

Tabla n.º 20. Resultados de las métricas de evaluación por clase

Núm. prueba	Clase	Dataset	Exactitud	Precisión	Recall	F1 score
2	CHE	72	100%	99%	100%	99%
	ABD	8	75%	100%	75%	86%
	PLV	1	0%	0%	0%	0%
	CHA	2	0%	0%	0%	0%
	ABP	186	100%	96%	100%	98%
	CAP	103	95%	99%	95%	97%
3	CHE	72	99%	97%	99%	98%
	ABD	11	64%	100%	64%	78%
	PLV	3	0%	0%	0%	0%
	CHA	2	50%	20%	50%	29%
	ABP	191	98%	96%	98%	97%
	CAP	104	89%	97%	89%	93%
4	CHE	88	95%	80%	95%	87%
	ABD	37	86%	91%	86%	89%
	PLV	11	55%	86%	55%	67%
	CHA	22	18%	57%	18%	28%
	ABP	190	98%	94%	98%	96%
	CAP	106	93%	98%	93%	96%
5	CHE	92	98%	76%	98%	86%
	ABD	104	89%	93%	89%	91%
	PLV	115	39%	90%	39%	55%
	CHA	118	42%	94%	42%	58%
	ABP	193	93%	88%	98%	93%
	CAP	109	94%	52%	94%	67%

Nota: Elaboración propia (2024).

También, en la **Tabla n.º 21**, se hace un resumen con la cantidad de registros que fueron clasificados de manera errónea por el modelo en cada una de las pruebas realizadas, también en el **Anexo I. Detalle de las clasificaciones erróneas** se adjunta los detalles de cuáles imágenes fueron clasificadas erróneamente.

Tabla n.º 21. Cantidad de errores de clasificación, según prueba

Prueba	CHE	ABD	PLV	CHA	ABP	CAP	Cantidad de clasificaciones erróneas
Prueba 2	0	2	1	2	0	5	9
Prueba 3	1	4	3	1	3	11	23
Prueba 4	4	5	5	18	3	7	41
Prueba 5	2	11	70	68	3	6	159

Nota: Elaboración propia (2024).

Como se aprecia en la **Tabla n.º 20 y Tabla n.º 21**, se tiene un patrón de error con las clases PLV y CHA donde superan 50 clasificaciones erróneas, asimismo los resultados de sus métricas de evaluación promedian 50. Esto refuerza que el modelo necesita mayor entrenamiento o aumento de la sensibilidad en estas clases para realizar la clasificación correcta. Además, refuerza la necesidad de agrandar la cantidad de imágenes para cada clase con el objetivo de mejorar el análisis y clasificación de dichas clases.

4.3.5. Modificación y entrenamiento del modelo

Con respecto a esta actividad, al llegar al final del proyecto se decidió en conjunto con el supervisor (Apéndice H. Minuta 3 – Segunda entrega de productos) no realizar una nueva fase de entrenamiento del modelo base, debido a las siguientes razones:

- No se lograron validar que los resultados a tiempo obtenidos después de realizada la prueba 5, como se había estipulado en Apéndice G. Minuta 2 – Primera entrega de productos.
- Al no tener validados los resultados, si se utilizan las imágenes de *testing* como *training* se tenía la posibilidad de caer en las siguientes situaciones:
 - Una desconfiguración del modelo, lo que significa que este es entrenado con imágenes etiquetadas de manera errónea.
 - Aparición del *Overffiting* donde el modelo se aprende las imágenes de entrenamiento y logra clasificar correctamente imágenes nunca vistas.
 - La idea de utilizar la base de datos seleccionada era presentarle al modelo imágenes nuevas para conocer su desempeño, si se toma estas y se aplican en un proceso de entrenamiento se tiene la posibilidad que el modelo presente métricas mejoradas, pero no apegadas a cómo se comportaría en clasificaciones generales.

4.3.5.1. Selección del modelo óptimo

Debido a la decisión de no realizar una modificación significativa ni una nueva fase de entrenamiento del modelo, se decide continuar con la versión estable del modelo⁷ sin realizarle cambios sustanciales, ya que como se observa en la **Tabla n.º 19**, el modelo tiene un desempeño general oscila entre 79-97%, lo cual es aceptable dentro del contexto del proyecto, esto debido a que se tenía como criterio de aceptación que el modelo obtuviera resultados mayores a 75% en cada prueba ejecutada.

Este criterio se estableció tomando en cuenta los resultados obtenidos en el trabajo elaborado dentro del laboratorio mencionado en la **Sección 1.2.3.1 punto 1**, donde se obtuvieron métricas de evaluación que oscilaban en 78% a 81%. Así como de los resultados obtenidos en los modelos de *Deep Learning* desarrollados basándose en la metodología *CRISP-DM* y los modelos basados en arquitectura *ResNet* expuestos en la **Sección 2.2.3 y Sección 2.2.4** respectivamente; donde se tienen ejemplos de modelos con porcentajes generales de las métricas de evaluación que oscilan entre 60%-80%.

⁷ Model_classification_resnet05-21-2024_10-11_1000dataset. pt

4.4. Discusión de análisis de resultados

En este apartado se enlistan recomendaciones de situaciones o temas que tienen la posibilidad de ser desarrollados en futuras investigaciones y trabajos, con el fin de extender y mejorar la funcionalidad del modelo.

- El modelo actual fue desarrollado para utilizar imágenes NiFTi para realizar su clasificación; sin embargo, al incluir otros formatos como DICOM puede presentar una mejora dentro del flujo de trabajo del personal médico y hacer que el modelo sea más robusto al aceptar diferentes formatos, lo que también permite tener disponible una diversidad de bases de datos para utilizar.
- El modelo fue entrenado y probado con diferentes bases de datos, sin embargo, exponerlo a nuevas bases de datos nunca garantiza que el modelo sea más robusto y preciso al realizar la clasificación. Además, al exponer constantemente el modelo a nuevas imágenes médicas, se pueden identificar otros patrones de error, así como oportunidades de mejora en su configuración y características; específicamente en aquellas clases donde se obtuvieron métricas de evaluación por debajo de 70% como lo es PLV y CHA para así conocer si las clasificaciones erróneas se deben a la calidad de la base de datos o si el modelo necesita modificarse en su definición de las clases.
- Aunque el modelo se desarrolla de manera que se adhiera a los contextos reales del flujo de trabajo médico, siempre es una buena práctica obtener el apoyo o la participación del personal médico auténtico para validar el desempeño del modelo y la aplicación, como validar si las regiones definidas para la clasificación en este modelo son de importancia o deberían ser modificadas. De esta forma se obtiene retroalimentación que sirve como insumo para futuras mejoras o ampliaciones de las funcionalidades.

Finalmente, este capítulo comprende solamente las fases 1, 2 y 3 debido a que las fases 4 y 5 tienen que ver directamente con la definición e implementación de la propuesta de solución planteada en este proyecto, por lo que los detalles de estas se encuentran en el siguiente **Capítulo Propuesta de Solución**.

5. Propuesta de Solución

En esta sección se detalla la propuesta de solución planteada y ejecutada por la estudiante para cumplir con todos los objetivos planteados dentro del proyecto, en forma de las fases 4 y 5 que se derivan de la aplicación de la metodología CRIPS-DM y lo planteado en la **Sección 3.7**.

5.1. Fase 4 – Integración

En esta fase se realizan las actividades que permiten la preparación y desarrollo del puente que conecta el modelo de clasificación con la herramienta de escritorio creada.


5.1.1. Preparación del modelo y aplicación para integración

Con respecto a esta tarea, se realiza un proyecto en el lenguaje de programación Python, y se utilizan la librería *Onnx* para realizar la configuración de una API que permite realizar *request* al modelo sin importar que otro lenguaje se esté utilizando para el *Frontend*, en este caso el uso de *Electron*.

En la **Figura n.º 33** se presenta la distribución del proyecto en Electron, donde se puede visualizar las carpetas:

- **View:** Donde se encuentra todo lo relacionado con las interfaces gráficas y las interacciones del usuario con ellas.
- **Model:** Donde se encuentra la lógica de los *requests* a la API.
- **Utils:** Donde se albergan códigos misceláneos que se utilizan en diferentes partes del flujo de funcionalidad de la herramienta.
- **Controller:** Donde se presenta la lógica que conecta las interacciones en las interfaces gráficas con su respectivas *requests* en *model*.
- **API:** Donde se encuentra el código del modelo, el código para guardar el modelo y el archivo “. onnx” resultante.

Figura n.º 33 Distribución del proyecto



Nota: Elaboración propia (2024).

Por último, en la **Figura n.º 34** se presenta el código utilizado para preparar el modelo para después guardarlo y agregarlo al proyecto. En este código se llama el modelo en su versión reciente y estable, se le brinda sus configuraciones y después se guarda en un archivo formato “.onnx”.

Figura n.º 34 Código para preparar modelo

```
import sys
import os
current_dir = os.path.dirname(os.path.abspath(__file__))
project_dir = os.path.dirname(current_dir)
sys.path.append(project_dir)
import pandas as pd
# from utils.load_data import Dataset
# from utils.bases import split_data_equally, data_statistics
from model.model import modified_resnet50
# from utils.runner import Runner
import torch
import torch.nn as nn

model_path = 'work_dir\\resnet50\\model_classification_resnet05-21-2024_10-11_1000dataset.pt'
model = modified_resnet50(pretrained=False, in_channels=1, num_classes=6) # Define your model architecture
if not os.path.exists(model_path):
    print(f"Model file not found at {model_path}")
else:
    model.load_state_dict(torch.load(model_path, map_location=torch.device('cpu'))))

torch_input = torch.randn(1, 1, 224, 224)
torch.onnx.export(model, torch_input, "API/modelOnnxSingle.onnx")
```

Nota: Elaboración propia (2024).

5.1.2. Integración modelo-herramienta

En la **Figura n.º 35** se adjunta el proceso seguido para la integración del modelo dentro de la herramienta.

Figura n.º 35 Proceso de integración del modelo



Nota: Elaboración propia (2024).

Primero, en la **Figura n.º 36**, se presenta el archivo que contiene el modelo guardado.

Figura n.º 36 Archivo del modelo


Nombre	Fecha de modificación	Tipo	Tamaño
app	18/12/2024 23:59	Python File	1 KB
model_classification_resnet05-21-2024_1...	31/12/2024 19:48	Archivo PT	23 552 KB
modelOnnx.onnx	19/12/2024 00:00	Archivo ONNX	91 772 KB
modelOnnxSingle.onnx	31/12/2024 23:22	Archivo ONNX	91 772 KB
onnxSave	31/12/2024 23:17	Python File	1 KB

Nota: Elaboración propia (2024).

Seguidamente, en la **Figura n.º 37**, se presenta la validación realizada con *Netron* para confirmar que el modelo contiene todas sus características.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.


Figura n.º 37 Validación en Netron



Nota: Elaboración propia (2024).

Por último, en la **Figura n.º 38**, se presenta la evidencia de que el modelo fue agregado dentro del proyecto principal, en la carpeta “model”.

Figura n.º 38 Modelo en proyecto principal



Nota: Elaboración propia (2024).

5.2. Fase 5 – Despliegue


En esta fase el objetivo principal es el seguimiento de los pasos necesarios para el desarrollo de la herramienta de escritorio; y su integración con el modelo de clasificación seleccionado.

5.2.1. Diseño de la interfaz gráfica

En relación con la elaboración del diseño de la interfaz gráfica de la herramienta, se decide realizarla por medio de los lenguajes *HTML*, *CSS* y *JavaScript*; asimismo se utiliza la plataforma de *Electron* para asegurar la compatibilidad con los diferentes sistemas operativos.

Primero, en la **Figura n.º 39** se presenta el *sketch* de cómo debería verse la herramienta con sus interfaces gráficas.


Figura n.º 39 Sketch de las interfaces gráficas



Nota: Elaboración propia (2024).


Seguidamente, en la **Figura n.º 40**, **Figura n.º 41** y **Figura n.º 42**, se muestra la apariencia estética de la herramienta.

Figura n.º 40 Página "About ClassiCTMed"




Nota: Elaboración propia (2024).

Figura n.º 41 Página "Single classification"



Nota: Elaboración propia (2024).

Figura n.º 42 Página "Bulk Classification"



Nota: Elaboración propia (2024).

5.2.2. Diseño de la arquitectura

La arquitectura seleccionada para el desarrollo de la aplicación se compone de los siguientes elementos:


- **Backend:**
 - Modelo desarrollado en *Python*.
 - API desarrollado con *Onnxruntime* para enviar las imágenes y obtener el resultado de la clasificación.
- **Frontend:**
 - Se utiliza el *framework* Modelo-Vista-Controlador para separar la lógica, y aumentar la facilidad para mantener el código.
 - Se utilizan una variedad de librerías de NodeJs para desarrollar las funcionalidades de la herramienta, estas son:
 - **Nifti-reader-js:** Esta librería permite la manipulación de las imágenes NiFTi, y así corroborar que contienen la información necesaria para ser clasificadas.
 - **Niivue:** Esta librería permite la carga de una previsualización de la imagen con formato NiFTi seleccionada por el usuario.
 - **Onnxruntime:** Esta librería permite la comunicación modelo-herramienta.
 - **Amd-zip:** Esta librería permite la gestión de archivos tipo ZIP. Dentro del proyecto se encarga de gestionar la funcionalidad que permite visualizar los archivos del ZIP seleccionado.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

- Se utiliza *Electron* con *Javascript*, *HTML* y *CSS* para crear las interfaces gráficas de la aplicación.

Por último, en la **Figura n.º 43** se adjunta un resumen de cómo se plantea la arquitectura de la aplicación donde se detallan las librerías utilizadas para el *Frontend*.

Figura n.º 43 Arquitectura de la aplicación



Nota: Elaboración propia (2024).

5.2.3. Desarrollo de la herramienta

Primeramente, se detalla en la **Tabla n.º 22**, las tareas relacionadas con el desarrollo de la herramienta junto con su complejidad, los conocimientos puestos en práctica obtenidos en la carrera y el tiempo en días que tomó completarlas en semanas. La escala utilizada para medir la complejidad se encuentra detallada a continuación:

- **Baja:** Se refiere a tareas que requieren de un conocimiento de funciones básicas de programación y toman de uno a tres días para completarlas.
- **Media:** Se refiere a tareas que requieren conocimientos avanzados de programación y toman de cuatro a siete días para completarlas.
- **Alta:** Se refiere a tareas que requieren conocimientos especializados en programación y toman más de siete días para completarlas.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Tabla n.º 22. Tareas para el desarrollo de la herramienta

Tarea	Complejidad	Conocimientos utilizados	Tiempo (en días)
Selección de las tecnologías por utilizar	Media	Diseño de <i>software</i>	4
Diseño (en papel) de la interfaz gráfica	Baja	Diseño de <i>software</i>	1
Configuración inicial de la herramienta <i>framework</i> MVC	Baja	Diseño y desarrollo de <i>software</i>	1
Programación estética de la interfaz gráfica 1 - Página "About"	Baja	Desarrollo de <i>software</i>	2
Programación funcionalidad de la interfaz gráfica 1 - Página "About"	Baja	Desarrollo de <i>software</i>	2
Programación estética de la interfaz gráfica 2 - Página "Single Classification"	Baja	Desarrollo de <i>software</i>	3
Programación de mostrar los resultados de clasificación - Página "Single Classification"	Baja	Desarrollo de <i>software</i>	1
Programación estética de la interfaz gráfica 3 - Página "Bulk classification"	Media	Desarrollo de <i>software</i>	4
Programación de mostrar los resultados de clasificación - Página "Bulk classification"	Media	Desarrollo de <i>software</i>	7
Agregar la funcionalidad de guardar en diferentes carpetas las clasificaciones realizadas	Alta	Desarrollo de <i>software</i>	9
Agregar funcionalidad de previsualización del TAC en la herramienta	Alta	Desarrollo de <i>software</i>	9
Agregar funcionalidad de previsualización de los contenidos del zip en la herramienta	Media	Desarrollo de <i>software</i>	4
Agregar la comunicación entre modelo-herramienta	Alta	Desarrollo de <i>software</i>	11
Pruebas de funcionalidad	Baja	Calidad de <i>software</i>	3

Nota: Elaboración propia (2024).

En total el tiempo utilizado para desarrollar la herramienta fue de **61 días** u ocho semanas de desarrollo en paralelo con las pruebas del modelo de *Deep Learning*.

Además, en el **Apéndice I. Cronograma de desarrollo de la herramienta** se puede encontrar el cronograma de desarrollo de la herramienta según las semanas del proyecto en las cuales se completaron las tareas planteadas.

Seguidamente, en la **Tabla n.º 23** se describen las dificultades, decisiones u obstáculos atravesados en cada una de las tareas.

Tabla n.º 23. Dificultades del desarrollo de la herramienta

Tarea	Dificultad, decisión u obstáculo
Selección de las tecnologías por utilizar	• Para la integración modelo-herramienta, en un principio se había tomado la decisión de utilizar <i>Flask</i>, pero después de considerar las características de esta librería y contrastarlas con <i>Onnx</i>, se decidió continuar con <i>Onnx</i> debido a su flexibilidad, fácil uso y oportunidades de distribución. • Para el desarrollo de la lógica de negocios y el <i>FrontEnd</i> se escogió utilizar el <i>open-source Electron</i> que permitía un <i>framework</i> sencillo de utilizar y con mínimo tiempo de configuración, además ya incluía los intérpretes de <i>Javascript</i>, <i>HTML</i> y <i>CSS</i>. • Para generar y gestionar el código, se decidió utilizar la herramienta <i>Visual Studio Code</i> por familiaridad con sus funcionalidades y conocimiento de sus características.
Diseño (en papel) de la interfaz gráfica	Para el diseño de la interfaz se tomaron en cuenta aquellos colores que transmitían sector médico, por la naturaleza del proyecto. Además, del <i>skecth</i> realizado en papel se realizó su versión en <i>Figma</i> para obtener una versión profesional de lo diseñado.
Configuración inicial de la herramienta <i>framework</i> MVC	La decisión de utilizar el <i>framework</i> MVC viene del esfuerzo por entregar un código de calidad, ya que este <i>framework</i> permite separar la lógica de manera que el código tenga un alto porcentaje de mantenibilidad y un bajo porcentaje de complejidad. También, otra de las razones fue facilitar la colaboración y extensión de la herramienta desarrollada, por lo que al utilizar las características de separación del código permite que este sea reutilizado en otros desarrollos.
Programación estética de la interfaz gráfica 1 - Página "About"	Se decidió agregar imágenes móviles (gif) que mostraran las regiones del cuerpo que el modelo clasifica para ayudar a la comprensión del contexto de la herramienta.
Programación estética de la interfaz gráfica 2 - Página "Single Classification"	Después de analizar la herramienta se decide agregar un cuadro con el significado de cada uno de los acrónimos que presenta como resultado el modelo para una sencilla interpretación de la información presentada.

Tarea	Dificultad, decisión u obstáculo
Programación de mostrar los resultados de clasificación - Página "Single Classification"	Al desarrollar esta funcionalidad se presentó una dificultad relacionada con la presentación del resultado, ya que la información devuelta por el modelo era abundante y no se lograba llegar al resultado que se deseaba mostrar. Por esto, se tuvo que ir disecando la respuesta parte por parte hasta encontrar la parte de la respuesta que se quería mostrar.
Programación de mostrar los resultados de clasificación - Página "Bulk classification"	Después de analizar la herramienta se decide eliminar la posibilidad de visualizar la exactitud del modelo con respecto a las clasificaciones realizadas, por dos razones: • No se consideró un dato relevante para los usuarios finales. • Evitar errores de cálculo de la exactitud cuando se recibe un ZIP que no contine unca cantidad balanceada de cada clase. • Se consideró que sería de ayuda tener una opción que permita a los usuarios descargar un ZIP con los resultados de la clasificación realizada por el modelo.
Agregar la funcionalidad de guardar en diferentes carpetas las clasificaciones realizadas	• Esta tarea sufrió un retraso importante debido a que el equipo de cómputo utilizado para desarrollar la herramienta dejó de funcionar y se perdió todo el avance que se tenía. • Por otro lado, esta funcionalidad se planteó como medida para aumentar la funcionalidad de la herramienta y como intercambio con la funcionalidad que presentaba la exactitud de la clasificación.
Agregar funcionalidad de previsualización del TAC en la herramienta	• Esta funcionalidad fue agregada después de analizar la herramienta y pensar que sería importante que los usuarios tengan la posibilidad de corroborar que la imagen que quieren clasificar es la que seleccionaron. • Para esta funcionalidad se tomaron varias rutas de ejecución: ○ Primero, se intentó realizar dibujando en un <i>canvas</i> de <i>HTML</i>, pero se encontraron problemas de calidad de la imagen. ○ Segundo, se intentó utilizar diferentes librerías de visualización de imágenes, pero no eran compatibles con <i>NodeJS</i>. Al final se indagó y se encontró la librería <i>Niivue</i> que permite la previsualización de imágenes NiFTi de alta calidad.
Agregar funcionalidad de previsualización de los contenidos del zip en la herramienta	Esta tarea sufrió de un retraso importante debido a que el equipo de cómputo utilizado para desarrollar la herramienta dejó de funcionar y se perdió todo el avance que se tenía.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Tarea	Dificultad, decisión u obstáculo
Agregar la comunicación entre modelo-herramienta	Esta tarea sufrió de un retraso importante debido a que el equipo de cómputo utilizado para desarrollar la herramienta dejó de funcionar y se perdió todo el avance que se tenía. Además, se realizaron dos actualizaciones del modelo porque: 1. La entrada de datos estaba mal configurada y 2. Se actualizó el modelo.
Pruebas de funcionalidad	Para la realización de las pruebas se decidió que se llevarían a cabo cuatro tipos para asegurar la calidad de la herramienta elaborada: usabilidad y funcionalidad, calidad, tiempos de respuesta y uso de recursos computacionales.

Nota: Elaboración propia (2024).


Continuando, se exponen las lecciones aprendidas del proceso de creación de la herramienta.

- El uso de *Onnx* permite una comunicación modelo-herramienta sencilla de comprender y gestionar, mientras que el uso primario de *Flask* presentaba un doble esfuerzo por parte de los usuarios finales para usar la herramienta.
- Es importante guardar en varios repositorios el proyecto que se está elaborando para evitar la pérdida de información y avance.
- El plantear la realización de pruebas de funcionalidad de varios tipos permite asegurar un grado de calidad a la herramienta desarrollada.
- El utilizar el *framework* permite realizar un desarrollo ordenado y gestionar los cambios de manera fluida.
- El utilizar un nuevo programa *Electron* presenta una curva de aprendizaje que debe tomarse en cuenta en el cronograma de ejecución.
- La programación paralela permite avanzar de manera ágil y presentar resultados con rapidez.

Por último, en la **Figura n.º 44**, **Figura n.º 44** se presenta la evidencia de que la herramienta fue desarrollada.

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Figura n.º 44 Evidencia de desarrollo de la herramienta



Nota: Elaboración propia (2024).

5.2.4. Pruebas de funcionalidad

Las pruebas de funcionalidad realizadas en la aplicación fueron de tipo caja negra, donde se pretende evaluar las funcionalidades y usabilidad de la aplicación sin tomar en cuenta la lógica del código en el *backend*, y caja blanca, donde si se evalúa el código fuente junto con la lógica detrás.

Primeramente, en la **Tabla n.º 24** se adjunta la definición del ambiente de pruebas para la herramienta desarrollada.


Tabla n.º 24. Ambiente de pruebas de la herramienta

Característica	Detalle
Cantidad de pruebas realizadas	• Usabilidad y funcionalidad: 3. • Calidad: 1. • Recursos computacionales: 1 • Tiempos de ejecución: 1.
Tipo	• Usabilidad y funcionalidad: caja negra. • Calidad: caja blanca. • Recursos computacionales: caja blanca. • Tiempos de ejecución: caja negra.
Equipo de cómputo	Computadora HP • Procesador: AMD A9-9425 RADEON R5. • RAM: 12 GB. • Sistema operativo: Windows 10 x64.
Software	• Usabilidad y funcionalidad: Visual Studio Code v1.96.3. • Calidad: SonarQube Community Edition v25.1.0.102122. • Recursos computacionales: Visual Studio Code v1.96.3. • Tiempos de ejecución: Visual Studio Code v1.96.3.

Nota: Elaboración propia (2024).

Seguidamente, en la **Figura n.º 45**, se presenta la evidencia de la funcionalidad para ver una vista previa del TAC seleccionado para su clasificación.


Figura n.º 45 *Mostrar una vista previa del TAC*



Nota: Elaboración propia (2024).

Continuando, en la **Figura n.º 46**, se presenta el resultado de la clasificación del TAC mostrado en la vista previa.


Figura n.º 46 *Resultado de la clasificación individual*



Nota: Elaboración propia (2024).

Asimismo, en la **Figura n.º 47**, se muestra cómo se visualiza el proceso de clasificación de un zip que contiene TAC.

Figura n.º 47 Proceso de clasificación grupal




Nota: Elaboración propia (2024).

Posteriormente, en la **Figura n.º 48** y **Figura n.º 49**, se expone los resultados de la clasificación grupal donde se presenta un resumen de los contenidos del zip seleccionado, un resumen de la cantidad de imágenes clasificadas en cada región y un botón que le permite al usuario descargar un zip con las imágenes guardadas en folders según su clasificación.


Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Figura n.º 48 Resultados de la clasificación grupal



Nota: Elaboración propia (2024).

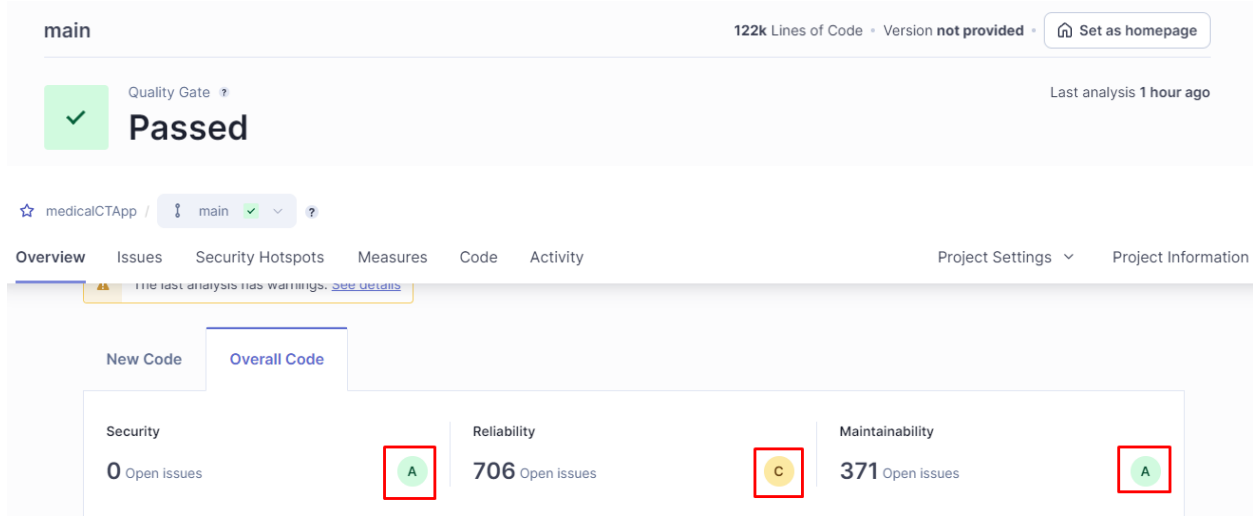
Figura n.º 49 Zip con los resultados de la clasificación



Nota: Elaboración propia (2024).

Continuando, en la **Figura n.º 50** Resultados de la prueba de calidad se exponen los resultados obtenidos después de realizar la prueba de calidad, donde se midió la seguridad, fiabilidad y mantenibilidad de la herramienta desarrollada.

Figura n.º 50 Resultados de la prueba de calidad



Nota: Elaboración propia (2024).

Con respecto a los resultados obtenidos, la nota obtenida en el apartado “**Reliability**” es C debido a situaciones con los módulos instalados dentro de la herramienta; sin embargo, esto no presenta un peligro eminente ni un obstáculo de funcionalidad por lo que se acepta la calificación.

Además, en la **Tabla n.º 25** se detalla un promedio del uso de recursos computacionales al ejecutar la funcionalidad “*Single Classification*” y “*Bulk Classification*”, cabe destacar que en el **Anexo III. Detalle de prueba: recursos computacionales** se adjuntan los detalles de la prueba.

Tabla n.º 25. Uso de recursos computacionales

Funcionalidad	Recurso computacional	Uso
Single classification	CPU	0% – 16%
	Memoria	30000 – 80000 KB
Bulk classification (12 imágenes)	CPU	0% – 1,24%
	Memoria	79000 – 410000 KB

Nota: Elaboración propia (2024).

Los resultados de la **Tabla n.º 25** permiten establecer que la herramienta consume un porcentaje mínimo de recursos computacionales lo que presenta un beneficio de uso.

Por otro lado, se realiza una prueba para conocer el tiempo que toman las funcionalidades en completar el trabajo, donde se obtuvieron los siguientes resultados presentados en la **Tabla n.º 26**. Además, es importante mencionar que en los tiempos de la clasificación grupal están relacionados con el tiempo de procesar una imagen dentro del zip.

Tabla n.º 26. *Tiempos de procesamiento*

Funcionalidad	Tiempo individual	Tiempo total
Clasificación individual	Proceso de clasificación: 3,363 s. Presentación de resultados: 2 s.	5,363 s.
Clasificación grupal (12 imágenes)	Proceso de preprocesamiento: 35 s – 120 s. Proceso de clasificación: 1 s – 3 s. Presentación de zip con resultados: 40 s – 120 s.	76s – 243 s.

Nota: Elaboración propia (2024).

Analizando los tiempos presentados, la aplicación presenta una opción rápida para la clasificación individual y grupal de TAC.

Por último, se realiza una encuesta de usabilidad y satisfacción general a uno de los usuarios expertos para conocer su opinión; además, en la **Tabla n.º 27**, se enlistan detalles de las encuestas aplicadas.

Tabla n.º 27. *Características de las encuestas de usabilidad y satisfacción*

Característica	Detalla
Número de preguntas	Encuesta usabilidad: 10. Encuesta satisfacción: 7.
Escala de calificación	La escala de calificación usada fue de uno a cinco, donde uno significa “Totalmente en desacuerdo” y “Totalmente de acuerdo”.
Plantilla de preguntas	Encuesta usabilidad: Apéndice E. Plantilla de encuesta de usabilidad. Encuesta de satisfacción: Apéndice D. Plantilla de encuesta de satisfacción.
Temas de las preguntas	Encuesta usabilidad: Apariencia general, presentación de los resultados, complejidad de uso, grado de inconsistencias y grado de conocimiento profesional para utilizar la herramienta. Encuesta satisfacción: Importancia de las funcionalidades dentro del contexto, tiempo de respuesta, instrucciones claras dentro de la herramienta, cumplimiento de expectativas y grado de impacto dentro del sector salud.
Usuario experto	En este caso, el usuario experto para ambas encuestas fue el supervisor del proyecto, quien tiene experiencia en aplicaciones de similar naturaleza.
Interpretación de resultados	Encuesta de usabilidad: <i>System Usability Scale</i> (SUS) que permite medir qué tan usable son las aplicaciones o sistemas desarrollados en <i>software</i> , donde las calificaciones por encima de 80,3 significan que el sistema cumple con las consideraciones de usabilidad. Encuesta de satisfacción: La calificación de satisfacción se mide con una escala del uno a cinco, donde una calificación cercana a cinco significa que la aplicación cumple con lo esperado.

Nota: Elaboración propia (2024).

Asimismo, en la **Tabla n.º 28**, se presenta las calificaciones obtenidas en cada una de las encuestas, igualmente las respuestas de estas se encuentran en **Anexo IV. Respuestas encuesta de satisfacción** y **Anexo V. Respuestas de encuesta de usabilidad**.

Tabla n.º 28. Resultados de encuesta de satisfacción y usabilidad

Encuesta	Calificación
Satisfacción	4,86
Usabilidad	87,5

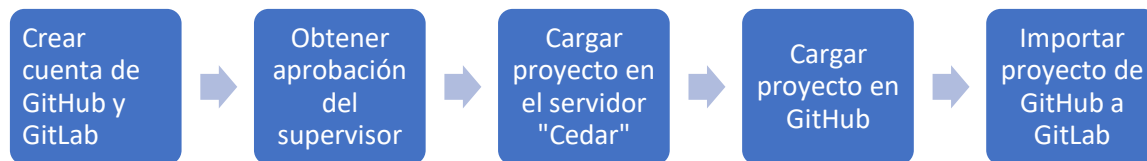
Nota: Elaboración propia (2024).

Con estos resultados, se tiene la certeza que la aplicación desarrollada cumple con las expectativas planteadas, así como, que presenta una opción de valor para la automatización de la clasificación de imágenes médicas.

5.2.5. Paso a producción

En primer lugar, en la **Figura n.º 51** se adjunta el proceso seguido para realizar el paso a producción de la herramienta.

Figura n.º 51 Proceso de paso a producción



Nota: Elaboración propia (2024).

En segundo lugar, en la **Tabla n.º 29** se presentan las dificultades, obstáculos o situaciones encontrados a la hora de realizar el paso a producción de la herramienta.

Tabla n.º 29. Dificultades del paso a producción

Paso del proceso	Dificultad-obstáculo-situaciones
Crear cuenta de GitHub	Al crear la cuenta de GitHub esta se debió crear con la cuenta del laboratorio para permitir la correcta comunicación entre GitHub y GitLab.
Crear cuenta de GitLab	Para crear la cuenta de GitLab era necesario seguir los pasos delimitados en el manual “FAISAL compute setup” donde se requería solicitar permiso para acceder a los repositorios del laboratorio y así terminar de configurar la cuenta.
Obtener aprobación del supervisor	La presentación de los resultados al supervisor sufrió de un atraso de alrededor de dos semanas, debido a problemas con el equipo de cómputo utilizado para el desarrollo, así como la pérdida de parte del código funcional de la herramienta.
Cargar proyecto en el servidor “Cedar”	Las dificultades presentadas para cargar el proyecto dentro del servidor “Cedar” fueron: • El servidor estuvo caído por dos semanas, por lo que, no se tenía acceso a él para realizar la respectiva carga. • A la hora de copiar el proyecto, la conexión con el servidor se perdía, por lo que se tuvo que aumentar el tiempo de conexión. • Se tuvo que solicitar la creación de un nuevo repositorio de archivos dentro del servidor, debido a problemas con el espacio disponible.
Cargar proyecto a GitHub	Para lograr cargar el proyecto dentro de GitHub se presentó el obstáculo relacionado con el peso de los archivos dentro del proyecto, donde la plataforma no permitía archivos que superaran los 50 MB; dentro del proyecto se tenían dos documentos que sobrepasaban este límite, por lo que, se tuvieron dos opciones 1. Usar un programa externo llamado Git Lfs o 2. Excluir aquellos archivos mayores a 50 MB. Tomando en cuenta el tiempo y la facilidad, se implementó la segunda opción y se excluyó la carga de los archivos mayores a 50MB.
Importar proyecto de GitHub a GitLab	Al momento de importar el proyecto de GitHub a GitLab se presentaron las siguientes dificultades: • El nombre del proyecto en GitHub y en GitLab deben coincidir para que la importación se dé correctamente. • En la configuración de GitLab se deben agregar los repositorios del laboratorio para agregar el proyecto. • Así como en GitHub, GitLab no permite la carga de archivos que sobrepasen los 50 MB de peso, por lo que, se excluyeron los mismos archivos que en el paso “Carga proyecto a GitHub”.

Nota: Elaboración propia (2024).

En tercer lugar, en la **Tabla n.º 30** se realiza un resumen de los requerimientos completados y presentados junto a las secciones que evidencian su cumplimiento. Asimismo, dichos requerimientos fueron presentados al supervisor para “**Obtener aprobación del supervisor**”.

Tabla n.º 30. Trazabilidad de los requerimientos

Requerimiento	Estado	Evidencia
Análisis del modelo base	Terminado y presentado	Sección 3.7.1.3 y 3.7.1.4.
Etiquetado manual de imágenes médicas	Terminado y presentado	Sección 3.7.2.1.
Depuración y preprocesamiento del dataset	Terminado y presentado	Sección 3.7.2.2 y 3.7.2.3.
Pruebas al modelo base	Terminado y presentado	Sección 3.7.3.
Desarrollo del frontend de la herramienta	Terminado y presentado	Sección 3.7.5.
Integración modelo-frontend	Terminado y presentado	Sección 3.7.4.

Nota: Elaboración propia (2024).

Todos los requerimientos fueron presentados al supervisor como parte de la entrega final de productos y se recibió la aprobación de estos, como se detalla en el Apéndice H. Minuta 3 – Segunda entrega de productos, lo que permite a otros colaboradores realizar mejoras y actualizaciones de esta, lo que permite continuar con la carga del proyecto en GitHub, GitLab y el servidor “Cedar”.

En cuarto lugar, se muestra de la **Figura n.º 52 a la Figura n.º 54**, la evidencia de que el proyecto que contiene la aplicación desarrollada fue cargado en el servidor “cedar”, GitHub y el GitLab del laboratorio, lo que permite a otros colaboradores realizar mejoras y actualizaciones de esta.


Figura n.º 52 Proyecto en servidor "cedar"



Nota: Elaboración propia (2024).


Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Figura n.º 53 Proyecto en GitHub



Nota: Tomado de GitHub (2024).

Figura n.º 54 Proyecto en GitLab



Nota: Tomado de GitLab (2024).

Para finalizar, al llevar a cabo de todos los pasos para el paso a producción de la herramienta, se recolectaron las siguientes lecciones aprendidas.

- El uso de las plataformas *GitHub* y *GitLab* presenta una opción de colaboración y extensión de la herramienta desarrollada.
- Es importante el almacenamiento del código desarrollado en múltiples repositorios locales y en la nube para evitar la pérdida de información.
- El acatamiento temprano y en regla de los manuales de configuración para el entorno de desarrollo permite ahorrarse tiempo a la hora de pasar a producción las herramientas desarrolladas.

5.3. Análisis de la viabilidad

En la presente sección, se presenta un análisis de viabilidad económica-financiera que se define como “análisis de investigación donde se toma en cuenta todos los factores relevantes que afectan el proyecto para determinar la probabilidad de completar el proyecto con éxito y margen de ganancia” (Wanatot, 2024, párr. 2); así se obtiene prueba de la pertinencia de la solución propuesta.

Debido a la naturaleza del proyecto, los costos que se exponen en la presente sección están relacionados con la manutención y gastos de viaje incurridos por la estudiante para trabajar en el laboratorio y la universidad.

5.3.1. Consideraciones para los cálculos

En este apartado se presentan las consideraciones que son tomadas en cuenta para realizar los cálculos de costos referentes al desarrollo del proyecto.

- El tipo de cambio utilizado para la conversión entre dólares canadienses y dólares americanos es **1 USD = 0,7020 CAD**.
- Se utiliza un máximo de dos decimales en los diferentes cálculos y conversiones de monedas.
- La estudiante contó con una beca económica con un monto de **2.350 USD**, por parte del Instituto Tecnológico de Costa Rica para la compra de los tiquetes aéreos y seguro médico. Asimismo, contó con una beca económica por parte del gobierno canadiense por un monto de **8.200 CAD** para cubrir con los gastos relacionados a la manutención.
- Dentro de los costos se hace una división en dos categorías: costos personales de la estudiante para llevar a cabo el proyecto; y costos relacionados directamente al desarrollo del proyecto. En la primera categoría, se toma en cuenta los tiquetes de avión, hospedaje, alimentación, seguro médico y compra de equipo de cómputo; mientras que para la segunda categoría se toma en cuenta los costos aproximados de las membresías y licencias de los servidores.
- Con respecto a los costos por parte del laboratorio, se toma la decisión de solo adjuntar el costo de los servidores CEDAR y GITLAB; esto debido que para agregar los datos de los servicios públicos se tenían los costos por todas las sedes de la universidad dificultando el cálculo específico del laboratorio o lo utilizado

por la estudiante. Similarmente con los costos de las licencias de Google y Microsoft 365, ya que, la universidad tiene un convenio educacional; debido a esto las licencias son gratis.

- No se toma en cuenta costos relacionados con las tecnologías utilizadas para la elaboración de la aplicación, ya que, tanto *Electron* como *Onnx* son software *open source* y gratis. Además, los costos de equipo del equipo de cómputo utilizado relacionado con el laboratorio se encuentran comprendido en el rubro del servidor CEDAR.

5.3.2. Cálculo de costos

En la **Tabla n.º 31**, se exponen todos aquellos costos incurridos por parte de la estudiante para realizar el proyecto en la universidad Memorial.

Tabla n.º 31. Desglose de costos

Concepto	Costo (CAD)	Costo (USD)
Costos personales de la estudiante		
Tiquetes de avión	\$ 1.752,10	\$ 1.230
Hospedaje (residencia)	\$ 2.310	\$ 1.621,61
Alimentación	\$ 2.915	\$ 2.046,32
Seguro médico extranjero	\$ 261.59	\$ 183.63
Equipo de cómputo	\$ 585	\$ 410,66
Costos para el desarrollo		
Softwares y servidores:	\$5.000 (CEDAR)	\$3.510 (CEDAR)
• Servidor CEDAR	\$165,24 (GITLAB)	\$116 (GITLAB)
• Gitlab		
Total:	\$ 12.988,93	\$ 9.118,22

Nota: Elaboración propia (2024).

En conclusión, el total invertido para el desarrollo del proyecto fue de **\$9.118,22** dólares americanos donde **\$ 5.492,22** dólares americanos son costos relacionados con los gastos personales de la estudiante y **\$3.626** dólares americanos son costos relacionados con el laboratorio.

5.3.3. Beneficios esperados

En este apartado, se desglosan los beneficios esperados por motivo de la implementación de la propuesta de solución, estos beneficios no son cuantificados en términos monetarios debido a que el proyecto fue desarrollado en un ambiente investigativo dentro de un laboratorio universitario, lo cual complica la cuantificación económica.

- Reducción del tiempo de clasificación de TAC que muestran diferentes secciones del cuerpo.
- Reducción del tiempo de análisis e interpretación de los TAC, al obtener una clasificación previa de las imágenes médicas.
- Reducción de la carga de trabajo de los médicos radiólogos, al tener una herramienta que les permite clasificar los TAC, en segundo plano.

6. Conclusiones

En este capítulo se realiza un resumen de los hallazgos y datos relevantes dentro del Análisis de Resultados y la Propuesta de Solución, para así reflejar el cumplimiento de los objetivos definidos.

6.1. Objetivo específico uno

Seleccionar los datos correctos dentro de las bases de datos, para la prueba y entrenamiento del modelo de *Deep Learning*, por medio de la limpieza y clasificación de los registros.

De acuerdo con los resultados obtenidos al aplicar la revisión documental y las reuniones con el supervisor, que permitieron seleccionar la base de datos idónea para las pruebas y entrenamiento del modelo según las necesidades definidas, se concluye lo siguiente:

- Comprender cómo está configurado y cómo funciona el modelo es el primer insumo para realizar la selección de la base de datos óptima para su posterior prueba y entrenamiento, según lo expuesto en la **Sección 4.1.4**.
- La base de datos debe estar compuesta por imágenes de TAC con formato NiFTi, así como contener una cantidad de imágenes mayor a 5000, una cantidad balanceada de imágenes de cada clase y nunca haberse usada en el modelo, como se especifica en la **Sección 4.1.4**.
- Las imágenes dentro de la base de datos fueron pasadas por un preprocesamiento donde se realizó su limpieza, depuración, descarte y corte, obteniendo así las imágenes médicas que fueron utilizadas para realizar las pruebas, según lo estipulado en la **Sección 3.7.1.1** y **Sección Fase 2 - Comprensión y preprocesamiento de datos**
- El resaltado de inconsistencia en la **Sección 4.2.3** dentro de la base de datos permitió tener una visión general de la calidad de esta, con respecto a las necesidades planteadas.
- Se obtuvo un conjunto de alrededor de 5224 datos etiquetados después de realizar el etiquetado manual, según la **Tabla n.º 13**.

6.2. Objetivo específico dos

Desarrollar un modelo de *Deep Learning* que mejore el estado del arte, con el fin de definir el modelo óptimo.

De acuerdo con los diferentes diseños experimentales y tablas de registro realizadas, que permitieron la prueba y entrenamiento del modelo, se concluye que:

- En el proceso de pruebas, es necesario utilizar un *dataset* balanceado para obtener una vista detallada de cómo el modelo se comporta cuando se le presentan imágenes nunca vistas, según los resultados obtenidos en **Tabla n.º 19**.
- El modelo presentó un patrón de error relacionado con la identificación de las clases Pelvis (PLV) y Abdomen-Pelvis (CHA), donde más de la mitad de su *dataset* fue clasificado de manera errónea, lo que sugiere que el modelo encuentra difícil reconocer esas regiones y las confunde con otras, como lo muestra la **Tabla n.º 21**.

- El modelo debe ser entrenado con imágenes de otro *dataset* para evitar el *Overfitting* y mantener un registro del patrón de error con las clases Pelvis (PLV) y Abdomen-Pelvis (CHA), según lo expuesto en la **Sección 3.7.3.5**.
- El modelo óptimo fue seleccionado con base en la versión del modelo que se encontraba estable al momento de terminadas las pruebas realizadas, según lo estipulado en la **Sección 4.3.5**.

6.3. Objetivo específico tres

Evaluar el modelo de *Deep Learning* para la selección del modelo óptimo en términos de precisión, eficiencia y desempeño.

De acuerdo con las tablas de registro presentadas en la **Sección Fase 3 – Modelaje**, que permiten realizar un análisis del desempeño global del modelo, se concluye que:

- Al realizar una comparación entre los porcentajes generales de las métricas de evaluación obtenidos en el estado del arte y los porcentajes obtenidos en las pruebas, se nota que el modelo tiene un desempeño por encima del 75%, según lo mostrado en la **Tabla n.º 19**, lo que se considera aceptable dentro del contexto, según lo expuesto en la **Sección 4.3.5.1**.
- Al analizar los resultados de las métricas para cada una de las clases se confirma que el modelo logra clasificar correctamente las clases CHE, ABP y CAP en la mayoría de los casos probados, como se muestra en la **Tabla n.º 20**, esto permite concluir que el modelo identifica correctamente estas regiones en imágenes nuevas o nunca vistas.

6.4. Objetivo específico cuatro

Implementar una herramienta de escritorio (beta) integrando el modelo de *Deep Learning* seleccionado, que sea accesible y útil al personal médico, para la agilización del proceso de análisis e interpretación de los TAC.

De acuerdo con los diseños experimentales y encuestas realizadas, que permitieron desarrollar la aplicación, así como calificarla, se concluye que:

- La herramienta cumple con todo lo definido y estipulado a nivel funcional en la **Sección 3.7.1.1**, donde se llevó a cabo la recolección de requerimientos.
- El cargar el proyecto a diferentes servidores o ambientes, como se muestra en la **Sección 5.2.5**, permite abrir la puerta a nuevas colaboraciones, posibles mejoras y potenciales identificación de cuellos de botella; así como presenta una agilización en el proceso de introducir la herramienta al mercado.
- Las pruebas realizadas en la **Sección 5.2.4** a la herramienta permite agregar un grado de profesionalismo, calidad y seguridad en su desempeño, al utilizar herramientas como SonarQube, que presenta una opción completa de análisis.

6.5. Objetivo general

Desarrollar una herramienta de escritorio basada en la ejecución de un modelo de *Deep Learning*, utilizando la metodología CRISP-DM, para la automatización del proceso de análisis e interpretación de un TAC por medio de su clasificación, dentro del II semestre del 2024.

De acuerdo con lo expuesto en las **Secciones 1.2.1.** Modalidad del proyecto y **Sección Análisis de** la viabilidad, se concluye que:

- El proyecto llegó a su término de manera satisfactoria, todas las tareas fueron completadas en tiempo; asimismo los resultados presentados fueron aceptados por el supervisor, como se evidencia en la **Sección 5.2.5.**

6.6. Conclusiones sobre la modalidad del proyecto

Estas conclusiones responden a la modalidad del proyecto, su naturaleza, las experiencias vividas, las dificultades, entre otras situaciones experimentadas. Se concluye lo siguiente:

- La exposición a un ambiente multicultural presenta la oportunidad de crecer a nivel interpersonal y permite utilizar las habilidades blandas desarrolladas a lo largo de la carrera.
- La disponibilidad de equipo de cómputo de calidad para el desarrollo y prueba de los diferentes modelos de inteligencia artificial permiten la experimentación libre de nuevas tecnologías sin preocuparse de la demanda computacional.
- La experiencia presenta una oportunidad de conocimiento de nuevas tecnologías, al trabajar en un laboratorio donde cada persona se encuentra desarrollando un proyecto en una rama diferente.
- El ambiente multicultural abre las puertas a crear nuevas conexiones profesionales dentro y fuera de los dominios de la carrera.
- El ambiente de colaboración dentro del laboratorio permitió aplanar la curva de aprendizaje para diferentes tareas dentro del proyecto, al tener compañeros expertos o recursos compartidos para consultar.

7. Recomendaciones

En esta sección se exponen las recomendaciones planteadas posterior a la finalización del proyecto realizado en el laboratorio DIAG, en términos de actualización, extensión o mejora de la herramienta y el modelo utilizado dentro del proyecto, siendo estas:

1. Se insta a plantear, elaborar y ejecutar un plan de pruebas donde esté presente una representación del personal médico, este debido a que aunque el modelo se desarrolla de manera que se adhiera a los contextos reales del flujo de trabajo médico, siempre es una buena práctica obtener el apoyo o la participación de este personal para validar el desempeño del modelo y la aplicación, por ejemplo: validar si las regiones definidas para la clasificación en este modelo son de importancia o deberían ser modificadas; así como si la aplicación desarrollada debería contener nuevas características o mejorar su usabilidad. De esta forma se obtiene retroalimentación que sirve como insumo para futuras mejoras o ampliaciones de las funcionalidades; así como funge como un método de socialización y disminución de la resistencia al cambio a este tipo de tecnologías y herramientas como se menciona en la **Sección 1.3.1**.
2. En una próxima iteración del modelo, se recomienda tomar en cuenta la prueba del modelo con otra configuración de arquitectura como EfficientNET o MobileNETV2 que ya fueron consideradas dentro del modelo que funge como el estado del arte; con el objetivo de mejorar los resultados de desempeño y demanda computacional.
3. Se recomienda realizar un plan de integración y lanzamiento para el software que contendrá todas las herramientas elaboradas hasta el momento para tener una salida al mercado rápida.
4. Se insta a realizar la validación pendiente de los resultados obtenidos en la última prueba del modelo para así proceder con una nueva fase de entrenamiento.
5. El modelo debería tener una fase de entrenamiento enfocada en las clases Pelvis (PLV) y Pecho-Abdomen (CHA), que fueron las que obtuvieron las métricas bajas y la mayor incidencia de clasificaciones erróneas.
6. En la próxima iteración del modelo debería tomarse en cuenta el cambiar la distribución del *dataset*, aumentando el porcentaje de prueba y disminuyendo el porcentaje de validación o plantear una nueva distribución para así validar si el problema de clasificación se sigue manifestando o era cuestión de que el modelo necesitaba una mayor cantidad de datos de prueba o validación.
7. En la próxima iteración del modelo se debería tomar en cuenta la modificación del *learning rate* junto con los *epochs*, ya que en este momento se encuentra en valores mínimos, significando un aprendizaje lento; entonces, si se experimentase con estos valores se tendría la posibilidad de disminuir el porcentaje de error en las clasificaciones.
8. En la próxima iteración o actualización de la herramienta se debería tomar en cuenta otras metodologías y tecnologías que permitan la integración modelo-aplicación de manera sencilla y sin tener que estar cambiando el documento del modelo en el *backend*.
9. Investigar sobre las funcionalidades de *Onnxruntime* para realizar actualizaciones y cargar la herramienta en las tiendas de aplicaciones como *Play Store*, *Apple Store*, entre otros; con aras de hacer la herramienta fácil de distribuir en el futuro.

10. En términos del etiquetado de imágenes, se debería considerar la herramienta WIMARS desarrollada por el laboratorio para automatizar el proceso de etiquetado y enfocarse en la manipulación del modelo, al mismo tiempo que se disminuye los errores humanos.
11. El uso de SonarQube como *software* para analizar el código generado es recomendado para obtener números detallados de cómo mejorar la aplicación, ya que brinda estadísticas del código y permite la trazabilidad de cambios y completitud de los problemas identificados.

8. Referencias

- ¿Qué es Python? - Explicación del lenguaje Python - AWS. (s. f.). Amazon Web Services, Inc. <https://aws.amazon.com/es/what-is/python>
- A. Purbasari, F. R., Rinawan, A., Zulianto, A. I., Susanti, & H. Komara. (2021). CRISP-DM for Data Quality Improvement to Support Machine Learning of Stunting Prediction in Infants and Toddlers. *Paper presented at the 2021 8th International Conference on Advanced Informatics: Concepts, Theory and Applications (ICAICTA)*, 1–6. 10.1109/ICAICTA53211.2021.9640294
- Abd El-Ghany, Sameh & Ramadan, Mai & Alruwaili, Madallah & Elmogy, Mohammed. (2021). Diagnosis of Various Skin Cancer Lesions Based on Fine-Tuned ResNet50 Deep Network. *Computers, Materials & Continua*. 68. 117-135. 10.32604/cmc.2021.016102.
- About DICOM- Overview. (s. f.). DICOM. <https://www.dicomstandard.org/about>
- Annotated Data for AI/ML - The Cancer Imaging Archive (TCIA) Public Access - Cancer Imaging Archive Wiki. (s. f.). <https://wiki.cancerimagingarchive.net/pages/viewpage.action?pageId=59310412>
- Axelrod, G. (2024, 28/03). *More MRI techs needed to combat wait times as burnout figures rise, association says*. <https://www.cbc.ca/news/canada/manitoba/more-mri-techs-need-to-combat-wait-times-1.7157863>. Retrieved 24/09/2024
- B S, Maya & Asha, T. (2018). *Automatic Detection of Brain Strokes in CT Images Using Soft Computing Techniques*. 10.1007/978-3-319-61316-1_5.
- Baba, Y. (2021). *Late arterial phase*. Radiopaedia.org. <https://doi.org/10.53347/rid-91605>
- Baba, Y., Murphy, A. (2023). *Early arterial phase*. Reference article, Radiopaedia.org (Accessed on 28 Oct 2024) <https://doi.org/10.53347/rID-91603>
- Baba, Y., Murphy, A., Haouimi, A., et al. (2023). *Portal venous phase*. Reference article, Radiopaedia.org (Accessed on 28 Oct 2024) <https://doi.org/10.53347/rID-91786>
- Baena Paz, G. (2017). *Metodología de la investigación*. Grupo Editorial Patria.
- Beldar, Mahavir & Rajguru, Swapnil & Suman, Sakshi & Pandey, Shiwanshu & Chavan, Prashant & Patil, Tulshihar. (2023). *A Comparative Analysis For Early Diagnosis of Lung Cancer Detection and Classification By Ct Images Processing Using Resnet-50 Model of Cnn*. 12. 191-201. 10.31838/ecb/2023.12.s3.027.
- Btd. (2024, 7 enero). Performance Insights: Train Loss vs. Test Loss in Machine Learning Models. *Medium*. <https://baotramduong.medium.com/machine-learning-train-loss-vs-test-loss-735ccd713291#:~:text=a.,Definition:,seen%20during%20the%20training%20phase>.
- Build cross-platform desktop apps with JavaScript, HTML, and CSS | Electron. (s. f.). <https://www.electronjs.org/>

- CADTH. (2023). Wait List Strategies for CT and MRI Scans. *Canadian Journal of Health Technologies*, 3(1)10.51731/cjht.2023.557
- Canadian Association of Radiologists. (2019). ENHANCING PATIENT CARE THROUGH MEDICAL IMAGING. En *Canadian Association of Radiologists*. <https://www.ourcommons.ca/Content/Committee/421/FINA/Brief/BR10596272/br-external/CanadianAssociationOfRadiologists-e.pdf>
- Canadian Medical Association (CMA). (2021). *Deloitte. A struggling system: understanding the health care impacts of the pandemic*. Ottawa: The Association; <https://digitallibrary.cma.ca/link/digitallibrary7> (accessed 2024 Nov 8).
- Chia, M. (2020). Development of a delayed chronic subdural hematoma 2 months after mild traumatic brain injury with a normal initial brain computed tomography: A case report. *Journal of the American College of Emergency Physicians Open*. 1. 10.1002/emp2.12198.
- Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., Moore, S., Phillips, S., Maffitt, D., Pringle, M., Tarbox, L., & Prior, F. (2013). The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository. In *Journal of Digital Imaging* (Vol. 26, Issue 6, pp. 1045–1057). Springer Science and Business Media LLC. <https://doi.org/10.1007/s10278-013-9622-7>
- Clínica Universidad de Navarra. (s. f.). *Procedimiento. Diccionario médico*. <https://www.cun.es.https://www.cun.es/diccionario-medico/terminos/procedimiento>.
- Deshpande, A., Estrela, V. V., & Patavardhan, P. (2021). The DCT-CNN-ResNet50 architecture to classify brain tumors with super-resolution, convolutional neural network, and the ResNet50. *Neuroscience Informatics*, 1(4), 100013. 10.1016/j.neuri.2021.100013
- Diccionario de cáncer del NCI. (s. f.). Cancer.gov. <https://www.cancer.gov/espanol/publicaciones/diccionarios/diccionario-cancer/def/tomografia-axial-computarizada>.
- Diwakar, M., & Kumar, M. (2018). A review on CT image noise and its denoising. *Biomed. Signal Process. Control.*, 42, 73-88. <https://doi.org/10.1016/j.bspc.2018.01.010>.
- Duker, A. & Kinderman, D. & Jordan, C. & Niiler, T. & Baker-Smith, C. & Thompson, L. & Parry, D. & Carroll, R. & Bober, M. (2021). Microcephalic osteodysplastic primordial dwarfism type II is associated with global vascular disease. *Orphanet Journal of Rare Diseases*. 16. 10.1186/s13023-021-01852-y.
- Elhadad, A., Jamjoom, M. & Abulkasim, H. (2024). Reduction of NIFTI files storage and compression to facilitate telemedicine services based on quantization hiding of downsampling approach. *Sci Rep* 14, 5168 <https://doi.org/10.1038/s41598-024-54820-4>
- Elpeltagy, M., Sallam, H. *Automatic prediction of COVID– 19 from chest images using modified ResNet50*. *Multimed Tools Appl* 80, 26451–26463 (2021). <https://doi.org/10.1007/s11042-021-10783-6>

- Erickson, B., Korfiatis, P., Akkus, Z., & Kline, T. (2017). *Machine Learning for Medical Imaging. Radiographics: a review publication of the Radiological Society of North America, Inc*, 37 2, 505-515. <https://doi.org/10.1148/rg.2017160130>.
- Faghani, S., Khosravi, B., Zhang, K., Moassefi, M., Jagtap, J. M., Nugen, F., Vahdati, S., Kuanar, S. P., Rassoulinejad-Mousavi, S. M., Singh, Y., Garcia, D. V. V., Rouzrokh, P., & Erickson, B. J. (2022). *Mitigating Bias in Radiology Machine Learning: 3. Performance Metrics. Radiology. Artificial Intelligence*, 4(5). <https://doi.org/10.1148/ryai.220061>
- Florez-Aroni, S., Hancoco-Condori, M., & Torres-Cruz, F. (2023). *Noise Reduction in Medical Images*. ArXiv, abs/2301.01437. <https://doi.org/10.48550/arXiv.2301.01437>.
- Fraenkel, J. R., & Wallen, N. E. (2006). *How to Design and Evaluate Research in Education* (6th ed.). McGraw-Hill.
- García Fenoll, I. (2010). *Aportaciones a la Segmentación y Caracterización de Imágenes Médicas 3D* (Bachillerato).
- Gonsalves, T., & Upadhyay, J. (2021). Chapter Eight - Integrated deep learning for self-driving robotic cars. In R. N. Shaw, A. Ghosh, V. E. Balas & M. Bianchini (Eds.), *Artificial Intelligence for Future Generation Robotics* (pp. 93–118). Elsevier. 10.1016/B978-0-323-85498-6.00010-1
- Guzmán Arias, V. (2015, 12 agosto). *Instrumentos en la investigación cuantitativa*. prezi.com. <https://prezi.com/87o6sp4z0pgm/instrumentos-en-la-investigacion-cuantitativa/>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition*. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1512.03385>
- Healey. (2024, 6 diciembre). Research Guides: Primary Sources: A Research Guide: Primary vs. Secondary. Healey Library. <https://umb.libguides.com/PrimarySources/secondary>.
- Holdsworth, J., & Scapicchio, M. (2024, 17 junio). What is deep learning? *Think*. <https://www.ibm.com/think/topics/deep-learning>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2018). *Densely Connected Convolutional Networks*
- Huérfino, Y., Vera, M., Del Mar, A., Chacón, J., Vera, M., Bautista, N., Martínez, M. S., Rojas, J., Bermúdez, V., Contreras-Velásquez, J., Graterol-Rivas, M., Wilches- Durán, S., Torres, M., Prieto, C., Siguencia, W., Ortiz, R., Aguirre, M., Angarita, L., Cerda, M., Garicano, C., Hernández-Ladinde, J. D., Arias, V., Graterol-Silva, R., Chacín, M. & Bravo, A. (2016). Imagenología médica: Fundamentos y alcance. *Archivos Venezolanos de Farmacología y Terapéutica*, 35(3), 71-76. http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S0798-02642016000300002&lng=es&tlng=es.
- Ibm. (2024, 8 julio). Pytorch. Python. <https://www.ibm.com/es-es/topics/pytorch>
- Ibm. (s. f.). ¿Qué es el deep learning? | IBM. <https://www.ibm.com/es-es/topics/deep-learning>

Instituto Radiológico Providencia. (2024, 26 junio). «TAC con contraste vs. TAC sin contraste: ¿Cuál es la diferencia y por qué es importante el medio de contraste?» - IRP. IRP. <https://irp.cl/tac-con-contraste-vs-tac-sin-contraste-cual-es-la-diferencia-y-por-que-es-importante-el-medio-de-contraste/>

Introducción | Electron. (s. f.). <https://www.electronjs.org/es/docs/latest/>

Ker, J., Wang, L., Rao, J., & Lim, T. (2018). Deep Learning Applications in Medical Image Analysis. *IEEE Access*, 6, 9375-9389. <https://doi.org/10.1109/ACCESS.2017.2788044>.

Lachiner, S. M., & Fernando, H. M. L. (s. f.). *Síndrome de burnout*. https://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S1409-00152015000100014

Lakhani, P., Prater, A., Hutson, R., Andriole, K., Dreyer, K., Morey, J., Prevedello, L., Clark, T., Geis, J., Itri, J., & Hawkins, C. (2017). Machine Learning in Radiology: Applications Beyond Image Interpretation. *Journal of the American College of Radiology: JACR*, 15 2, 350-359. <https://doi.org/10.1016/j.jacr.2017.09.044>.

Leedy, P. D., & Ormrod, J. E. (2015). *Practical Research: Planning and Design*. Pearson.

Liu, Q., Yu, L., Luo, L., Dou, Q., & Heng, P. A. (s. f.) *Semi-supervised Medical Image Classification with Relation-driven Self-ensembling Model*.

Ma, D., Stocks, J., Rosen, H., Kantarci, K., Lockhart, S. N., Bateman, J. R., Craft, S., Gurcan, M. N., Popuri, K., Beg, M. F., & Wang, L. (2024). Differential diagnosis of frontotemporal dementia subtypes with explainable deep learning on structural MRI. *Frontiers in Neuroscience*, 18, 1331677. [10.3389/fnins.2024.1331677](https://doi.org/10.3389/fnins.2024.1331677)

Maya, S. & Asha, T. (2018). *Automatic Detection of Brain Strokes in CT Images Using Soft Computing Techniques*. [10.1007/978-3-319-61316-1_5](https://doi.org/10.1007/978-3-319-61316-1_5).

Membership Application Form | Digital Research Alliance of Canada. (s. f.). Digital Research Alliance Of Canada. <https://alliancecan.ca/en/membership-application-form>

Menaka, R. & Chellamuthu, C. & Ramamurthy, K. (2011). Efficient 3D point cloud generation from medical images in frequency domain using discrete curvelet transform. *European Journal of Scientific Research*. 60. 305-315.

Mirabnahrzham, G., Ma, D., Beaulac, C., Lee, S., Popuri, K., Lee, H., Cao, J., Wang, L., Galvin, J. E., & Beg, M. F. (2022). Predicting Alzheimer's disease progression in healthy and MCI subjects using multi-modal deep learning approach. *Alzheimer's & Dementia*, 18(S2), e060949–n/a. [10.1002/alz.060949](https://doi.org/10.1002/alz.060949)

Mohammadinejad, P., Mileto, A., Yu, L., Leng, S., Guimaraes, L., Missert, A., Jensen, C., Gong, H., McCollough, C., & Fletcher, J. (2021). CT Noise-Reduction Methods for Lower-Dose Scanning: Strengths and Weaknesses of Iterative Reconstruction Algorithms and New Techniques. *Radiographics: a review publication of the Radiological Society of North America, Inc*, 41 5, 1493-1508. <https://doi.org/10.1148/rg.2021200196>.

- Mohammadinejad, P., Mileto, A., Yu, L., Leng, S., Guimaraes, L., Missert, A., Jensen, C., Gong, H., McCollough, C., & Fletcher, J. (2021). CT Noise-Reduction Methods for Lower-Dose Scanning: Strengths and Weaknesses of Iterative Reconstruction Algorithms and New Techniques. *Radiographics: a review publication of the Radiological Society of North America, Inc*, 41 5, 1493-1508. <https://doi.org/10.1148/rg.2021200196>.
- Muhamedrahimov, R., Bar, A., Laserson, J., Akselrod-Ballin, A., & Elnekave, E. (2022). Using Machine Learning to Identify Intravenous Contrast Phases on Computed Tomography. *Computer Methods and Programs in Biomedicine*, 215, 106603. [10.1016/j.cmpb.2021.106603](https://doi.org/10.1016/j.cmpb.2021.106603)
- Muhamedrahimov, R., Bar, A., Laserson, J., Akselrod-Ballin, A., Elnekave, E. Using *Machine Learning to Identify Intravenous Contrast Phases on Computed Tomography*, *Computer Methods and Programs in Biomedicine*, Volume 215, 2022, 106603, ISSN 0169-2607, <https://doi.org/10.1016/j.cmpb.2021.106603>.
(<https://www.sciencedirect.com/science/article/pii/S0169260721006775>)
- Narváez Trejo, O.M. (2007). "Students' expectations of teachers: the case of students at a Mexican university English department". *MEXTESOL Journal*, 32/4, 57-64.
- NIFTI Definition | Encord. (s. f.). [https://encord.com/glossary/nifti-definition/#:~:text=Nifti%20\(short%20for%20%22Neuroimaging%20Informatics,emission%20tomography%20\(PET\)%20scans.](https://encord.com/glossary/nifti-definition/#:~:text=Nifti%20(short%20for%20%22Neuroimaging%20Informatics,emission%20tomography%20(PET)%20scans.)
- Office of the Vice-President (Research) | Office of the Vice-President (Research). (s. f.). Memorial University Of Newfoundland. <https://www.mun.ca/research/who-we-are/office-of-the-vice-president-research/#:~:text=The%20Office%20of%20the%20Vice,research%20activities%20undertaken%20at%20Memorial.>
- ONNX Runtime | Inference. (s. f.). <https://onnxruntime.ai/inference>
- Oscar, E., & Ramos Ponce. *Tema 4: Métricas de Evaluación*.
- Pavadaisamy, G. (2024). *A desktop tool for identifying phases in Contrast-Enhanced Abdominal CT imaging* [Tesis de maestría]. Memorial University
- Personal Health Information Protection Act, 2004, SO 2004, c 3, Sch A, <https://canlii.ca/t/563xm> Recuperado el 07 de junio del 2024.
- Petrella, J., Bachman, D., Tatsuoka, C. DeCarli, C., Cerbone, B., Albert, M., Mesulam, M., Oliver, A., Feldman, H., Borrie, M., Tremont, G., Sadowsky, C., Mathews, D., Levey, A., Rosen, H., Varma, P., Belden, C., Ott, B., Apostolova, D. . . P. (2018). Multimodal and Multiscale Deep Neural Networks for the Early Diagnosis of Alzheimer's Disease using structural MR and FDG-PET images. *Scientific Reports*, 8(1), 5697–13. [10.1038/s41598-018-22871-z](https://doi.org/10.1038/s41598-018-22871-z)
- Portal de Transparencia - El Salvador. (2014). *Procedimiento radiológico*.

- Pretorius, E. S. (2011). Chapter 2 - Introduction to Ultrasound, CT, and MRI. In E. S. Pretorius, & J. A. Solomon (Eds.), *Radiology Secrets Plus (Third Edition)* (pp. 13–18). Mosby. 10.1016/B978-0-323-06794-2.00002-X
- Prokop M, Shin HO, Schanz A, Schaefer-Prokop CM. Use of maximum intensity projections in CT angiography: a basic review. *Radiographics*. 1997 Mar-Apr;17(2):433-51. doi: 10.1148/radiographics.17.2.9084083. PMID: 9084083.
- Rajguru, S., Suman, S., Pandey, S., Beldar, M., Chavan, P., & Patil, T. B. (2022). A comparative analysis for early diagnosis of lung cancer detection and classification by CT images processing using Resnet-50 model of CNN. *European Chemical Bulletin*. <https://doi.org/10.31838/ecb>
- Real Academia Española. *Diccionario de la lengua española*, 23.^a ed., [versión 23.7 en línea]. <<https://dle.rae.es>> [31/10/2024].
- Rouzrokh, P., Khosravi, B., Faghani, S., Moassefi, M., Garcia, D. V. V., Singh, Y., Zhang, K., Conte, G. M., & Erickson, B. J. (2022). *Mitigating Bias in Radiology Machine Learning: 1. Data Handling*. *Radiology. Artificial Intelligence*, 4(5). <https://doi.org/10.1148/ryai.210290>
- Sakly, H., Bjaoui, M., Said, M., Kraiem, N. & Bouhlel, M. S. (2022). Medical decision-Making based on Combined CRISP-DM Approach and CNN Classification for Cardiac MRI. *Paper presented at the 2022 IEEE 9th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT)*, 25–30. 10.1109/SETIT54465.2022.9875820
- Sampieri, R. H., Collado, C. F., Lucio, P. B., Valencia, S. M., & Torres, C. P. M. (2014). *Metodología de la investigación*. McGraw Hill.
- Sanders, C. (2024, Oct 30). *Provincial Tory critic pins increase in CT wait times on NDP's 'reckless' decision to end task force*. Winnipeg Free Press <https://www.proquest.com/docview/3121829999>
- Sarwinda, D., Paradisa, R. H., Bustamam, A., & Anggia, P. (2021). Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer. *Procedia Computer Science*, 179, 423–431. 10.1016/j.procs.2021.01.025
- Seo, H., Khuzani, M., Vasudevan, V., Huang, C., Ren, H., Xiao, R., Jia, X., & Xing, L. (2019). Machine Learning Techniques for Biomedical Image Segmentation: An Overview of Technical Aspects and Introduction to State-of-Art Applications. *Medical physics*, 47 5, e148-e167. <https://doi.org/10.1002/mp.13649>.
- Sharma, T. (2023, 7 marzo). Detailed Explanation of Resnet CNN Model. - TANISH SHARMA - Medium. <https://medium.com/@sharma.tanish096/detailed-explanation-of-residual-network-resnet50-cnn-model-106e0ab9fa9e>
- Shearer, C. (2000) The CRISP-DM Model: The New Blueprint for Data Mining. *Journal of Data Warehousing*, 5, 13-22.

- Shen, D., Wu, G., & Suk, H. (2017). Deep Learning in Medical Image Analysis. *Annual review of biomedical engineering*, 19, 221-248. <https://doi.org/10.1146/annurev-bioeng-071516-044442>.
- Sola, I. (2022, 26 julio). 6 Librerías imprescindibles de Python para Machine Learning. IA SOLVER. <https://iasolver.es/6-librerias-de-python-para-machine-learning/>
- TCIA Programmatic Interface REST API guides - The Cancer Imaging Archive (TCIA) Public access - Cancer Imaging Archive Wiki. (s. f.). <https://wiki.cancerimagingarchive.net/display/Public/TCIA+Programmatic+Interface+REST+API+Guides>
- The Radiology Assistant: CT contrast injection and protocols. (2014, 1 junio). <https://radiologyassistant.nl/more/ct-protocols/ct-contrast-injection-and-protocols>
- Thomas, N. (2019, 13 septiembre). How to use the System Usability Scale (SUS) to evaluate the usability of your website. Usability Geek. <https://usabilitygeek.com/how-to-use-the-system-usability-scale-sus-to-evaluate-the-usability-of-your-website/>
- Tomografía computarizada (TC). (s. f.). National Institute Of Biomedical Imaging And Bioengineering. <https://www.nibib.nih.gov/espanol/temas-cientificos/tomograf%C3%ADa-computarizada-tc>
- Vogt, W. P., & Johnson, R. B. (2016). *Dictionary of Statistics & Methodology: A Nontechnical Guide for the Social Sciences*. Sage Publications.
- Wanatop, S. (2024b, febrero 9). Estudio de viabilidad de un proyecto ¿Cómo realizarlo? INFINITIA Industrial Consulting. <https://www.infinitiaresearch.com/noticias/estudio-de-viabilidad-de-un-proyecto-como-realizarlo/>
- Watson, H. J., Eckerson, W. W., Hanlon, N., Barquin, R., Duncan, K., Flood, D., Goodhue, D., Gray, P., Haisten, M., Klarin, R. M., Piatt, D., Shanks, G., Owens, D. S., Minor, L., Volonino, Wells, D., & Wixom, B. H. *DIRECTOR OF EDUCATION AND RESEARCH*
- What are the key differences between expert and novice users in interface usability testing? (2023, 2 noviembre). [www.linkedin.com. https://www.linkedin.com/advice/0/what-key-differences-between-expert-novice-users-ffkpc](https://www.linkedin.com/advice/0/what-key-differences-between-expert-novice-users-ffkpc).
- Wolterink, J., Leiner, T., Viergever, M., & Išgum, I. (2017). Generative Adversarial Networks for Noise Reduction in Low-Dose CT. *IEEE Transactions on Medical Imaging*, 36, 2536-2545. <https://doi.org/10.1109/TMI.2017.2708987>.
- Yadav, S. S., Jadhav, S. M. Deep convolutional neural network based medical image classification for disease diagnosis. *J Big Data* 6, 113 (2019). <https://doi.org/10.1186/s40537-019-0276-2>
- Yousif, A., Kareem, S., & Mikhail, D. (2023). Computer-aided classification of images containing white blood cells. *International Journal of Nonlinear Analysis and Applications*, 14(1), 2223-2231. doi: 10.22075/ijnaa.2022.7192.

- Zailan, Z. N. I., Mostafa, S. A., Abdulmaged, A. I., Baharum, Z., Jaber, M. M., & Hidayat, R. (2022). Deep Learning Approach for Prediction of Brain Tumor from Small Number of MRI Images. *JOIV: International Journal on Informatics Visualization Online*, 6(2-2), 581–586. 10.30630/joiv.6.2.987
- Zhang, K., Khosravi, B., Vahdati, S., Faghani, S., Nugen, F., Rassoulinejad-Mousavi, S. M., Moassefi, M., Jagtap, J. M. M., Singh, Y., Rouzrokh, P., & Erickson, B. J. (2022). *Mitigating Bias in Radiology Machine Learning: 2. Model Development*. *Radiology. Artificial Intelligence*, 4(5). <https://doi.org/10.1148/ryai.220010>
- Zhao, Mayang & Song, Liming & Zhu, Jiarui & Zhou, Ta & Zhang, Yuanpeng & Chen, Cara Shu Cheng & Li, Haojiang & Cao, Di & Jiang, Yi-Quan & Ho, Waiyin & Cai, Jing & Ren, Ge. (2024). Non-contrasted computed tomography (NCCT) based chronic thromboembolic pulmonary hypertension (CTEPH) automatic diagnosis using cascaded network with multiple instance learning. *Physics in Medicine & Biology*. 69. 10.1088/1361-6560/ad7455.
- Zwanenburg, A., Vallières, M., Abdalah, M. A., Aerts, H. J. W. L., Andrearczyk, V., Apte, A., Ashrafinia, S., Bakas, S., Beukinga, R. J., Boellaard, R., Bogowicz, M., Boldrini, L., Buvat, I., Cook, G. J. R., Davatzikos, C., Depeursinge, A., Desseroit, M., Dinapoli, N., Dinh, C. V., . . . Löck, S. (2020). The Image Biomarker Standardization Initiative: Standardized Quantitative Radiomics for High-Throughput Image-based Phenotyping. *Radiology*, 295(2), 328- 338. <https://doi.org/10.1148/radiol.2020191145>

9. Apéndices

Apéndice A. Cronograma

En la **Figura n.º 55** se presenta el detalle del cronograma de actividades llevadas a cabo dentro del proyecto y las semanas en las que se trabajaron.

Figura n.º 55 Cronograma de trabajo

Cronograma para el desarrollo del proyecto																				
Actividad	Semanas																			
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Reunión inicial con el profesor tutor	■																			
Última versión del anteproyecto	■																			
Inicio del desarrollo de TFG	■																			
Desarrollo de la Fase I: Entendimiento del negocio	■	■	■																	
Desarrollo del Capítulo I del TFG	■	■																		
Correcciones de anteproyecto	■																			
Entrega de I avance		■	■	■	■															
Desarrollo de la Fase II: Compresión y preprocesamiento de datos		■	■	■	■	■														
Correcciones de avance I		■	■	■	■															
Desarrollo del Capítulo II del TFG		■	■	■	■															
Elaboración de Marco Conceptual		■	■	■	■															
Primera evaluación organización y tutor					■															
Entrega de II avance					■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Desarrollo de Fase III: Modelaje					■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Correcciones de avance II					■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Desarrollo de Capítulo III del TFG					■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Definición de la metodología					■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Envío video explicativo profesor lector										■										
Entrega de III avance									■	■	■	■	■	■	■	■	■	■	■	■
Correcciones del III avance									■	■	■	■	■	■	■	■	■	■	■	■
Correcciones de lector académico									■	■	■	■	■	■	■	■	■	■	■	■
Desarrollar el Capítulo IV y V del TFG									■	■	■	■	■	■	■	■	■	■	■	■
Agregar resultados y solución									■	■	■	■	■	■	■	■	■	■	■	■
Entrega de IV avance									■	■	■	■	■	■	■	■	■	■	■	■
Desarrollo de fase IV y V: Actualización y Despliegue									■	■	■	■	■	■	■	■	■	■	■	■
Segunda evaluación organización y tutor											■									
Correcciones IV avance											■	■	■	■	■	■	■	■	■	■
Desarrollo del Capítulo VI del TFG											■	■	■	■	■	■	■	■	■	■
Definición de conclusiones y recomendaciones											■	■	■	■	■	■	■	■	■	■
Entrega de V avance												■	■	■	■	■	■	■	■	■
Correcciones de V avance												■	■	■	■	■	■	■	■	■
Tercer evaluación por organización														■						
Entrega del reporte final (laboratorio)																	■	■	■	■
Entrega de la aplicación (laboratorio)																	■	■	■	■
Entrega de informe final tutor																	■	■	■	■
Entrega del TFG																			■	■
Entrega informe final a Coordinación de TFG																			■	■
Defensas orales y otros trámites																				■

Nota: Elaboración propia (2024).

Apéndice B. Plantilla de minutas

En la **Tabla n.º 32** Plantilla de minuta en español. se presenta la plantilla de minuta para todas las reuniones referentes al proyecto; y en la **Tabla n.º 33** Plantilla de minuta en inglés. se adjunta su versión en inglés para las reuniones con el profesor externo y colaboradores del laboratorio.

Tabla n.º 32. *Plantilla de minuta en español*

ID Reunión:	RE - XX	Fecha:		Horario:	
Objetivo:				Medio:	
Participantes:	Presentes:				
	Ausentes:				
Agenda					
Temas tratados					
No.	Asunto			Comentarios	
Acuerdos					
Responsable	Compromiso asignado			Fecha de entrega	
Próxima reunión					
Temas a tratar		Fecha		Convocados	
Firmas:					

Nota: Elaboración propia (2024).

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Tabla n.º 33. Plantilla de minuta en inglés

Meeting ID:	MEE - XX	Date:		Time:	
Objective:				Platform:	
Participants:	Present:				
	Absent:				
Agenda					
Topics					
No.	Topic	Comments			
Agreements					
Responsible	Assigned commitment	Deadline			
Next meeting					
Topics	Date	Participants			
Signatures:					

Nota: Elaboración propia (2024).

Apéndice C. Plantilla de hoja de cambios

En la **Tabla n.º 34** Plantilla de hoja de cambios. se adjunta la plantilla para la gestión de los cambios del proyecto.

Tabla n.º 34. Plantilla de hoja de cambios

Hoja de control de cambios			
Datos generales de cambio			
Nº cambio:			
Solicitante:		Fecha de solicitud de cambio	
Responsable de la implementación:		Fecha de realización del cambio	
Estado:	☐ Aprobado ☐ En revisión ☐ Rechazado		
Detalles del cambio			
Categoría:			
Descripción detallada:			
Justificación:			
Implicaciones de realizar el cambio:			
Impacto (incluyendo impacto en otras áreas del proyecto):			
Comentarios/Observaciones:			

Revisado por:

Nombre tutor:

Firma:

(Prof. Tutor)

Revisado por:

Nombre representante empresa:

Firma:

(Empresa)

Elaborado por:

Nombre estudiante:

Firma:

(Estudiante)

Aprobado por:

Nombre coordinadora TFG:

Firma:

(Coordinadora de TFG)

Nota: Tomado de la página de insumos y documentos para anteproyecto de la escuela (2024).

Apéndice D. Plantilla de encuesta de satisfacción

En la **Figura n.º 56**, **Figura n.º 57** y **Figura n.º 58** se presenta las preguntas utilizadas para evaluar la satisfacción de los usuarios con la aplicación.

Figura n.º 56 Encuesta de satisfacción - Parte I

Satisfaction's survey

This survey is pretended to know about the user satisfaction with ClassiCTMed.

[Iniciar sesión en Google](#) para guardar lo que llevas hecho. [Más información](#)

* Indica que la pregunta es obligatoria

I am satisfied with my overall experience using the application. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

I think the functionalities of the application are relevant within the context. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

Nota: Elaboración propia (2024).

Figura n.º 57 Encuesta de satisfacción - Parte II

The application performs tasks between a reasonable time and without issues. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

The instructions provided for using the application are clear and easy to follow. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐

The application's data visualization tools (e.g., charts, graphs) are informative and easy to understand. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

The application can potentially improve the efficiency or quality of care in medical tasks. *

1 2 3 4 5

Nota: Elaboración propia (2024).

Figura n.º 58 Encuesta de satisfacción - Parte III

The image shows a digital survey form with a light blue background. It contains two identical-looking question blocks, each with a white background and rounded corners. The first question is "The information displayed is relevant within the context. *". Above the question are five numbers: 1, 2, 3, 4, 5. Below the question are five radio buttons, each aligned with a number. To the left of the first radio button is the text "Strongly disagree" and to the right of the fifth is "Strongly agree". The second question is "The application meets what is expected of it, in visual and functional terms. *". It also has five numbers (1-5) above and five radio buttons below, with "Strongly disagree" on the left and "Strongly agree" on the right. At the bottom left of the form is a blue button with the text "Enviar". At the bottom right is a blue link that says "Borrar formulario".

The information displayed is relevant within the context. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

The application meets what is expected of it, in visual and functional terms. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

Enviar

[Borrar formulario](#)

Nota: Elaboración propia (2024).

Apéndice E. Plantilla de encuesta de usabilidad

En la **Figura n.º 59**, **Figura n.º 60** y **Figura n.º 61** se presenta las preguntas utilizadas para evaluar la satisfacción de los usuarios con la aplicación.

Figura n.º 59 Encuesta de usabilidad - Parte I

Usability's survey

This questions are meant to scale the usability of the tool ClassiCTMed.

[Iniciar sesión en Google](#) para guardar lo que llevas hecho. [Más información](#)

* Indica que la pregunta es obligatoria

I think that I would like to use this system frequently. *

1

2

3

4

5

Strongly disagree

☐

☐

☐

☐

☐

Strongly agree

I found the system unnecessarily complex. *

1

2

3

4

5

Strongly disagree

☐

☐

☐

☐

☐

Strongly agree

I thought the system was easy to use. *

1

2

3

4

5

Nota: Elaboración propia (2024).

Figura n.º 60 Encuesta de usabilidad - Parte II

I think that I would need the support of a technical person to be able to use this system. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

I found the various functions in this system were well integrated. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

I thought there was too much inconsistency in this system. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

I would imagine that most people would learn to use this system very quickly. *

1 2 3 4 5

Nota: Elaboración propia (2024).

Figura n.º 61 Encuesta de usabilidad - Parte III

The image shows a digital survey form with three identical Likert scale questions. Each question is followed by a horizontal row of five radio buttons, numbered 1 to 5. The first question is 'I think that the colors and proportions are correct and legible. *', the second is 'I felt very confident using the system. *', and the third is 'I needed to learn a lot of things before I could get going with this system. *'. The labels 'Strongly disagree' and 'Strongly agree' are positioned at the ends of the radio button rows. At the bottom of the form, there is a blue button labeled 'Enviar' on the left and a blue text link 'Borrar formulario' on the right.

I think that the colors and proportions are correct and legible. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

I felt very confident using the system. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

I needed to learn a lot of things before I could get going with this system. *

1 2 3 4 5

Strongly disagree ☐ ☐ ☐ ☐ ☐ Strongly agree

[Enviar](#) [Borrar formulario](#)

Nota: Elaboración propia (2024).

Apéndice F. Minuta 1 – Recolección de requerimientos

En la **Figura n.º 62**, se presenta el detalle de la minuta relacionada con la recolección de los requerimientos.

Figura n.º 62 Minuta - Recolección de requerimientos

Meeting ID:	ME - 01	Date:	11-09-2024	Time:	12:00 – 12:30 m.d.
Objective:	Discuss the generalities of the project.			Platform:	At the lab.
Participants:	Present:	KarteeK Popuri and Stephanie Valverde Vizcaino.			
	Absent:	None.			
Agenda					
1. Outline the requirements of the project.					
Topics					
No.	Topic	Comments			
1.	Outline the requirements of the project.	The student and professor KarteeK agree on the following requirements for the project: • The first step is to analyze Morteza's model to understand what was developed by him. • Do some labeling of the images in a database Morteza is working on right now. • Perform so preprocessing of the images contain in the database. • Conduct the testing on the model. • Identify error patterns or opportunities for improvement. • Analyze the possibility of retraining or modifying of the model. • Develop of a GUI for the model and perform its respective integration.			
Agreements					
Responsible	Assigned commitment	Deadline			
Stephanie	Start working on the different tasks related to the outlined requirements for the project.	Early December.			
Next meeting					
Topics	Date	Participants			
1. Show the results of the project.	Early December.	• KarteeK Popuri. • Stephanie Valverde.			
Signatures:	  KarteeK Popuri Professor  Stephanie Valverde Vizcaino Student				

Nota: Elaboración propia (2024).

Apéndice G. Minuta 2 – Primera entrega de productos

En la **Figura n.º 63**, se presenta el detalle de la minuta relacionada con la primera entrega de productos.

Figura n.º 63 Minuta - Primera entrega de productos

Meeting ID:	ME - 01	Date:	14-12-2024	Time:	14:00 – 14:30
Objective:	Deliver the products finished by the 13 th of December.			Platform:	Microsoft Teams.
Participants:	Present:	Karteek Popuri and Stephanie Valverde Vizcaino.			
	Absent:	None.			
Agenda					
1. Discuss the status of the project: a. What is finished? b. What is still pending? c. When is the expected end date of the remaining work? d. Reasons for the delay in delivering the final product.					
Topics					
No.	Topic			Comments	
1.	Discuss the status of the project: a. What is finished? b. What is still pending? c. When is the expected end date of the remaining work? d. Reasons for the delay in delivering the final product.			The student starts the meeting remembering the purpose of the meeting, and then start with the different points in the agenda. A. What is finished? R/ The student mentions that the front-end of the desktop tool is finished, in addition she explains that at the moment all the tests on the model have been performed and she is waiting only on Morteza's validation of the results obtained. Also, she mentions that the model has been saved and prepared to configure its integration with the desktop tool. B. What is still pending? R/ The student explain that she lost part of her work regarding the integration between the saved model and the tool. So, she is working on the integration code again with the help of one of the lab members. Additionally, the student mentions that the final report of the project is still pending. On the other hand, the student asks Professor Karteek if there is an activity she may be overlooking, but the professor confirms that what is left is correct. C. When is the expected end date of the remaining work? R/ The student established the first week of January as the end date for the remaining work, giving the student two more weeks to finish her project, and professor Karteek agrees with it. D. Reasons for the delay in delivering the final product. R/ The student explains that she suffers delays due to some server down times, as well as she mentions that her computer died so she lost some of her work. Furthermore, she tried to fix her computer through different means but was unable to improve the situation and she has to wait until she returns to her country to try to fix it.	

Agreements		
Responsible	Assigned commitment	Deadline
Stephanie	- Integrate the Model-API with the Front-end of the desktop tool. - Write the final report on the whole project.	06/01/2025
Next meeting (tentative)		
Topics	Date	Participants
- Receive feedback from the finished product. - Close the project.	06/01/2025	Karteek Popuri and Stephanie Valverde
Signatures:	X  Karteek Popuri Professor X  Stephanie Valverde Vizzalino Student	


Nota: Elaboración propia (2024).

Apéndice H. Minuta 3 – Segunda entrega de productos

En la **Figura n.º 64**, se presenta el detalle de la minuta relacionada con la segunda entrega de productos.

Figura n.º 64 Minuta - Entrega final de productos

Meeting ID:	ME - 02	Date:	08-01-2025	Time:	11:00 – 12:00
Objective:	Present the final product of the project.			Platform:	Microsoft Teams.
Participants:	Present:	Karteek Popuri and Stephanie Valverde Vizcaino.			
	Absent:	None.			
Agenda					
1. Present the final product of the project: a. Show the application's functionalities and format. b. Show the document for the project's report.					
2. Discuss whether the project result is accepted or not.					
Topics					
No.	Topic		Comments		
1.	Present the final product of the project: a. Show the application's functionalities and format. b. Show the document for the project's report.		The student starts the meeting by talking about how she is going to first present the application developed and then talk about the project's report. A. Show the application's functionalities and format. R/ The student begins to show the application, while explaining what each of the different functionalities and navigation of the application does. Next, the student comments that for the Single Classification functionality she decided to add a functionality to see a preview of the image selected for classification along with a small information box on how to interpret the classification result. The professor comments that if possible, it would be important to change the intensity in the image preview settings to make it more readable. Finally, the student explains the Bulk classification functionality (classification of CT scans in a zip) where she mentions that she also added the possibility of seeing a preview of the contents of the selected zip to verify that the correct one was chosen; It also mentions that after the classification, a result of the number of images classified according to the class to which they belong is presented; and finally, there is the button that allows you to download a zip with the classification results. The professor comments that he thinks it is valuable to have the classification results not only in the application, but also to be able to download them in a zip separated by classes. B. Show the document for the project's report. R/ The student tells the professor that to prepare the document she relied on what was done by another colleague in the laboratory, at least, to guide her with the main sections and that from there she created her respective subsections.		

2.	Discuss whether the project result is accepted or not.	To end the meeting, the student asks the professor if the result of the project meets the expectations of the laboratory and him. To which the teacher comments that he does and that it seems very important to have created a functional application. Therefore, the project is accepted by the professor.
Agreements		
Responsible	Assigned commitment	Deadline
Stephanie	Upload the project's code to cedar and GitHub.	-
Signatures:	  Karimok Popuri Professor Stephanie Valverde Vizzini Student	

Nota: Elaboración propia (2024).

Apéndice I. Bitácora de reuniones entre profesor tutor y estudiante.

Para:

Escuela de Administración de Tecnologías de Información

Dr. Isaac Alpízar Chacón

Estimado profesor Isaac,

Por medio de este documento se agrupan y firman las minutas relacionadas con la elaboración del proyecto “Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de *Deep Learning*.”, elaborado por la estudiante Stephanie Valverde Vizcaíno en el laboratorio DIAG del departamento de ciencias de la computación de la universidad Memorial. En la **Tabla n.º 35**, se adjunta el identificador, objetivo, participantes y fecha de cada una de las minutas realizadas a lo largo del proyecto. En caso de necesitar mayor detalle, las minutas se encuentran disponibles en el TEC Digital en la carpeta Minutas Isaac Alpízar → “Minutas Stephanie Valverde” o en nuestra carpeta compartida “Stephanie Deep Learning”.

El profesor Isaac Alpízar Chacón, valida su participación y concuerda con lo discutido en las minutas detalladas en la **Tabla n.º 35**.

Tabla n.º 35. Bitácora de reuniones

Id.	Objetivo	Participantes	Fecha
REU - 01	Discutir sobre la situación actual del proyecto.	Profesor tutor y estudiante.	05-09-2024
REU - 02	Discutir los avances del proyecto, así como las tareas pendientes.	Profesor tutor y estudiante.	12-09-2024
REU - 03	Discutir los avances del proyecto, así como las tareas pendientes.	Profesor tutor y estudiante.	19-09-2024
MEG - 01	Explain to the supervisor of the project how the project is going to be carried out.	Profesor tutor, contraparte de la organización y estudiante.	19-09-2024
REU - 04	Revisar el primer avance correspondiente al Capítulo I.	Profesor tutor y estudiante.	26-09-2024
REU - 05	Revisar la retroalimentación del primer avance correspondiente al Capítulo I – Introducción.	Profesor tutor y estudiante.	03-10-2024
REU - 06	Discutir sobre lo realizado en la semana con respecto al desarrollo del capítulo III referente al Marco Metodológico.	Profesor tutor y estudiante.	10-10-2024
REU - 07	Revisar el trabajo realizado en el capítulo III – Marco Metodológico.	Profesor tutor y estudiante.	17-10-2024

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Id.	Objetivo	Participantes	Fecha
REU - 08	Revisar el trabajo realizado en el capítulo II – Marco Conceptual.	Profesor tutor y estudiante.	25-10-2024
REU - 09	Revisar los comentarios de retroalimentación en los capítulos II y III.	Profesor tutor y estudiante.	01-11-2024
REU - 10	Conversar sobre los avances y situaciones emergentes referentes al desarrollo del proyecto durante la semana.	Profesor tutor y estudiante.	07-11-2024
MEG - 02	Discuss about the student's work so far in the project.	Profesor tutor, contraparte de la organización y estudiante.	07-11-2024
REU - 11	Discutir sobre el futuro actuar para finalizar el producto y el proyecto en el tiempo estipulado.	Profesor tutor y estudiante.	11-11-2024
REU - 12	Discutir sobre el estado general del proyecto y la toma de decisión, con respecto a la extensión de tiempo.	Profesor tutor y estudiante.	21-11-2024
REU - 13	Discutir sobre el avance del proyecto y estado actual del mismo.	Profesor tutor y estudiante.	28-11-2024
REU - 14	Discutir sobre el estado actual del proyecto y la etapa final del mismo.	Profesor tutor y estudiante.	05-11-2024
MEG - 03	Discuss about the student's work in the project and some inconveniences encounter by the student.	Profesor tutor, contraparte de la organización y estudiante.	05-11-2024
REU - 15	Discutir sobre el futuro del proyecto con la vuelta al país de la estudiante.	Profesor tutor y estudiante.	12-12-2024
REU - 16	Conversar y estipular los pasos a seguir por la estudiante para la finalización de su proyecto final.	Profesor tutor y estudiante.	19-12-2024

Nota: Elaboración propia (2024).

X  Digitally signed by ISAAC ALPIZAR CHACON (FIRMA)
Date: 2025.01.19 19:05:42 +01'00'

Isaac Alpizar Chacón
Profesor tutor

X 

Stephanie Valverde Vizcaino
Estudiante

Atentamente, Stephanie Valverde Vizcaino.

Apéndice I. Cronograma de desarrollo de la herramienta

En la **Figura n.º 65** se adjunta las tareas realizadas para el desarrollo de la herramienta junto con su complejidad y la semana del proyecto donde se estuvieron llevando a cabo.

Figura n.º 65 Cronograma de desarrollo de la herramienta

Tarea	Complejidad	Semanas							
		1	2	3	4	5	6	7	8
Selección de las tecnologías a utilizar.	Media								
Diseño (en papel) de la interfaz gráfica.	Baja								
Configuración inicial de la herramienta <i>framework</i> MVC.	Baja								
Programación estética de la interfaz gráfica #1 - Página "About".	Baja								
Programación funcionalidad de la interfaz gráfica #1 - Página "About".	Baja								
Programación estética de la interfaz gráfica #2 - Página "Single Classification".	Media								
Programación de mostrar los resultados de clasificación - Página "Single Classification".	Baja								
Programación estética de la interfaz gráfica #3 - Página "Bulk classification".	Media								
Programación de mostrar los resultados de clasificación - Página "Bulk classification".	Media								
Agregar la funcionalidad de guardar en diferentes carpetas las clasificaciones realizadas.	Alta								
Agregar funcionalidad de previsualización del TAC en la herramienta.	Alta								
Agregar funcionalidad de previsualización de los contenidos del zip en la herramienta.	Media								
Agregar la comunicación entre modelo-herramienta.	Alta								

Nota: Elaboración propia (2024).

Apéndice J. Plantilla de revisión documental.

En la **Tabla n.º 36** se adjunta el detalle de la plantilla utilizada para recolectar información por medio de la revisión documental.

Tabla n.º 36. *Plantilla de revisión documental*

Concepto	Hallazgo/Detalle/Descripción
Concepto 1	
Concepto 2	
Concepto 3	
Concepto 4	
Concepto N	

Nota: Elaboración propia (2024).

Apéndice K. Plantilla de tabla de registro.

En la **Tabla n.º 37** y **Tabla n.º 38** se adjunta la estructura de las diferentes tablas de registro que serán utilizadas para recolectar información.

Tabla n.º 37. *Plantilla de tabla de registro: métricas de evaluación*

Prueba	Dataset	Exactitud	Precisión	Recall	F1-score	Desempeño	Pérdida de prueba
Prueba 1							
Prueba N							

Nota: Elaboración propia (2024).

Tabla n.º 38. *Plantilla de tabla de registro: información de pruebas*

Prueba	Concepto/Característica 1	Concepto/Característica N
Prueba 1		
Prueba 2		
Prueba N		

Nota: Elaboración propia (2024).

10. Anexos

Anexo I. Detalle de las clasificaciones erróneas

De la **Figura n.º 66 a la Figura n.º 68**, se adjuntan los detalles de aquellos TAC que fueron clasificados de manera errónea por el modelo en las diferentes pruebas realizadas.

Figura n.º 66 Detalle de las clasificaciones erróneas en las pruebas 2 y 3.

ID	Filename	Predicted Label	True Label
0	13026901_302690-scan_2	4	5
1	13023051_302305-scan_3	4	5
2	13025511_302551-scan_1	4	2
3	13029661_302966-scan_1	4	1
4	13029651_302965-scan_1	4	1
5	13019872_301987-scan_1	2	5
6	13027611_302761-scan_2	4	5
7	13029591_302959-scan_1	0	3
8	13027881_302788-scan_1	4	5
9	13027471_302747-scan_1	5	3

ID	Predicted Label	True Label
0	3	0
1	2	1
2	2	1
3	2	1
4	4	1
5	4	2
6	4	2
7	4	2
8	0	3
9	5	4
10	5	4
11	5	4
12	0	5
13	2	5
14	2	5
15	2	5
16	2	5
17	3	5
18	3	5
19	3	5
20	4	5
21	4	5
22	4	5

Nota: Extraído del resultado de la prueba (2024).

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Figura n.º 67 Detalle de las clasificaciones erróneas en la prueba 4.

ID	Filename	Predicted Label	True Label
0	13023681_302368-scan_2	0	5
1	13029661_302966-scan_1	4	1
2	13000641_300064-scan_1	4	2
3	13024781_302478-scan_1	1	4
4	129221_2922-scan_3	0	1
5	13026901_302690-scan_2	4	5
6	13019872_301987-scan_1	2	5
7	108391_839-scan_2	0	3
8	13018991_301899-scan_2	4	5
9	13024961_302496-scan_2	3	0
10	13008571_300857-scan_2	0	3
11	108771_0877-scan_2	0	3
12	119301_1930-scan_1	0	3
13	108621_862-scan_2	0	3
14	13004411_300441-scan_1	4	2
15	119551_1955-scan_1	4	2
16	108801_880-scan_2	0	3
17	13029791_302979-scan_1	4	1
18	108951_0895-scan_1	0	3
19	13025691_302569-scan_3	4	5
20	13011461_301146-scan_1	1	3
21	13008271_300827-scan_2	0	3
22	13009851_300985-scan_2	0	3
23	13005851_300585-scan_1	0	3
24	13024961_302496-scan_1	3	0
25	116441_1644-scan_2	0	3
26	13006481_300648-scan_1	0	3
27	13001661_300166-scan_3	0	1
28	13005091_300509-scan_2	0	3
29	13009311_300931-scan_1	0	3
30	13027611_302761-scan_2	4	5
31	13026361_302636-scan_3	3	0
32	104791_479-scan_2	0	3
33	13016132_301613-scan_3	4	5
34	13019361_301936-scan_1	5	4
35	13003221_300322-scan_2	4	2
36	13004061_300406-scan_1	4	2
37	13026521_302652-scan_1	5	4
38	13009351_300935-scan_2	1	0
39	13012361_301236-scan_2	0	3
40	103841_0384-scan_1	0	1
41	13001531_300153-scan_1	0	3

Nota: Extraído del resultado de la prueba (2024).

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

Figura n.º 68 Detalle de las clasificaciones erróneas en prueba 5


ID	Filename	Predicted Label	True Label	ID	Filename	Predicted Label	True Label	ID	Filename	Predicted Label	True Label	ID	Filename	Predicted Label	True Label
0	126691_2669-scan_1	5	2	42	103741_374-scan_2	5	3	83	104711_471-scan_1	5	3	121	122561_2256-scan_1	5	3
1	122171_2217-scan_1	5	3	43	112871_1287-scan_1	5	3	84	13007021_30	5	2	122	125971_2597-scan_1	4	1
2	102631_0263-scan_1	5	3	44	13010121_301012-scan_1	5	2	85	13011921_30	5	2	123	13010241_30	5	2
3	13004411_300441-scan_1	4	2	45	13000481_300048-scan_2	4	2	86	13010361_30	5	2	124	13010961_30	5	2
4	124031_2403-scan_3	5	3	46	13004791_300479-scan_2	5	2	87	13008941_30	0	3	125	13016441_30	3	0
5	129631_2963-scan_1	5	2	47	13010961_301096-scan_2	5	2	88	13010291_30	0	3	126	13011271_30	0	1
6	108951_0895-scan_1	0	3	48	13003801_300380-scan_3	5	2	89	115941_1594-scan_1	5	3	127	108391_839-scan_1	0	3
7	13008481_300848-scan_1	5	2	49	125491_2549-scan_3	5	3	90	13008601_30	0	3	128	13010461_30	5	2
8	123551_2355-scan_2	1	3	50	13008871_300887-scan_3	0	3	91	13005301_30	0	3	129	104101_410-scan_1	5	3
9	13012531_301253-scan_1	0	3	51	125781_2578-scan_1	5	3	92	13013571_30	5	2	130	13027601_30	4	2
10	124321_2432-scan_3	1	3	52	126861_2686-scan_1	5	2	93	13018991_30	4	5	131	13009311_30	0	3
11	109381_938-scan_1	5	3	53	13009751_300975-scan_2	0	3	94	129691_2969-scan_1	5	2	132	110101_1010-scan_1	0	3
12	13013171_301317-scan_1	5	2	54	125951_2595-scan_1	5	3	95	13008201_30	5	2	133	13015111_30	4	5
13	128091_2809-scan_2	5	2	55	119301_1930-scan_2	5	3	96	13004711_30	4	1	134	13011491_30	0	3
14	13003221_300322-scan_2	4	2	56	13024781_302478-scan_1	1	4	97	122101_2210-scan_1	5	3	135	122121_2122-scan_1	5	3
15	13008871_300887-scan_1	5	2	57	13011111_301111-scan_2	5	2	98	13002451_30	5	2	136	13005671_30	2	1
16	13009851_300985-scan_2	0	3	58	13012661_301266-scan_1	5	2	99	13005301_30	4	2	137	124551_2455-scan_1	5	3
17	13014471_301447-scan_3	5	2	59	13010741_301074-scan_2	5	2	100	13014081_30	4	2	138	101471_147-scan_1	5	3
18	13005851_300585-scan_1	0	3	60	128451_2845-scan_2	1	2	101	13013621_30	5	2	139	124961_2496-scan_1	4	1
19	13012531_301253-scan_2	5	2	61	13022461_302246-scan_1	0	3	102	13013101_30	0	3	140	123631_2363-scan_1	5	3
20	13008571_300857-scan_2	0	3	62	13004821_300482-scan_2	0	3	103	13010901_30	5	2	141	108771_0877-scan_1	0	3
21	120481_2048-scan_1	5	3	63	116501_1650-scan_2	1	3	104	122271_2227-scan_1	5	3	142	13008301_30	5	2
22	108771_0877-scan_1	5	3	64	13011091_301109-scan_1	5	2	105	13012551_30	5	2	143	125181_2518-scan_1	5	3
23	123671_2367-scan_1	5	3	65	13008901_300890-scan_1	0	3	106	13014111_30	4	2	144	13014631_30	5	2
24	13019872_301987-scan_1	2	5	66	13009521_300952-scan_5	5	2	107	13012361_30	0	3	145	127851_2785-scan_1	4	2
25	13009541_300954-scan_1	4	2	67	117491_1749-scan_1	0	3	108	13001661_30	0	1	146	109481_948-scan_1	4	1
26	119151_1915-scan_2	5	3	68	13011331_301133-scan_3	5	2	109	13027471_30	5	3	147	13009671_30	5	2
27	123591_2359-scan_1	5	3	69	121011_2101-scan_1	5	3	110	125121_2512-scan_1	5	3	148	13010671_30	5	2
28	13002611_300261-scan_3	5	2	70	13002391_300239-scan_1	4	2	111	13029691_30	4	1	149	114511_1451-scan_1	5	3
29	13012771_301277-scan_2	0	3	71	13006401_300640-scan_2	0	3	112	127131_2713-scan_1	5	2	150	13011091_30	0	3
30	13023681_302368-scan_1	5	4	72	109591_0959-scan_1	5	3	113	13002831_30	5	2	151	100321_32-scan_1	2	3
31	128941_2894-scan_3	5	2	73	129631_2963-scan_3	4	2	114	13016311_30	4	5	152	13010741_30	5	2
32	129781_2978-scan_1	4	2	74	13011471_301147-scan_2	5	2	115	110191_1019-scan_1	5	3	153	13000181_30	5	2
33	117421_1742-scan_3	5	3	75	13025212_302521-scan_1	3	5	116	13003851_30	4	2	154	13003221_30	4	2
34	107931_793-scan_2	5	3	76	13003141_300314-scan_2	5	2	117	13026361_30	3	0	155	13024941_30	1	4
35	13012321_301232-scan_2	0	3	77	13010291_301029-scan_2	5	2	118	13029001_30	4	1	156	111451_1145-scan_1	5	3
36	13012771_301277-scan_1	5	2	78	116051_1605-scan_3	5	3	119	127731_2773-scan_1	5	2	157	13008381_30	5	2
37	13011161_301116-scan_1	4	2	79	13006371_300637-scan_2	5	2	120	13010581_30	5	2	158	113511_1351-scan_1	4	1
38	121651_2165-scan_2	1	3	80	13013871_301387-scan_1	5	2					159	13028092_30	2	5
39	13013191_301319-scan_1	5	2												
40	13028821_302882-scan_1	2	1												
41	13009521_300952-scan_3	5	2												

Nota: Extraído del resultado de la prueba (2024).

Anexo II. Matrices de confusión


De la **Figura n.º 69 a la Figura n.º 72**, se adjuntan las matrices de confusión como resultado de las pruebas realizadas al modelo.

Figura n.º 69 Matriz de confusión de Prueba 2




Nota: Extraído del resultado de la prueba (2024).

Figura n.º 70 Matriz de confusión de la prueba 3.




Nota: Extraído del resultado de la prueba (2024).

Figura n.º 71 Matriz de confusión de prueba 4



Nota: Extraído del resultado de la prueba (2024).

Figura n.º 72 Matriz de confusión de prueba 5



Nota: Extraído del resultado de la prueba (2024).

Anexo III. Detalle de prueba: recursos computacionales

A continuación, se adjunta el detalle de la prueba realizada para medir el uso de recursos computacionales de la herramienta desarrollada, donde se obtiene el tipo de proceso, el identificador del proceso, el uso del CPU y el uso de memoria.

-----	CPU Usage: 0%	-----
Process Type: GPU	Memory Usage: 350900 KB	Process Type: Utility
PID: 14280		PID: 6152
CPU Usage: 0%	-----	CPU Usage: 0%
Memory Usage: 350900 KB	Process Type: Utility	Memory Usage: 39112 KB
	PID: 6152	-----
-----	CPU Usage: 0%	Process Type: Tab
Process Type: Utility	Memory Usage: 39112 KB	PID: 16404
PID: 6152	-----	CPU Usage: 0%
CPU Usage: 0%	Process Type: Tab	Memory Usage: 79964 KB
Memory Usage: 39112 KB	PID: 16404	-----
-----	CPU Usage: 0%	App Metrics:
Process Type: Tab	Memory Usage: 79964 KB	Process Type: Browser
PID: 16404	-----	PID: 8748
CPU Usage: 0%	App Metrics:	CPU Usage: 0%
Memory Usage: 79964 KB	Process Type: Browser	Memory Usage: 411464 KB
-----	PID: 8748	-----
App Metrics:	CPU Usage: 0%	
Process Type: Browser	Memory Usage: 411452 KB	Process Type: GPU
PID: 8748		PID: 14280
CPU Usage: 0%	-----	CPU Usage: 0%
Memory Usage: 411440 KB	Process Type: GPU	Memory Usage: 350900 KB
	PID: 14280	-----
-----	CPU Usage: 0%	
Process Type: GPU	Memory Usage: 350900 KB	Process Type: Utility
PID: 14280		PID: 6152

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

CPU Usage: 0%	Memory Usage: 79964 KB	CPU Usage: 0.3122785944765161%
Memory Usage: 39112 KB	-----	Memory Usage: 411536 KB
-----	App Metrics:	-----
Process Type: Tab	Process Type: Browser	-----
PID: 16404	PID: 8748	Process Type: GPU
CPU Usage: 0%	CPU Usage: 0%	PID: 14280
Memory Usage: 79964 KB	Memory Usage: 411492 KB	CPU Usage: 0%
-----	-----	Memory Usage: 350900 KB
App Metrics:	Process Type: GPU	-----
Process Type: Browser	PID: 14280	Process Type: Utility
PID: 8748	CPU Usage: 0%	PID: 6152
CPU Usage: 0%	Memory Usage: 350900 KB	CPU Usage: 0%
Memory Usage: 411480 KB	-----	Memory Usage: 39112 KB
-----	Process Type: Utility	-----
Process Type: GPU	PID: 6152	Process Type: Tab
PID: 14280	CPU Usage: 0%	PID: 16404
CPU Usage: 0%	Memory Usage: 39112 KB	CPU Usage: 0%
Memory Usage: 350900 KB	-----	Memory Usage: 79964 KB
-----	Process Type: Tab	-----
Process Type: Utility	PID: 16404	App Metrics:
PID: 6152	CPU Usage: 0%	Process Type: Browser
CPU Usage: 0%	Memory Usage: 79964 KB	PID: 8748
Memory Usage: 39112 KB	-----	CPU Usage: 0%
-----	App Metrics:	Memory Usage: 411552 KB
Process Type: Tab	Process Type: Browser	-----
PID: 16404	PID: 8748	Process Type: GPU
CPU Usage: 0%		

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

PID: 14280	Process Type: GPU	Process Type: Utility
CPU Usage: 0%	PID: 14280	PID: 6152
Memory Usage: 350900 KB	CPU Usage: 0%	CPU Usage: 0%
-----	Memory Usage: 350900 KB	Memory Usage: 39112 KB
Process Type: Utility	-----	-----
PID: 6152	Process Type: Utility	Process Type: Tab
CPU Usage: 0%	PID: 6152	PID: 16404
Memory Usage: 39112 KB	CPU Usage: 0%	CPU Usage: 0%
-----	Memory Usage: 39112 KB	Memory Usage: 79968 KB
Process Type: Tab	-----	-----
PID: 16404	Process Type: Tab	App Metrics:
CPU Usage: 0%	PID: 16404	Process Type: Browser
Memory Usage: 79964 KB	CPU Usage: 0%	PID: 8748
-----	Memory Usage: 79968 KB	CPU Usage: 0%
App Metrics:	-----	Memory Usage: 408456 KB
Process Type: Browser	App Metrics:	-----
PID: 8748	Process Type: Browser	Process Type: GPU
CPU Usage: 0%	PID: 8748	PID: 14280
Memory Usage: 411564 KB	CPU Usage: 0%	CPU Usage: 0%
-----	Memory Usage: 408444 KB	Memory Usage: 350900 KB
App Metrics:	-----	-----
Process Type: Browser	Process Type: GPU	Process Type: Utility
PID: 8748	PID: 14280	PID: 6152
CPU Usage: 0%	CPU Usage: 0%	CPU Usage: 0%
Memory Usage: 408420 KB	Memory Usage: 350900 KB	Memory Usage: 39112 KB
-----	-----	-----
		Process Type: Tab

Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

PID: 16404	PID: 8748	PID: 14280
CPU Usage: 0%	CPU Usage: 0%	CPU Usage: 0%
Memory Usage: 79968 KB	Memory Usage: 408484 KB	Memory Usage: 350900 KB
-----	-----	-----
App Metrics:		
Process Type: Browser	Process Type: GPU	Process Type: Utility
PID: 8748	PID: 14280	PID: 6152
CPU Usage: 0%	CPU Usage: 0%	CPU Usage: 0%
Memory Usage: 408468 KB	Memory Usage: 350900 KB	Memory Usage: 39112 KB
-----	-----	-----
Process Type: GPU	Process Type: Utility	Process Type: Tab
PID: 14280	PID: 6152	PID: 16404
CPU Usage: 0%	CPU Usage: 0%	CPU Usage: 0%
Memory Usage: 350900 KB	Memory Usage: 39112 KB	Memory Usage: 79968 KB
-----	-----	-----
Process Type: Utility	Process Type: Tab	App Metrics:
PID: 6152	PID: 16404	Process Type: Browser
CPU Usage: 0%	CPU Usage: 0%	PID: 8748
Memory Usage: 39112 KB	Memory Usage: 79968 KB	CPU Usage: 0%
-----	-----	Memory Usage: 408512 KB
Process Type: Tab	App Metrics:	-----
PID: 16404	Process Type: Browser	Process Type: GPU
CPU Usage: 0%	PID: 8748	PID: 14280
Memory Usage: 79968 KB	CPU Usage: 0%	CPU Usage: 0%
-----	Memory Usage: 408496 KB	Memory Usage: 350900 KB
App Metrics:	-----	-----
Process Type: Browser	Process Type: GPU	Process Type: Utility



Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

PID: 6152	CPU Usage: 0%	Memory Usage: 39112 KB
CPU Usage: 0%	Memory Usage: 39112 KB	-----
Memory Usage: 39112 KB	-----	Process Type: Tab
-----	Process Type: Tab	PID: 16404
Process Type: Tab	PID: 16404	CPU Usage: 0%
PID: 16404	CPU Usage: 0.9366863941979996%	Memory Usage: 80416 KB
CPU Usage: 0%	Memory Usage: 80956 KB	-----
Memory Usage: 79968 KB	-----	App Metrics:
-----	App Metrics:	Process Type: Browser
App Metrics:	Process Type: Browser	PID: 8748
Process Type: Browser	PID: 8748	CPU Usage: 1.188761430416658%
PID: 8748	CPU Usage: 0.31146481553907435%	Memory Usage: 408380 KB
CPU Usage: 1.2489246758540897%	Memory Usage: 408564 KB	-----
Memory Usage: 408576 KB	-----	Process Type: GPU
-----	Process Type: GPU	PID: 14280
Process Type: GPU	PID: 14280	CPU Usage: 0.14859526359135494%
PID: 14280	CPU Usage: 0%	Memory Usage: 349800 KB
CPU Usage: 1.2489226792968386%	Memory Usage: 349496 KB	-----
Memory Usage: 350580 KB	-----	Process Type: Utility
-----	Process Type: Utility	PID: 6152
Process Type: Utility	PID: 6152	CPU Usage: 0%
PID: 6152	CPU Usage: 0%	Memory Usage: 39112 KB

Anexo IV. Respuestas encuesta de satisfacción


En la **Figura n.º 73** se exponen las respuestas obtenidas en la encuesta relacionada con la usabilidad general de la aplicación.

Figura n.º 73 Resumen de respuestas - Encuesta de satisfacción




The instructions provided for using the application are clear and easy to follow.

1 respuesta




The application's data visualization tools (e.g., charts, graphs) are informative and easy to understand.

1 respuesta




The application can potentially improve the efficiency or quality of care in medical tasks.

1 respuesta




The information displayed is relevant within the context.

1 respuesta



Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de Deep Learning.

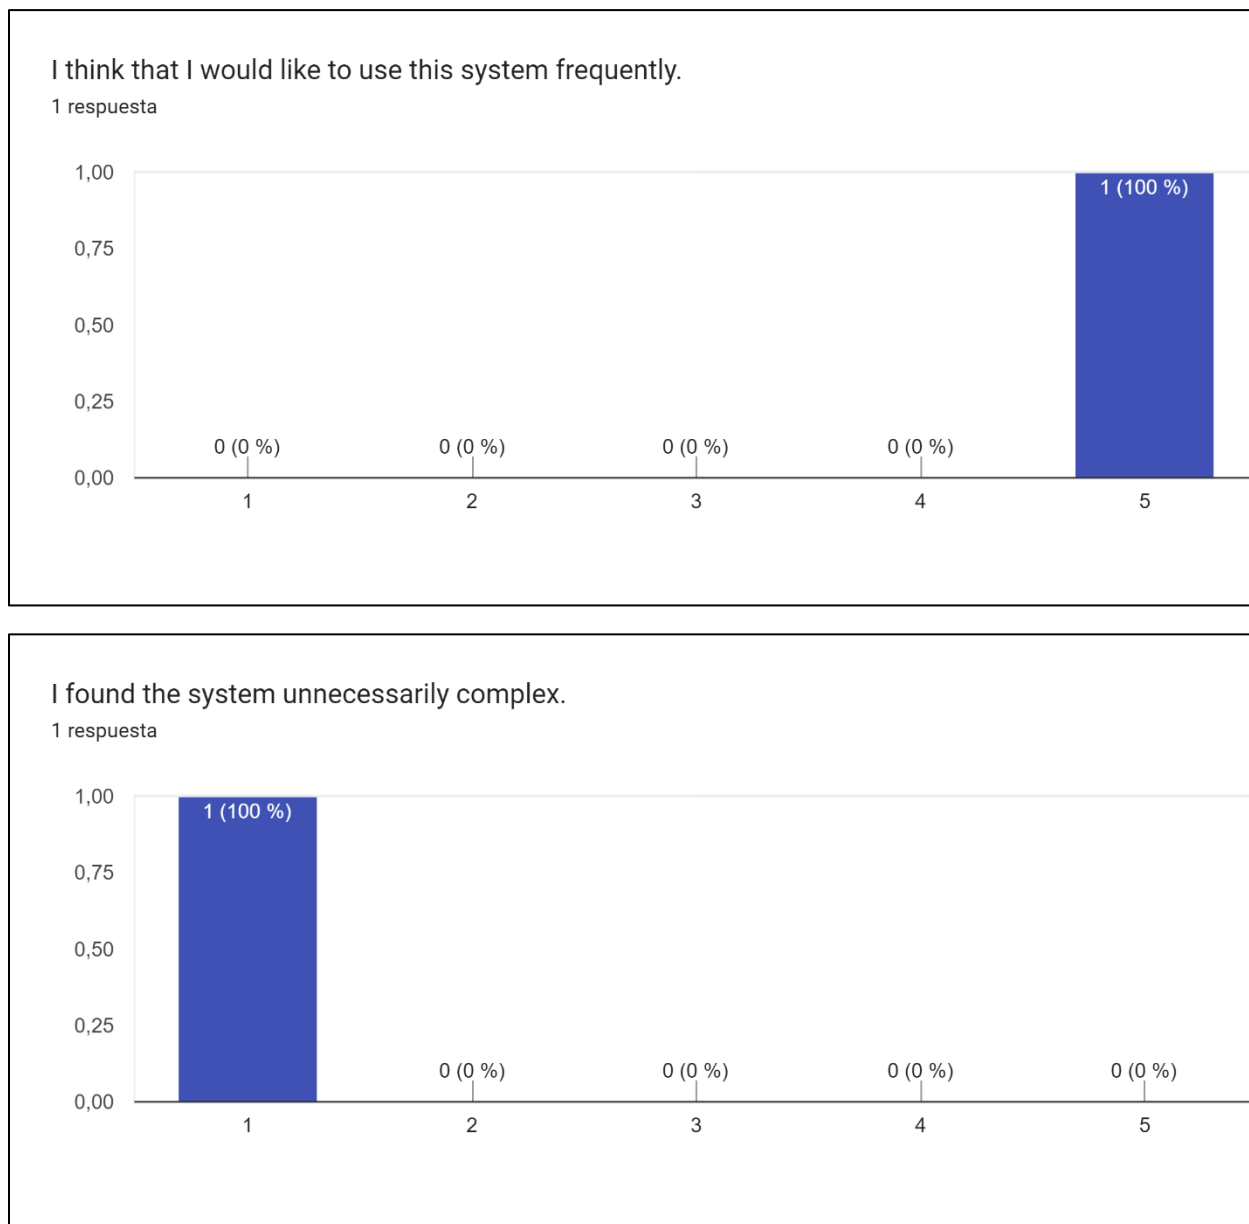


Nota: Resumen de Google Forms (2024).

Anexo V. Respuestas de encuesta de usabilidad


En la **Figura n.º 74** se exponen las respuestas obtenidas en la encuesta relacionada con la usabilidad general de la aplicación.

Figura n.º 74 Resumen de respuestas - Encuesta usabilidad




I thought the system was easy to use.

1 respuesta




I think that I would need the support of a technical person to be able to use this system.

1 respuesta




I found the various functions in this system were well integrated.

1 respuesta




I thought there was too much inconsistency in this system.

1 respuesta




I would imagine that most people would learn to use this system very quickly.

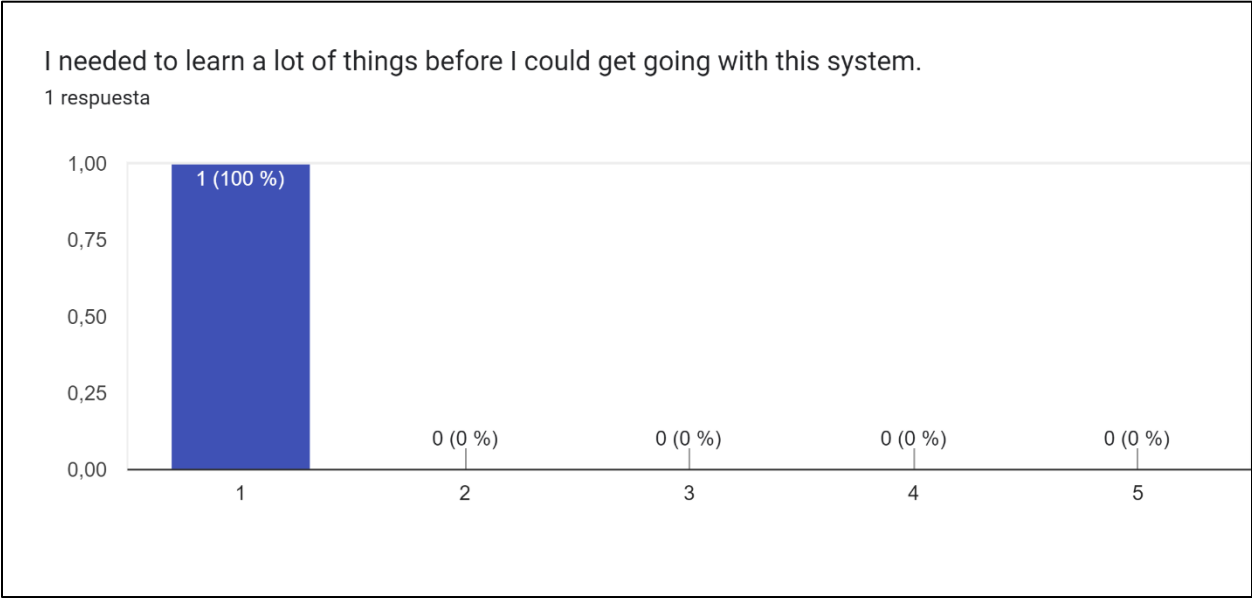

1 respuesta



I think that the colors and proportions are correct and legible.

1 respuesta





Nota: Resumen de Google Forms (2024).

Anexo VI. Carta de revisión filológica.

A continuación, en la **Figura n.º 75** Carta de revisión de la filóloga, se adjunta la carta brindada por la filóloga que realizó la revisión del documento, en términos de escritora y formato.

Figura n.º 75 Carta de revisión de la filóloga.

20 de enero de 2025

Señores
Escuela de Administración de Tecnologías de Información
Tecnológico de Costa Rica

Estimados señores:

Leí y corregí el documento denominado: "Desarrollo de una herramienta de escritorio para la automatización del proceso de análisis e interpretación de tomografías axiales computarizadas (TAC) mediante la aplicación de un modelo de *Deep Learning*", elaborado por la estudiante Stephanie Valverde Vizcaino, para optar por el grado de Licenciatura en Administración de Tecnologías de Información.

Corregí el trabajo en aspectos tales como: construcción de párrafos, vicios del lenguaje que se trasladan a lo escrito, ortografía, puntuación y otros relacionados con el campo filológico, y desde ese punto de vista considero que está listo para ser presentado como Trabajo Final de Graduación, por cuanto cumple con los requisitos establecidos.

Cordialmente,

GINETTE
FONSECA
VARGAS (FIRMA)

Firmado digitalmente
por GINETTE FONSECA
VARGAS (FIRMA)
Fecha: 2025.01.20
15:28:28 -06'00'

Lcda. Ginette Fonseca Vargas
Filóloga
Camé: 10993

Nota: Elaboración propia (2024).