

Programa informático de apoyo para la evaluación del desarrollo de tumores mediante el método RECIST aplicando procesamiento digital de imágenes biomédicas a través de inteligencia artificial

Presentado por:

Johan Steven Ballesteros Rincón

Oskar Daliegt Guzmán Trillos

Códigos:

U00122462

U00123074

Director:

M.C. Oscar Mauricio Gelvez Lizarazo

Codirector:

M.I. Manuel Hernando Franco Arias

Universidad Autónoma de Bucaramanga

Facultad de Ingeniería

Programa de Ingeniería Biomédica

Bucaramanga

2022

Resumen

El presente proyecto comprende el desarrollo de un programa informático de apoyo para la evaluación del desarrollo de tumores mediante el método RECIST aplicando procesamiento digital de imágenes biomédicas, a fin de secundar el diagnóstico del especialista en salud según los criterios del método ya mencionado. En cumplimiento del objetivo principal, se realizó el entrenamiento de una inteligencia artificial a través de redes neuronales convolucionales (CNN), la cual fue entrenada por medio de tomografías computacionales (CT) y máscaras de segmentación correspondientes al hígado, obtenidas de la base de datos del Decatlón de segmentación médica (MSD), así como el respectivo desarrollo de una interfaz gráfica de usuario (GUI) en la que se implementaron los criterios correspondientes a RECIST 1.1, todo realizado en el lenguaje de código abierto Python, con lo que se obtuvo una exactitud del 97,21%.

Abstract

This project includes the development of a computer support program for the evaluation of tumor development using the RECIST method applying digital processing of biomedical images, in order to support the diagnosis of the health specialist according to the criteria of the aforementioned method. In fulfillment of the main objective, the training of an artificial intelligence was carried out through convolutional neural networks (CNN), which was trained by means of computational tomography (CT) and segmentation masks corresponding to the liver, obtained from the database of the Medical Segmentation Decathlon (MSD), as well as the respective development of a graphical user interface (GUI) in which the criteria corresponding to RECIST 1.1 were implemented, all done in the open source language Python, which obtained an accuracy of 97.21%.

Agradecimientos

Inicialmente, quiero darle las gracias a mis padres por haberme brindado su apoyo y motivación incondicional en el camino que he recorrido para llegar a este punto, agradezco igualmente a mis hermanos y abuelos por aquellas palabras de aliento que me guiaron y aconsejaron, a la familia Ovalle quienes me acogieron como un hijo más, brindándome toda su ayuda con el fin de cumplir esta meta. Agradezco a mi amigo Julián por la compañía brindada en estos años, evitando así que desfalleciera en mi desarrollo como profesional. Agradezco inmensamente a mi perrita Niuska, mi gran amor, por alegrar mis días, por ayudarme a levantar en aquellos momentos que llegue a ser débil, por su cariño brindado, acciones comunes que me marcaron y motivaron a seguir hacia delante.

Agradezco al docente Oscar Mauricio por sus consejos y guía, los cuales lograron hacer de este proyecto una realidad, así como el apoyo del asesor externo del proyecto, Carlos Andrés Arias Duran. Finalmente, doy las gracias al cuerpo docente de la Universidad Autónoma de Bucaramanga, el cual me educo y oriento, haciendo de mí una persona responsable, respetuosa y profesional en el ejercicio de distintas actividades.

Johan Steven Ballesteros Rincón

Agradecimientos

Dedico este libro a mi familia, quienes con su amor y apoyo incondicional me ayudaron a lograr este objetivo de vida, siendo uno de los motivos principales para convertir mi sueño en realidad. También a todas las personas que estuvieron cerca dándome sus palabras de motivación y gracias a la vida por permitirme vivir esta experiencia.

Oskar Daliegt Guzmán Trillos

Lista de contenido

| | |
|---|-----------|
| Resumen..... | 2 |
| Abstract..... | 3 |
| Agradecimientos..... | 4 |
| Lista de contenido | 6 |
| Lista de imágenes | 9 |
| Lista de tablas..... | 11 |
| Lista de ecuaciones..... | 12 |
| Lista de diagramas..... | 13 |
| Lista de gráficas | 14 |
| Capítulo 1..... | 17 |
| 1.1. Planteamiento del problema..... | 17 |
| 1.2. Justificación del problema..... | 18 |
| 1.3. Pregunta de investigación | 20 |
| 1.4. Objetivos | 20 |
| <i>1.4.1. Objetivo general.....</i> | <i>20</i> |
| <i>1.4.2. Objetivos específicos</i> | <i>20</i> |
| Capítulo 2..... | 21 |
| 2.1. Marco teórico..... | 21 |
| <i>2.1.1. Evaluación en respuesta tumoral</i> | <i>21</i> |
| 2.1.1.1. RECIST | 21 |
| <i>2.1.2. Imágenes médicas.....</i> | <i>22</i> |
| 2.1.2.1. Técnicas de adquisición de imágenes médicas | 22 |
| 2.1.2.1.1. Imágenes por resonancia magnética (MRI)..... | 22 |

| | | |
|-------------------------|--|-----------|
| 2.1.2.1.2. | <i>Tomografías computarizadas (CT)</i> | 22 |
| 2.1.3. | <i>Inteligencia artificial – IA</i> | 23 |
| 2.1.3.1. | <i>Machine Learning</i> | 23 |
| 2.1.3.1.1. | <i>Deep Learning</i> | 23 |
| 2.1.3.1.2. | <i>Redes Neuronales Convolucionales (CNN)</i> | 23 |
| 2.1.4. | <i>Procesamiento de imágenes</i> | 23 |
| 2.1.4.1. | <i>Segmentación</i> | 24 |
| 2.2. | Marco legal | 24 |
| 2.3. | Estado del arte | 26 |
| Capítulo 3 | | 30 |
| 3.1. | Etapa 1. Definición de requerimientos | 30 |
| 3.1.1. | <i>Criterios RECIST</i> | 30 |
| 3.1.2. | <i>Obtención de la base de datos</i> | 33 |
| 3.2. | Etapa 2. Diseño del software | 38 |
| 3.2.1. | <i>Selección del lenguaje de programación</i> | 38 |
| 3.2.2. | <i>Entrenamiento de la inteligencia artificial</i> | 40 |
| 3.2.2.1. | <i>Redes neuronales convolucionales (CNN)</i> | 40 |
| 3.2.2.2. | <i>Visualización máscaras de predicción</i> | 46 |
| 3.2.2.3. | <i>Evaluación del modelo de segmentación</i> | 48 |
| 3.2.3. | <i>Diseño del aplicativo</i> | 51 |
| 3.3. | Etapa 3. Evaluación del software | 55 |
| Capítulo 4 | | 63 |
| 4.1. | Presentación de resultados | 63 |
| 4.1.1. | <i>Diseño del software</i> | 63 |
| 4.1.2. | <i>Evaluación del software</i> | 64 |
| 4.2. | Análisis de resultados | 77 |
| 4.2.1. | <i>Diseño del software</i> | 77 |

| | |
|--|-----------|
| 4.2.2. <i>Evaluación del software</i> | 79 |
| Capítulo 5 | 81 |
| 5.1. Conclusiones | 81 |
| 5.2. Recomendaciones | 82 |
| REFERENCIAS | 84 |
| ANEXOS | 90 |
| a) Anexo 1. Carta de soporte del especialista | 90 |
| b) Anexo 2. Manual de Usuario | 91 |
| c) Anexo 3. Guía de manejo rápido | 92 |

Lista de imágenes

| | |
|---|----|
| Imagen 1. Resumen de las diez tareas diferentes del MSD. | 36 |
| Imagen 2. Imagen volumétrica, corte toracoabdominal..... | 37 |
| Imagen 3. Mascara de segmentación hepática..... | 37 |
| Imagen 4. Imágenes combinadas | 38 |
| Imagen 5. ANN vs CNN | 41 |
| Imagen 6. Conjunto de datos volumétricos por parches de muestreo..... | 44 |
| Imagen 7. Checkpoints – modelo de segmentación hepática..... | 45 |
| Imagen 8. Imagen CT procesada y mascara obtenida por UNet..... | 46 |
| Imagen 9. Imagen CT y mascara de segmentación proporcionada por la base de datos. | 47 |
| Imagen 10. Imagen CT con ventana de vista abdominal. | 47 |
| Imagen 11. Visualización de la imagen volumétrica obtenida a través de matplotlib..... | 48 |
| Imagen 12. Interfaz usuario / modo automático | 52 |
| Imagen 13. Interfaz usuario / modo manual | 52 |
| Imagen 14. Interfaz usuario / Imagen CT y otros datos..... | 53 |
| Imagen 15. Imagen de salida / Diámetros máximos de lesiones. | 54 |
| Imagen 16. Interfaz usuario / Calculo automático de RECIST 1.1..... | 55 |
| Imagen 17. Selección directorio DCM. | 56 |
| Imagen 18. Archivo NII de salida..... | 56 |
| Imagen 19. Imagen DCM convertida a NII / Ventana automática | 57 |
| Imagen 20. Imagen DCM convertida a NII / Ventana abdomen. | 58 |
| Imagen 21. Interfaz usuario / Imagen CT “volume-99.nii.gz” | 59 |

| | |
|---|----|
| Imagen 22. 3D-Slider / Imagen CT “volume-99.nii.gz” y su máscara “label-99.nii.gz” | 59 |
| Imagen 23. 3D-Slider / Imagen CT “volume-99.nii.gz” – Lesiones..... | 60 |
| Imagen 24. 3D-Slider / Imagen CT “volume-99.nii.gz”- Diámetro de la lesión | 61 |
| Imagen 25. Imagen de salida / Diámetro de la lesión aplicable a “lesión diana” | 61 |
| Imagen 26. Medidas manuales correspondientes al corte 39/78 de la imagen volumétrica. | 76 |
| Imagen 27. Medidas automáticas correspondientes al corte 39/78 de la imagen volumétrica. ... | 76 |

Lista de tablas

| | |
|---|----|
| Tabla 1. Tipos de cáncer comunes | 33 |
| Tabla 2. Matriz de Pugh..... | 39 |
| Tabla 3. ANN vs CNN vs RNN..... | 42 |
| Tabla 4. Matriz de confusión. | 50 |
| Tabla 5. Elementos de diseño de la GUI..... | 51 |
| Tabla 6. Datos de funcionamiento del modelo de segmentación hepático entrenado. | 63 |
| Tabla 7. Métricas obtenidas. | 64 |
| Tabla 8. Matriz de confusión. | 64 |
| Tabla 9. Diámetros mayores por obtención automática..... | 65 |
| Tabla 10. Diámetros mayores por obtención manual. Primera muestra. | 67 |
| Tabla 11. Diámetros mayores por obtención manual. Segunda muestra. | 68 |
| Tabla 12. Diámetros mayores por obtención manual. Tercera muestra..... | 69 |
| Tabla 13. Diámetros mayores por obtención manual. Cuarta muestra. | 71 |
| Tabla 14. Promedio suma diámetros mayores manuales. | 73 |
| Tabla 15. Variación obtenida a través del porcentaje de error..... | 74 |

Lista de ecuaciones

| | |
|------------------------------------|----|
| Ecuación 1. Exactitud. | 49 |
| Ecuación 2. Precisión. | 50 |
| Ecuación 3. Recuerdo. | 50 |

Lista de diagramas

| | |
|--|----|
| Diagrama 1. Criterios RECIST 1.0..... | 30 |
| Diagrama 2. Criterios RECIST 1.1..... | 32 |

Lista de gráficas

| | |
|--|----|
| Grafica 1. Comportamiento de las métricas dimensionales obtenidas | 80 |
| Grafica 2. Porcentaje de error. | 80 |

Introducción

Se aborda la materialización de este proyecto con la finalidad de apoyar el juicio de especialistas en salud al momento de identificar y evaluar el progreso de tratamientos oncológicos, facilitando la segmentación de tumores hepáticos y, en consecuencia, la aplicación de criterios de evaluación en respuesta tumoral según terapias aplicadas sobre el paciente, esto mediante el procesamiento de imágenes biomédicas. El procesamiento de imágenes son aquellas técnicas de detección automática o semiautomática de límites dentro de una imagen 2D o 3D. A su vez, la segmentación obtenida de dichos procesos, permite la aplicación de métodos de adquisición de información diagnóstica, lo cual hace posible emplear métricas para la extracción de variables anatomofisiológicas. (Medical Image Segmentation, n.d.)

Mediante la implementación de redes neuronales convolucionales, el proyecto “Programa informático de apoyo para la evaluación del desarrollo de tumores mediante el método RECIST aplicando procesamiento digital de imágenes biomédicas” cuenta con la asesoría del docente Oscar Gelvez y del especialista en radiología Carlos Arias para imágenes volumétricas, con el fin de obtener y evaluar métricas dimensionales correspondientes a lesiones hepáticas; la base de datos se compone aproximadamente de 25.000 imágenes de CT para el entrenamiento del modelo de segmentación hepático. A través del modelo entrenado durante 1000 épocas, se logra visualizar en una GUI la imagen volumétrica, así como su máscara de segmentación y datos correspondientes a la suma de los diámetros mayores de las lesiones presentes, por lo que es posible aplicarse una evaluación automática y manual de la terapia con la cual ha sido tratado el paciente afectado.

Además de lo anterior, el especialista podrá obtener la máscara de segmentación para un posterior uso, así como imágenes por cortes axiales que identifican aquellos tumores de mayor diámetro, adjuntando a estas su diámetro en milímetros (mm). La comprobación de la exactitud del modelo entrenado se realizará mediante la comparación de un banco de imágenes ya segmentadas de un tamaño aproximado a 3.600 archivos.

Capítulo 1

Problema

En el presente capítulo se describe la problemática de la escasa existencia de programas automatizados que apliquen criterios de evaluación de respuesta en tumores tras terapias oncológicas. En el desarrollo del problema se indica a su vez la justificación y formulación de objetivos del presente proyecto.

1.1.Planteamiento del problema

El cáncer es una enfermedad que se caracteriza por la acumulación anormal de células que se multiplican sin control y además invaden tejidos cercanos, proceso conocido como neoplasia maligna. El neoplasma o tumor se caracteriza mediante localización, proliferación celular (tamaño) y vascularización, variables que permiten su medición y trazabilidad.

A partir de lo anterior es importante destacar la forma estándar de evaluar tumores, la cual se realiza mediante criterios de evaluación de la respuesta de tumores sólidos por sus siglas en inglés RECIST (Response evaluation criteria in solid tumors), medición que se realiza a partir de lesiones diana y no diana según la marcación del eje mayor y menor identificados por el especialista en salud, desde su juicio (punto de vista), permitiendo categorizar la respuesta del tratamiento según los cambios comparables con el pretratamiento en respuesta completa (CR), respuesta parcial (PR), enfermedad estable (SD) y enfermedad progresiva (PD). (RECIST 1.1 - Calyx Informatics, n.d.)

Dicho lo anterior, el juicio del especialista puede contribuir a incrementar el error en la evaluación del seguimiento del tratamiento en tumores, ya que la aplicación manual (imagen impresa/imagen digital) y de manera visual del método RECIST se genera debido al mal posicionamiento de los ejes de las lesiones diana, lo que implica variaciones en la trazabilidad de los registros. Además, el límite de tumores sólidos por órgano a trabajar presenta una gran desventaja en la clasificación de la respuesta, dado que, al excederse en esta cantidad en la región u órgano analizado, la clasificación se verá afectada significativamente debido a la dependencia de la suma de los ejes mayores de las lesiones diana. (Fenerty et al., 2016)

Por otro lado, la calidad de la información (en términos de contraste) que se da por la adquisición de las imágenes, afecta el análisis de la región de interés (ROI), es decir, dificulta la identificación de lesiones diana debido a los parámetros de procesamiento de la imagen. (Bali et al., 2018)

1.2. Justificación del problema

Actualmente, la sistematización de procesos de trazabilidad que provienen de métodos manuales ha permitido la mejora en la precisión y predicción de eventos presentes en estos. Dicho lo anterior, en el campo de la salud, la aplicación de la sistematización es de vital importancia puesto que conlleva a un seguimiento de los tratamientos para determinar el estado del paciente. En Colombia la tasa de incidencia de cáncer corresponde a 182 casos por cada cien mil habitantes según cifras del Observatorio Mundial del Cáncer (GCO, por sus siglas en inglés) (Cancer Today, n.d.) además, de acuerdo con estadísticas del Instituto Nacional de Cancerología, dadas 4998 formulaciones de quimioterapia de oncología, hematología y pediatría, se obtuvo un total de 54 errores de una selección de 440 pacientes, que pueden estar relacionados a la ocurrencia en

cualquiera de las etapas de uso del tratamiento, lo que implica directamente el seguimiento del mismo. (Carreño-Dueñas et al., 2014)

El Instituto Nacional de Cancerología para Colombia en un estudio de investigación en el año 2014, destaca que, de 230 formulaciones de quimioterapia en oncología, el 12.6% (29) se identificaron con errores que, si bien no produjeron la muerte o discapacidad del paciente, ocasionaron lesiones en el mismo, relacionando directamente un error en el seguimiento o monitoreo del tratamiento. Además, de dicha investigación se observan distintos factores en los errores producidos, entre los cuales se destacan errores en la monitorización, puesto que no se detectaba eficientemente problemas generados en el paciente debido a la terapia prescrita. (Carreño-Dueñas et al., 2014)

En consecuencia, casos como los anteriores han sido motivo del diseño e implementación de sistemas capaces de soportar la evaluación del especialista, adecuándose a métodos de monitorización y evaluación de tumores sólidos según la región anatómica afectada y la clasificación de los mismos, mediante variables como lo son tamaño, diámetro mayor y volumen(es) del tumor(es) (RECIST, n.d.), sin embargo, la necesidad de estandarización de criterios como RECIST, hace indispensable adecuar técnicas de segmentación y medición, que fortalezcan los procesos de trazabilidad del tratamiento a los tumores.

Dicho lo anterior, el diseño y desarrollo de un algoritmo capaz de clasificar los resultados de una terapia oncología, supone un gran aporte en el juicio del especialista, es por esto, que el desarrollo del presente proyecto proporciona un gran valor en cuanto a la monitorización, evaluación e implementación de marcas guías en las imágenes obtenidas con el fin de tomar

acciones tempranas en la formulación de tratamientos, evitando así lesiones, invalidaciones o muertes en pacientes por una evaluación errónea de los tratamientos aplicados.

1.3.Pregunta de investigación

¿Cómo las técnicas de procesamiento digital de imágenes médicas pueden apoyar al especialista en salud para la evaluación de tumores utilizando el método RECIST?

1.4.Objetivos

1.4.1. Objetivo general

Desarrollar un programa informático de apoyo para la evaluación del desarrollo de tumores mediante el método RECIST aplicando procesamiento digital de imágenes biomédicas a través de inteligencia artificial.

1.4.2. Objetivos específicos

- Identificar los parámetros de implementación del método RECIST a través de RECIST 1.1 para la obtención de los requerimientos del programa informático.
- Diseñar un modelo de inteligencia a través de un entorno de desarrollo integrado para el procesamiento digital de imágenes médicas aplicando parametrización del método RECIST.
- Verificar el modelo de apoyo para la evaluación del desarrollo de tumores mediante comparación de los resultados obtenidos de la implementación tradicional con los del programa informático por exactitud y precisión.

Capítulo 2

Marco teórico y Estado del arte

En el presente capítulo se comprenden conceptos relacionados a cáncer, tumores, equipos de imágenes diagnósticas, técnicas de procesamiento y descripciones de proyectos relacionados al tema de investigación. A su vez, se exponen aquellos documentos que protegen la propiedad intelectual, software, derechos de autores y otros registros, en el marco legal del proyecto realizado.

2.1.Marco teórico

2.1.1. *Evaluación en respuesta tumoral*

La evaluación de la respuesta de tumores sólidos suele consistir en mediciones bidimensionales o unidimensionales de los tumores antes y después del tratamiento como lo son la quimioterapia. (Shanbhogue et al., 2010)

2.1.1.1.RECIST

Llamado así por su abreviación en inglés de *Response Evaluation Criteria In Solid Tumors* (Criterios de evaluación de respuesta en tumores sólidos), proporcionan una metodología simple y práctica para la evaluación de la actividad y eficiencia de terapias aplicadas a cáncer de tumores sólidos, de forma que se usa para esta criterios validados y consistentes con el fin de analizar cambios en la carga tumoral. (RECIST, n.d.)

2.1.2. Imágenes médicas

La Agencia de Alimentos y Medicamentos por sus siglas en inglés FDA (2018) define imágenes médicas como aquellas tecnologías usadas para visualizar el cuerpo humano con el fin de diagnosticar, monitorear y/o tratar condiciones médicas. Cada una de las distintas tecnologías aplicadas actualmente, proporcionan información diferente en cuanto al área del cuerpo estudiada o tratada, de manera que estas se ven estrechamente relacionadas con el diagnóstico de enfermedades, lesiones o la efectividad en tratamientos médicos. (Medical Imaging | FDA, n.d.)

2.1.2.1. Técnicas de adquisición de imágenes médicas

2.1.2.1.1. Imágenes por resonancia magnética (MRI)

Se usan ondas de radio y un imán potente con el fin de crear imágenes detalladas del interior del cuerpo del paciente. (Instituto Nacional Del Cáncer IRM, n.d.) Las señales en este tipo de imágenes van desde 1 MHz a 300 MHz, y el rango de frecuencia de estas varía en función de la intensidad del campo magnético estático aplicado. El ancho de banda recibido es pequeño, por lo que normalmente suele ser menor a 20kHz. (Introduction to Magnetic Resonance Imaging (MRI), n.d.)

2.1.2.1.2. Tomografías computarizadas (CT)

Esta prueba combina una serie de escaneos de rayos X o imágenes tomadas desde varios ángulos para la posterior reconstrucción de una imagen en distintos planos a partir de un software de computadora genera imágenes transversales (rebanadas) de vasos sanguíneos y tejidos blandos dentro del cuerpo. (What Is Diagnostic Imaging? - Health Images, n.d.)

2.1.3. *Inteligencia artificial – IA*

International Business Machines Corporation (IBM) define la inteligencia artificial en la medicina como el uso de modelos de aprendizaje automático para la búsqueda de datos médicos y el uso de información que apoye en la mejora de la salud y experiencia de los pacientes. (¿Qué Es Inteligencia Artificial? | IBM, n.d.)

2.1.3.1. Machine Learning

Subconjunto de la IA cuyo objetivo es que las computadoras mejoran en el desarrollo de tareas mediante la experiencia de estas en su trabajo. (What Is Machine Learning? | IBM, n.d.)

2.1.3.1.1. Deep Learning

Subconjunto del aprendizaje automático basado en redes neuronales que permiten que una máquina se entrene a sí misma para realizar tareas. (What Is Deep Learning? | IBM, n.d.)

2.1.3.1.2. Redes Neuronales Convolucionales (CNN)

Es una clase de red neuronal artificial cuyo diseño se da el procesamiento de datos de pixeles, en donde se dan usos como lo es el reconocimiento procesamiento de imágenes. (Taner et al., 2021)

2.1.4. *Procesamiento de imágenes*

Proceso de detección automática o semiautomática de límites dentro de una imagen 2D o 3D. El resultado de la segmentación se puede utilizar para obtener más información de diagnóstico.

Las posibles aplicaciones son la medición automática de órganos, el recuento de células o las simulaciones basadas en la información de límites extraída. (Medical Image Segmentation, n.d.)

2.1.4.1.Segmentación

La segmentación de imágenes es el proceso de dividir por secciones o regiones una imagen según los rasgos que deseamos apreciar en la misma, por lo que los valores numéricos característicos de los píxeles se aprovechan para indicar la presencia de bordes en una imagen a partir de discontinuidades en estos valores. Dicho de otra manera, estos bordes pueden definir las regiones de interés de la imagen médica a procesar. (Segmentación de Imágenes - MATLAB & Simulink - MathWorks América Latina, n.d.)

2.2.Marco legal

- **Ley 23 de 1982:** busca proteger los derechos de los autores de obras literarias, científicas y artísticas, asimismo, a los intérpretes o ejecutantes, a los productores de programa y a los organismos de radiodifusión. (Ley 23 de 1982 - Gestor Normativo - Función Pública, n.d.)
- **Ley 44 de 1993:** Modifica el artículo 29 de la Ley 23 de 1982, donde se especifica la duración a favor del propietario intelectual cuando es persona natural y cuando es persona jurídica. (Ley 44 de 1993 Nivel Nacional, n.d.)
- **Decreto 1360 de 1989:** en el Artículo 1 se describe que el soporte lógico (software) se considera como una creación propia del dominio literario. Debido a lo anterior, en los Artículos 2 y 3 se definen los componentes del software con el fin de determinar su campo

de protección como “dominio literario”. (Decreto 1360 de 1989 - Gestor Normativo - Función Pública, n.d.)

- **Decisión Andina 351 de 1993:** régimen común sobre derecho de autor y derechos conexos: busca dar protección directa al software, en su Artículo 1 define que la finalidad de la decisión 351 es reconocer una adecuada y efectiva protección a los autores y demás titulares de derechos. Además, en su Artículo 4 reconoce la protección a “Los programas de ordenador”. (SICE - Comunidad Andina - Decisión 351, n.d.)
- **Decreto 1474 de 2002:** que promulga el "Tratado de la OMPI, Organización Mundial de la Propiedad Intelectual, sobre Derechos de Autor (WCT)", adoptado en Ginebra, el veinte (20) de diciembre de mil novecientos noventa y seis (1996)". (Decreto 1474 de 2002 Nivel Nacional, n.d.)
- **Python 3.9:** es un software de uso libre está bajo diferentes licencias, sin embargo, el poseedor de los derechos actuales es Python Software Foundation (PSF). El acuerdo de licencia se genera entre PSF y el individuo que accede y utiliza el software Python 3.9 en su forma de código fuente, donde se le permite al licenciatario analizar, probar, ejecutar o mostrar públicamente, preparar trabajos derivados, distribuir y utilizar cualquier otro modo Python 3.9. (History and License — Python 3.10.4 Documentation, n.d.)
- **La base de datos, Task03_Liver:** suministrada por Medical Segmentation Decathlon es de acceso público, sin embargo, cuenta con un acuerdo de licencia para los usuarios que hagan su uso. Una de las condiciones es no hacer uso de la información para identificar o contactar los participantes individuales, además, reconocer los repositorios de datos designados por la organización National Institutes of Health. (Antonelli et al., 2022a)

2.3.Estado del arte

A continuación, se contextualizan cronológicamente las investigaciones aplicables a la automatización y semiautomatización de la metodología RECIST con el fin de llevar a cabo el desarrollo del programa de soporte de evaluación de tratamiento oncológico.

Dentro de los trabajos más relevantes en cuanto a la segmentación de imágenes basada en el análisis de valores grises del ROI, en 2008, se publicó un documento del Centro de Computación para Imágenes Biomédicas de Bremen (Alemania), el cual presentó un algoritmo para la segmentación de metástasis hepáticas a través de TC que combina la umbralización adaptativa con el análisis de los valores en grises del ROI, lo cual permite la delimitación del tumor tanto en lesiones hiperdensas como hipodensas sin importar que estas se encontrasen internamente al hígado o en la periferia del mismo. La precisión y velocidad de aplicación del software de soporte sobre la imagen a procesar apoyan el diagnóstico del especialista en radiología, puesto que reduce su tiempo en la obtención de dimensiones del tumor y a su vez es eficaz para diversos tipos de tumores. Se resalta que el método de trabajo usado corresponde al algoritmo de segmentación de nódulos pulmonares de Kuhnigk et al, el cual abarca un problema común en cualquier tipo de tumor, el contacto con vasos sanguíneos u otros tipos de tumores delgados. (Moltz et al., 2008)

Seguidamente, en el 2010, un grupo de investigación perteneciente al Departamento de Ingeniería Informática Viale delle Scienze y el Departamento de Biotecnología Médica y Medicina Legal de la Universidad de Palermo (Italia), presentó una segmentación volumétrica automática basada en la textura del hígado en TC, mejorando el contraste de la imagen, la segmentación de la zona abdominal y la recuantificación de los niveles de grises de la imagen, esto en cuanto al preprocesado de la imagen, para posteriormente seleccionar un punto inicial que obtiene las

características de la textura y así seleccionar de manera automática el valor del umbral de la imagen. Se concluye que el algoritmo descarta correctamente vasos sanguíneos dado que su textura local es diferente a la del hígado, además, descarta tejidos adyacentes al órgano que mantienen vóxeles de nivel de gris similares. (Gambino et al., 2010)

Durante este mismo año, el Grupo de Procesamiento de Imágenes Médicas en Beijín (China) y el Centro de Investigación de Ciencias de la Vida en Shanxi (China), propusieron la segmentación automática en hígado en TC basado en un modelo de forma estadística integrado a una estrategia de detección de superficie óptima. Se usa la transformada de Hough como método de detección de formas arbitrarias en imágenes. (X. Zhang et al., 2010)

Posteriormente, en el año 2015, se desarrolló un método de registro de imágenes basadas en tejidos blandos para la evaluación de la respuesta del tumor a la terapia, en la Escuela de Ingeniería Eléctrica e Informática de la Universidad de Oklahoma (EE.UU.), dado que se detectó limitantes de los criterios RECIST al tratarse de imágenes deformables (B-spline). Dicha problemática se soluciona al adquirirse imágenes de TC previas y posteriores al tratamiento aplicado sobre el paciente, resaltando el crecimiento volumétrico o contracción del tumor empleando RECIST como guía. (Tan et al., 2015)

Durante el año 2020 en el Laboratorio de Inteligencia Artificial en Medicina y Física Biomédica de la Universidad de Stanford en EE.UU., se planteó la incorporación de U-Net modificado para la mejora de segmentación de hígado y tumores hepáticos en TC, lo cual evitó la duplicación de mapas de baja resolución en el borde del objeto, provocando que la información de borde de alta resolución de los mapas de la imagen se controle de forma adaptativa para combinarse a través de capas de convolución. Se concluye que la red de aprendizaje profundo propuesta ofrece

resultados precisos, puesto que evita la duplicación de información de baja resolución, además estima mapas de características de nivel alto que representan mejor la información del borde de alta resolución, asimismo, el método no requiere ningún tipo de preprocesamiento por lo que puede aplicarse a otros órganos o imágenes de bajo contraste. (Seo et al., 2020)

En este mismo año, una investigación realizada en conjunto por el Laboratorio de Biomarcadores de Imagen y Diagnóstico Asistido por Computador, Radiología y Ciencias de la Imagen en Bethesda (EE.UU.) y Ping una Compañía de Seguros de China en Shenzhen (China), desarrolló un modelo de segmentación 2D en hígado y tumores del mismo compuesto por dos etapas, la primera consiste en una red de segmentación gruesa del hígado mientras que la segunda es una red mejorada de borde (E-Net) que proporciona una segmentación precisa del órgano y tumores desarrollados en el mismo. E Net modela los objetos visibles del hígado y extrae la información de los bordes de estos con el fin de preservar de manera correcta los límites del órgano y lesión. (Tang et al., 2020)

Finalmente, en el año 2021, se llevó a cabo un proyecto de investigación liderado por Zhejiang Lab (China), el cual propuso el uso de diámetros RECIST como señales de supervisión para guiar la segmentación de tumores hepáticos (LiTS) para el desarrollo de una red sensible y guiada para LiTS. Se obtuvo un modelo interactivo DeepRecS basado en Deep Learning para la segmentación de tumores hepáticos, en el que se aprovecha RMP-Net para estimar marcas de orientación en segmentos fuera de RECIST, así como el diseño de CGBS-Net para la predicción de mapas de tumores a partir de marcas guías. (Y. Zhang et al., 2021)

A partir de lo anteriormente expuesto, es posible establecer una contextualización de la aplicación de tecnologías en el procesamiento y análisis de imágenes biomédicas de melanomas,

además de herramientas conceptuales que aportan a la construcción de conocimiento en el uso de técnicas de segmentación, fundamental para la aplicación en RECIST como apoyo al especialista en salud. Por ello, el interés de la presente investigación cuenta con un enfoque de desarrollo de un algoritmo de apoyo al especialista en salud basado en el procesamiento de imágenes biomédicas para la aplicación del método RECIST.

Capítulo 3

Metodología

Para el desarrollo del software se llevó a cabo la recopilación de información referente a la evaluación de tumores mediante criterios RECIST, lo cual permitió definir el enfoque del proyecto, de manera que se lograron definir requerimientos del sistema y variables relevantes para el cálculo automático de dicha evaluación. El progreso del presente trabajo, se realizó a través de un modelo metodológico en cascada iterativa, con el fin de permitir la retroalimentación del proyecto en cada una de sus etapas según las actividades asignadas por objetivo.

3.1.Etapa 1. Definición de requerimientos

3.1.1. *Criterios RECIST*

Para la selección de los criterios RECIST a aplicar, se realizaron consultas en artículos académicos y de investigación referentes a la evaluación de tumores, así como reuniones de modalidad remota con el asesor externo del proyecto quien es especialista en radiología, con lo cual se logró identificar y aplicar los criterios a usar según qué tan recientes son en cuanto al tiempo de haberse definido estos.

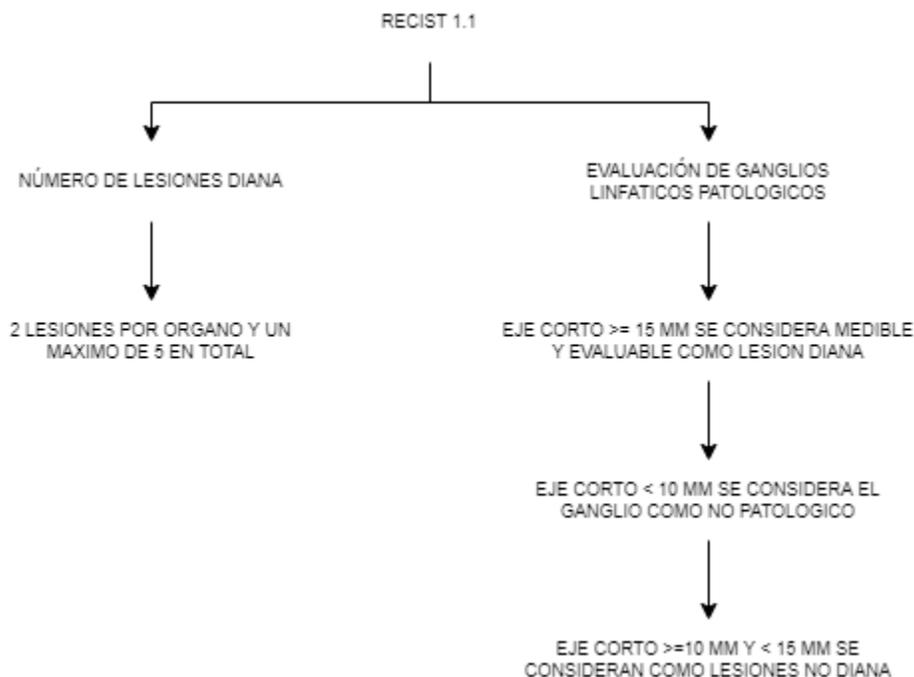
En los siguientes diagramas se describen los criterios correspondientes a RECIST 1.0 (Ver diagrama 1) y RECIST 1.1 (Ver diagrama 2):

Diagrama 1. Criterios RECIST 1.0



Elaboración propia.

Diagrama 2. Criterios RECIST 1.1



Elaboración propia.

Tal como se describe anteriormente, se observa una gran diferencia entre la cantidad de lesiones diana a tomar en cuenta en RECIST 1.0 respecto a RECIST 1.1, por lo que para el desarrollo de un tipo de automatización discriminatoria entre tumores se aplicaron los siguientes criterios: 1). Se consideran lesiones medibles aquellas que posean un diámetro mayor de o superior a 10 mm en cortes axiales menores o iguales a 5 mm de espesor, 2). Se analiza un máximo de 5 lesiones (2 por órgano), 3). Respuesta completa (RC); desaparecen totalmente aquellas lesiones y ganglios patológicos, 4). Respuesta parcial (RP); se presencia una disminución mayor o igual al 30% de la suma de los diámetros mayores, 5). Enfermedad progresiva (EP); se presencia un aumento mayor o igual al 20% de la suma de los diámetros mayores, 6). Enfermedad estable (EE); la suma de los

diámetros mayores no aplica para RP o EP. Los criterios trabajados corresponden a RECIST 1.1. (Cervera Deval, 2014a)

3.1.2. Obtención de la base de datos

Debido a la gran variedad de zonas en que los tumores pueden originarse, se es difícil realizar el entrenamiento de una IA que segmente lesiones en distintos órganos, por lo que para una primera versión del presente proyecto se optó por seleccionar una base de datos de imágenes de CT que contenga cortes toracoabdominales en donde se segmente hígado y a su vez, lesiones presentes en dicho órgano. La selección se da debido a la tasa de incidencia y mortalidad por tumores hepáticos respecto a otro tipo de órganos, así como una mayor área anatómica de análisis para el entrenamiento de la IA. A continuación, se expone en la tabla 1 los casos estimados de cáncer para distintos órganos y el número de muertes estimadas por los mismos para el año 2022, esto según cifras del Instituto Nacional de Cáncer de Estados Unidos (NIH).

Tabla 1. Tipos de cáncer comunes

| Tipo de cáncer | Nuevos casos estimados | Muertes estimadas |
|-------------------------------------|-------------------------------|--------------------------|
| Vejiga | 81,180 | 17,100 |
| Pecho (Femenino – Masculino) | 287,850 – 2,710 | 43,250 – 530 |

| | | |
|--|---------|---------|
| Colon y Rectal (Combinados) | 151,030 | 52,580 |
| endometrial | 65,950 | 12,550 |
| Riñón (célula renal y pelvis renal) | 79,000 | 13,920 |
| Leucemia (todos los tipos) | 60,650 | 24,000 |
| Hígado y vía biliar intrahepática | 41,260 | 30,520 |
| Pulmón (incluyendo bronquios) | 236,740 | 130,180 |
| Melanoma | 99,780 | 7,650 |
| No linfoma de Hodgkin | 80,470 | 20,250 |
| Pancreático | 62,210 | 49,830 |

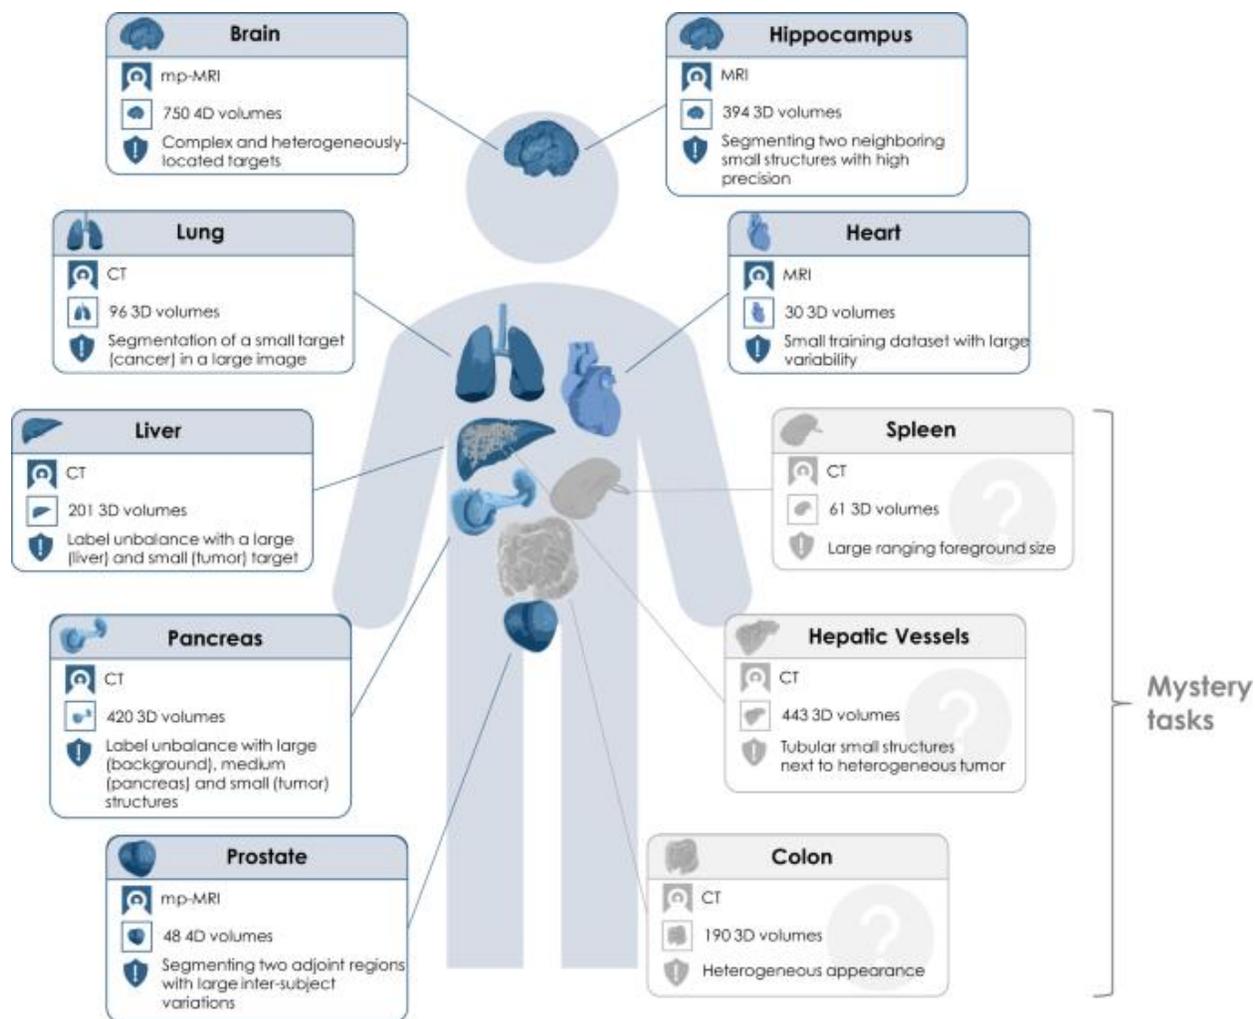
| | | |
|-----------------|---------|--------|
| Próstata | 268,490 | 34,500 |
| Tiroides | 43,800 | 2,230 |

(Common Cancer Types - NCI, n.d.-a)

Tal como lo indica el título de la tabla, uno de los tipos de cáncer más comunes es el hepático, por lo que debido a la escasez para conseguir datos de imagenología que contengan lesiones tumorales en otros órganos, la selección de la base de datos corresponde absolutamente para lesiones hepáticas. Se obtuvieron las imágenes volumétricas mediante el Decatlón de Segmentación Médica (MSD), el cual es un desafío de procesamiento de imágenes médicas que proporciona al público un banco extenso de distintos tipos de imágenes volumétricas, ya sean de CT o MRI, en donde se encuentran imágenes para distintos órganos, como lo son corazón, cerebro, hígado, próstata, páncreas, pulmones, entre otros, con sus respectivas máscaras de segmentación para un entrenamiento con redes neuronales, en el caso específico de las imágenes de hígado se hallaron tanto los archivos volumétricos de tipo nifti comprimido (.nii.gz) así como las máscaras de segmentación del órgano y lesiones presentes en este si las hay. Se destaca que las máscaras de segmentación proporcionadas fueron revisadas por especialistas médicos del desafío, con el fin de comprobar su fiabilidad.

A continuación, se presentan los órganos que proporciona el MSD y los desafíos que plantean a las personas que deseen participar en el mismo (Ver imagen 1).

Imagen 1. Resumen de las diez tareas diferentes del MSD.

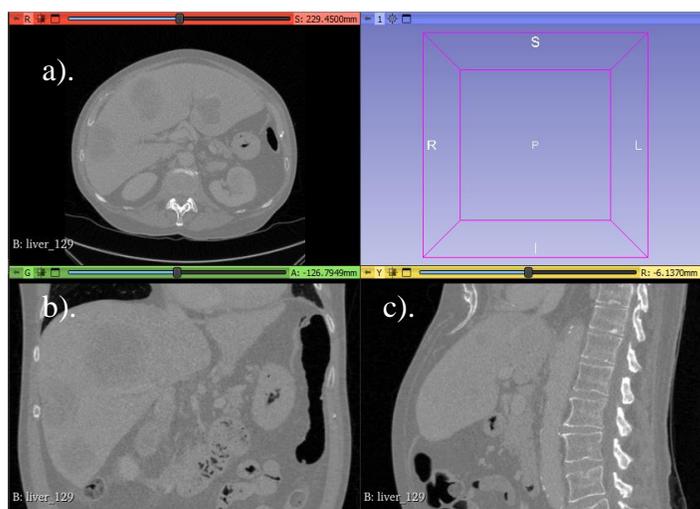


(Antonelli et al., 2022b)

La base de datos se compone de 131 archivos correspondientes a imágenes de TC y 131 archivos de máscaras de segmentación, para un total de 262 archivos de tipo nifti comprimido, por lo que al obtener las imágenes totales por cada archivo se registra aproximadamente 60.000 imágenes biomédicas de corte toracoabdominal, hablando solamente de imágenes TC, para las máscaras de segmentación el valor es el mismo debido a que estas poseen la misma cantidad de

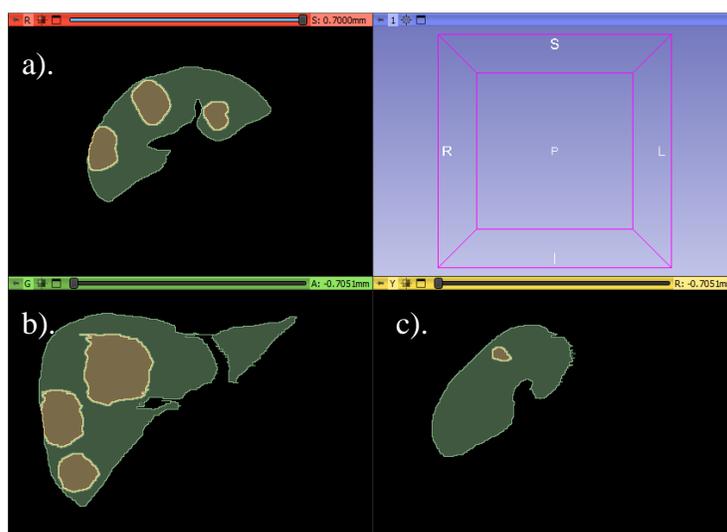
cortes que la imagen TC. El peso total de los datos corresponde a 18 GB aproximadamente. En las imágenes 2, 3 y 4 se aprecia los archivos volumétricos y de segmentación.

Imagen 2. Imagen volumétrica, corte toracoabdominal. a). Vista axial, b). Vista frontal, c). Vista sagital



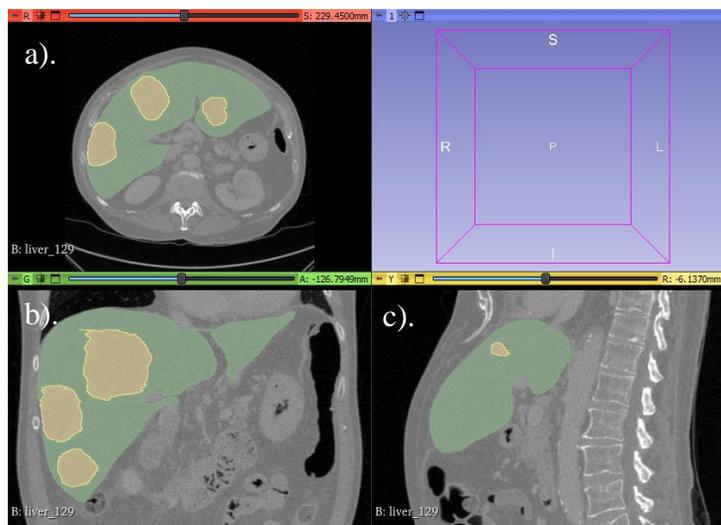
Elaboración propia.

Imagen 3. Mascara de segmentación hepática. a). Vista axial, b). Vista frontal, c). Vista sagital



Elaboración propia.

Imagen 4. Imágenes combinadas. a). Vista axial, b). Vista frontal, c). Vista sagital



Elaboración propia.

Dado al gran peso de las imágenes volumétricas, fue necesario hacer una adecuación de las mismas debido a los altos gastos computacionales y exigencias en RAM para el procesamiento de los datos en bruto, por lo que mediante programación se logró reducir el tamaño de dichos archivos a poco más de 2 GB de peso. Esto se explicará con mayor en la sección correspondiente a la etapa 2, “Entrenamiento de la inteligencia artificial”.

La base de datos final cuenta con un total de 262 archivos y aproximadamente 25.000 imágenes de TC en total.

3.2.Etapa 2. Diseño del software

3.2.1. Selección del lenguaje de programación

En la selección del lenguaje usado para el desarrollo del aplicativo, se tuvo en cuenta la aplicabilidad y compatibilidad de este sobre distintos tipos de sistemas operativos, y a su vez, el

acceso libre a la totalidad de funciones que pueda proveer dicho lenguaje mediante sus librerías. En consecuencia, tras el análisis de distintos tipos de lenguaje, como lo son el C++, el Python y MATLAB, se decidió dar continuidad con el proyecto a través de Python, esto debido a que el único lenguaje de los ya mencionados que cuenta con la totalidad de requerimientos mencionados anteriormente es este, puesto que lenguajes como el MATLAB y C++, si bien son en igual medida aplicables para el desarrollo de una IA, no permiten su uso a menos de tener una licencia de los mismos o limitan las funciones del usuario al tener un costo monetario la adquisición de librerías.

Aquellas necesidades que se buscaron solventar mediante la selección del lenguaje de programación fueron el procesamiento de bases de datos, diseño y entrenamiento de técnicas de IA, y el desarrollo de una interfaz que facilite la comunicación del usuario con el código diseñado para el procesamiento y evaluación de los datos cargados.

En la tabla 2, se exponen las alternativas de lenguaje de programación a trabajar y los respectivos criterios tenidos en cuenta para la evaluación de los mismos, donde 1 corresponde a una ejecución deficiente del criterio evaluado y 5, óptimo, con el fin de definir el tipo de lenguaje con el que se da desarrollo el presente proyecto.

Tabla 2. Matriz de Pugh

| Alternativas / Criterios | C++ | PYTHON | MATLAB |
|--|------------|---------------|---------------|
| <i>Procesamiento de datos</i> | 3 | 5 | 5 |
| <i>Bajo gasto computacional</i> | 4 | 4 | 2 |

| | | | |
|-------------------------------------|-----------|-----------|-----------|
| <i>Diseño y entrenamiento IA</i> | 3 | 5 | 4 |
| <i>Librerías</i> | 2 | 5 | 2 |
| <i>Desarrollo interfaz</i> | 2 | 4 | 5 |
| <i>Evaluación de datos cargados</i> | 3 | 5 | 5 |
| TOTAL | 17 | 28 | 23 |

Elaboración propia.

3.2.2. *Entrenamiento de la inteligencia artificial*

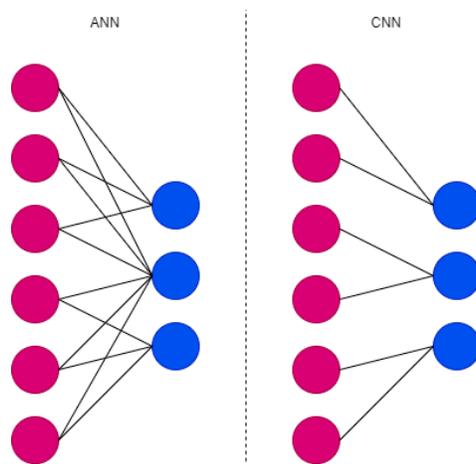
Para el entrenamiento de la IA se realizó el proceso bajo el lenguaje Python trabajando con el intérprete Visual Studio Code, en donde se implementaron archivos compatibles con Python y Jupyter Notebook según la necesidad de avances del proyecto. Por otro lado, el entrenamiento se llevó a cabo en las instalaciones de la Universidad Autónoma de Bucaramanga, específicamente en el laboratorio de sistemas, el cual cuenta con equipos de cómputo de última tecnología, lo que permitió el entrenamiento de dicho modelo de segmentación a través de una GPU, lo que redujo significativamente el tiempo de entrenamiento debido a su capacidad de procesamiento, esto respecto a los equipos de los integrantes.

3.2.2.1. **Redes neuronales convolucionales (CNN)**

A diferencia de las redes neuronales artificiales (ANN), las CNN generan menores cantidades de parámetros a medida que se realiza el entrenamiento de las mismas, por lo que, al

poseer menores parámetros a procesar, más rápido será el proceso de aprendizaje de estas. Por otro lado, las ANN generalmente requieren el aplanamiento de los datos suministrados, lo que supone la pérdida de información en la adecuación de estos, además que, en procesamiento de imágenes, este tipo de redes neuronales requieren de imágenes muy similares para así entregar resultados óptimos, es decir, aplicar un procesamiento que estandarice de la mejor manera las imágenes suministradas, lo que es complicado en el trabajo de imágenes volumétricas. En cuanto a las CNN, estas poseen capas convolucionales, que solucionan los inconvenientes que pueden llegar a presentar las ANN mediante múltiples filtros que son aplicados a las imágenes de entrada, además, CNN reduce la cantidad de parámetros al centrarse en una conectividad local, es decir, cada neurona recibe solo un grupo local de valores de píxeles de la imagen de entrada, caso contrario con las ANN, las cuales conectan todos sus valores a cada una de las neuronas. La siguiente imagen describe de mejor forma lo mencionado.

Imagen 5. ANN vs CNN



Elaboración propia.

Tras el análisis de distintos tipos de redes neuronales, se definió como desarrolladora del modelo de segmentación las redes neurales convolucionales debido a diversos factores, entre ellos el procesamiento y reconocimiento de imágenes. A continuación, se presenta una tabla comparativa entre las 3 redes neuronales que se investigaron para el posterior diseño del modelo inteligente.

Tabla 3. ANN vs CNN vs RNN.

| | ANN | CNN | RNN |
|---------------------------------|--|---|--|
| Estructura | Flujo de información en una dirección | Múltiples capas que pueden poseer capas convolucionales | Flujo de información en distintas direcciones, apoyando el autoaprendizaje |
| Tipo de datos | Datos tabulares y texto | Datos de imágenes | Datos de secuencia |
| Complejidad | Más simple | Más completo | Mayor potencial de aprendizaje y memoria |
| Principal característica | Trabaja con datos incompletos y posee una alta tolerancia a fallos | Precisión en el reconocimiento de imágenes | Memoria y autoaprendizaje |
| Reconocimiento espacial | No | Si | No |
| Desventaja | Dependiente del hardware | Requiere grandes cantidades de datos | Entrenamiento lento y complejo |
| Usos | Análisis predictivo | Visión artificial | Análisis de sentimientos |

Elaboración propia.

Para esta técnica de entrenamiento se aplicó el uso de las librerías pytorch y numpy, cuya tarea se dio en el procesamiento y manejo de datos de entrenamiento, así como el modelo de entrenamiento basado en UNet diseñado a partir de torch. Lo primero a realizarse fue el diseño de la estructura de UNet para datos tridimensionales, en donde se especifica el número de capas a trabajar, así como las neuronas de salida por cada una de estas, lo cual se puede definir de forma arbitraria, pero dada la investigación realizada previamente a través de diversos artículos de

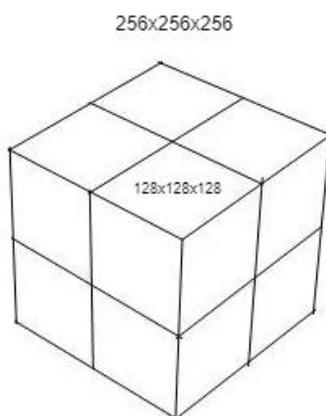
procesamiento de imágenes médicas, se definieron 4 canales de entrada y 4 más de salida, en donde el número máximo de neuronas es de 256.

Dado que al trabajar con datos volumétricos es complicado realizar un muestreo completo de las imágenes, se dividen estas por medio de conjuntos más pequeños, lo que facilita la velocidad del entrenamiento. En el caso específico de la base de datos usada, el tratar con los datos sin procesar equivalía a requerir más de 64 GB de RAM para las unidades de computo, puesto que las imágenes presentaban una resolución en plano axial de 512x512 píxeles y en ocasiones, más de 900 cortes volumétricos, por lo que la cantidad de datos a procesar dificultaba la velocidad o eficiencia del equipo computacional, por lo que fue necesario remuestrear dichas imágenes, y mediante la librería nibabel de Python, se realizó una estandarización volumétrica de las mismas, pasando a tener valores de vóxeles variables de (0.5,0.5,0.5) a (5.0,5.0,5.0) (esto refiriéndose al desplazamiento en milímetros en un espacio tridimensional), a valores de vóxeles estáticos de (2.0,2.0,5.0) por sus siglas en inglés de orden 'RAS', es decir, el primer valor corresponde al desplazamiento de lateral izquierda a lateral derecha, el segundo de posterior a anterior, y el tercero de inferior a superior, obteniendo así un banco de imágenes preprocesado de una máxima resolución en el plano axial de 256x256 píxeles y un máximo de cortes volumétricos de 200. Dicho lo anterior, es clara la reducción de tamaño por imágenes, por lo que el banco de imágenes preprocesado termina con un peso de poco más de 2 GB respecto a las 18 GB ocupadas por los datos en bruto, lo que indica una menor capacidad de computo para realizar el entrenamiento del modelo de segmentación.

Dado que el procesar imágenes en su volumen completo puede dificultar el entrenamiento de la IA por la gran cantidad de datos a manejar, se da uso de secciones de muestreo para un

análisis más sencillo y rápido, lo cual consiste en seccionar el conjunto de datos volumétricos en porciones más pequeñas para un fácil procesamiento de los mismos. La siguiente imagen describe lo mencionado anteriormente.

Imagen 6. *Conjunto de datos volumétricos por parches de muestreo.*



Elaboración propia.

Debido a que el muestro por parches se encarga de dividir el volumen de la imagen, es necesario juntar dichos parches nuevamente, con el fin de obtener la predicción del entrenamiento en el volumen original de la imagen (banco de imágenes preprocesadas). Ahora bien, para la aplicación del entrenamiento se dio uso de la librería torchio, la cual proporciona la carga, preprocesamiento y muestreo basado en parches de imágenes tridimensionales en el aprendizaje profundo. (TorchIO, n.d.)

Lo que permite esta librería es cargar todos los archivos de entrenamiento de tipo nifti en sujetos que se guardan en una lista, para posteriormente ser almacenados en tensores que contienen el conjunto de datos definidos para entrenamiento y validación, en donde se indica las transformaciones a aplicarse en los conjuntos de forma individual, primeramente se estandariza el

procesamiento para ambos conjuntos de datos, como lo es el rango de distribución de los valores de los píxeles, dado que las imágenes son en escala de grises la intensidad se posiciona en el rango de (-1,1) que es con el que trabajan las imágenes médicas, esto con el fin de asegurar que todas se encuentren en la misma escala, y a su vez, debido a que el banco no posee el mismo tamaño en sus imágenes, se indica que todas sean de dimensiones de (256,256,200), en donde los dos primeros valores indican la resolución de la imagen en el plano axial, en otras palabras, los cortes en el plano sagital y coronal, y el tercer valor indica la cantidad de cortes en el plano axial. Realizada la estandarización de los datos, se procede a aplicar una matriz afín de aumento en la que se indican transformaciones aleatorias de las imágenes cada que se muestreen, como lo es la escala dimensional y ángulos de rotación de las imágenes, dicha transformación solo aplica para el conjunto de entrenamiento.

Realizado lo anterior, se procede a indicar el dispositivo con el que se realizara el entrenamiento, el cual será por GPU y se crea una variable de instancias que guardar aquellos *checkpoints* que genere nuestro entrenamiento a medida que avanza. Se realizo un entrenamiento de 1000 épocas con *checkpoints* que se sobrescribían cada 10 épocas de entrenamiento, obteniéndose como pesos finales los siguientes:

Imagen 7. Checkpoints – modelo de segmentación hepática

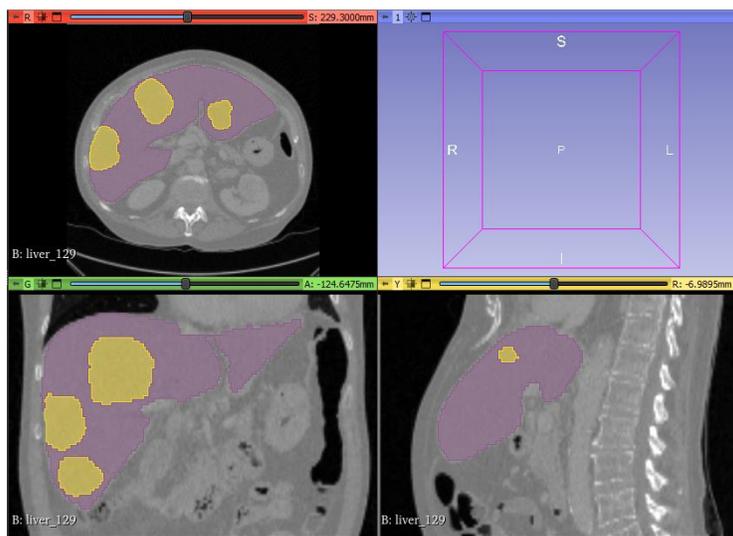
| | | | |
|----------------------------|-----------------------|--------------|-----------|
| epoch=146-step=38661.ckpt | 5/11/2022 4:20 a. m. | Archivo CKPT | 68.435 KB |
| epoch=182-step=48129.ckpt | 5/11/2022 6:26 a. m. | Archivo CKPT | 68.435 KB |
| epoch=199-step=52600.ckpt | 5/11/2022 7:25 a. m. | Archivo CKPT | 68.435 KB |
| epoch=249-step=65750.ckpt | 5/11/2022 10:18 a. m. | Archivo CKPT | 68.435 KB |
| epoch=353-step=93102.ckpt | 5/11/2022 4:19 p. m. | Archivo CKPT | 68.435 KB |
| epoch=366-step=96521.ckpt | 5/11/2022 5:04 p. m. | Archivo CKPT | 68.435 KB |
| epoch=469-step=123610.ckpt | 5/11/2022 10:51 p. m. | Archivo CKPT | 68.435 KB |
| epoch=614-step=161745.ckpt | 6/11/2022 6:45 a. m. | Archivo CKPT | 68.435 KB |
| epoch=874-step=230125.ckpt | 6/11/2022 8:57 p. m. | Archivo CKPT | 68.435 KB |
| epoch=922-step=242749.ckpt | 6/11/2022 11:35 p. m. | Archivo CKPT | 68.435 KB |

Elaboración propia.

3.2.2.2. Visualización máscaras de predicción

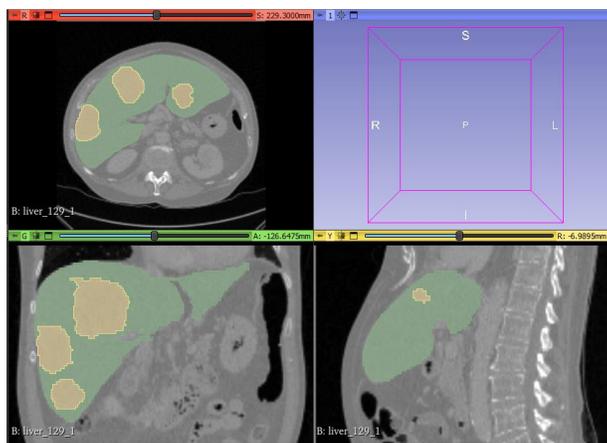
Finalizado el entrenamiento, se procede a realizar la carga de la época más reciente, en el caso específico de este proyecto fue la 922, a partir de la cual se obtiene el tensor de salida correspondiente a la máscara de segmentación predicha correspondiente a hígado y potenciales lesiones en el mismo. La máscara de segmentación es aplicada sobre aquellas imágenes correspondientes al conjunto de datos de validación, por lo que al realizar comparación de la predicción realizada por la inteligencia respecto a la máscara que ya proporcionaba la base de datos, no debería de mostrar una gran variación si el proceso se realizó correctamente. A continuación, se presenta la comparación entre las imágenes proporcionadas por la base de datos y la etiqueta generada por la IA (Ver imagen 8 y 9).

Imagen 8. Imagen CT procesada y mascara obtenida por UNet.



Elaboración propia.

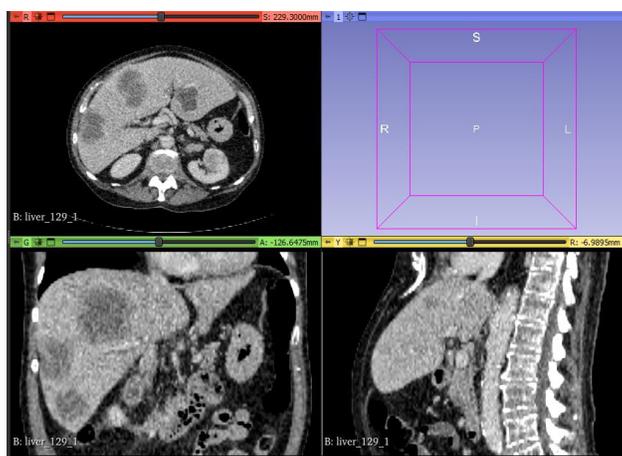
Imagen 9. Imagen CT y mascara de segmentación proporcionada por la base de datos.



Elaboración propia.

Como se observa, la segmentación de ambos casos es igual, variando en algunas delimitaciones de los contornos pertenecientes a la base de datos original, sin embargo, la respuesta es positiva, puesto que, en este caso específico la segmentación es exacta. La imagen 10 expone la imagen CT sin ninguna mascara de segmentación con el fin de comprobar la existencia de dichas lesiones.

Imagen 10. Imagen CT con ventana de vista abdominal.



Elaboración propia.

Como se observa, se puede verificar la presencia de las lesiones en el órgano. Las imágenes presentadas anteriormente se cargaron en el software de uso libre “3D-Slicer”, el cual es un aplicativo que permite visualizar imágenes volumétricas en sus distintos planos, así como la superposición de máscaras de segmentación.

En igual manera, el procesamiento de visualización de las imágenes se puede observar a través del uso de código, esto mediante la librería matplotlib, la cual permite visualizar en un plano cartesiano las imágenes con sus respectivas dimensiones ya sea como una imagen estática o una animación (Ver imagen 11).

Imagen 11. Visualización de la imagen volumétrica obtenida a través de matplotlib.



Elaboración propia.

3.2.2.3. Evaluación del modelo de segmentación.

Debido a la naturaleza de los datos, no es posible analizarlos mediante librerías de Python como lo es torchmetrics, librería que permite la obtención de la exactitud, precisión y matriz de

confusión, esto debido a que las funciones permiten solo la lecturas de archivos de tipo numpy (.npy), y al transformar las imágenes a dicho formato para el entrenamiento y posterior obtención de datos, se aumenta el peso de la base de datos preprocesada de 2GB a más de 15 GB, por lo que dado los recursos con los que se cuenta en este momento, es una limitación importante a considerar. Es por esto, que, usando las imágenes pertenecientes al conjunto de validación, se procede a comparar la predicción de la existencia de lesiones en el órgano, así como su segmentación a través de los contornos definidos por la IA entrenada, respecto a las máscaras de segmentación proporcionada por la base de datos de MSD, por lo que procede a obtener la exactitud, precisión, recuerdo y matriz de confusión del modelo entrenado.

La exactitud se obtiene a partir de la ecuación 1 que considera la suma de la cantidad de datos predichos como verdaderos, sobre la suma de estos mismos junto con los pronosticados como falsos, es decir, aquellas máscaras de segmentación que indiquen la correcta existencia de lesiones se etiquetaran como verdaderos positivos (TP); las máscaras que indiquen de forma correcta la inexistencia de lesiones se etiquetaran como verdaderos negativos (TN); las máscaras que indiquen la existencia de lesiones cuando no las hay se etiquetaran como falsos positivos (FP) y por último, aquellas mascaras que no indiquen la existencia de lesiones cuando hay presencia de las mismas sobre el órgano, se etiquetaran como falsos negativos (FN). A continuación, la ecuación que representa lo anteriormente mencionado.

Ecuación 1. Exactitud.

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

La precisión del modelo conseguido mediante la ecuación 2, proporciona cuantos datos definidos como verdaderos positivos se predicen correctamente, por lo que una alta precisión indica un menor número de falsos positivos.

Ecuación 2. Precisión.

$$\text{Precisión} = \frac{TP}{TP + FP}$$

El recuerdo del modelo determinado por la ecuación 3, expone la integridad del mismo, es decir, a mayor recuerdo del sistema menores son los reconocimientos de falsos negativos, mientras que, si el recuerdo posee un valor bajo, mayores son los datos clasificados como falsos negativos. La precisión se ve afectada por el aumento del recuerdo del modelo.

Ecuación 3. Recuerdo.

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

Finalmente, la matriz de confusión se encarga de exponer la cantidad de datos predichos como TP, TN, FP y FN (Ver tabla 4).

Tabla 4. Matriz de confusión.

| | |
|-----------------------------|-----------------------------|
| Verdaderos Positivos | Falsos Positivos |
| Falsos Negativos | Verdaderos Negativos |

Elaboración propia.

3.2.3. *Diseño del aplicativo*

La GUI desarrollada contiene distintos elementos en su diseño que hacen de esta un aplicativo amigable con el usuario, de forma que es sencilla de usar y posee algunas funciones similares de otros softwares estudiados. Los elementos con los que se realizó dicha interfaz son:

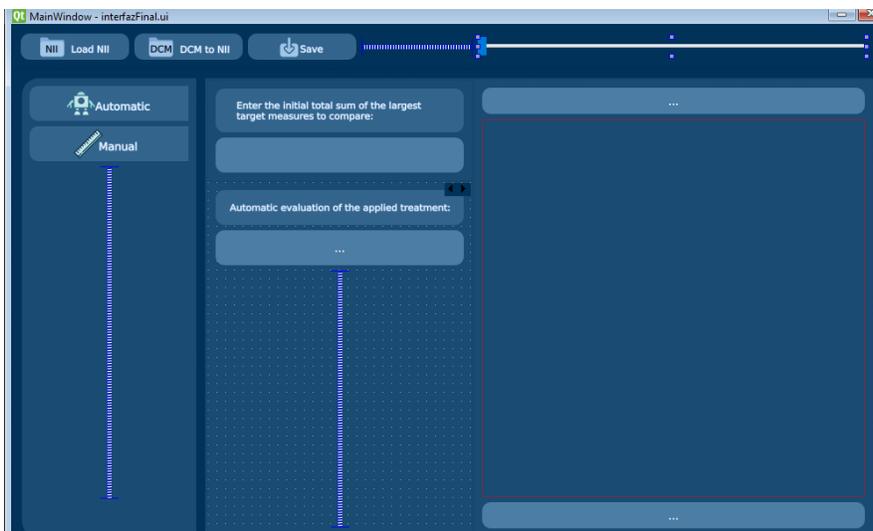
Tabla 5. *Elementos de diseño de la GUI*

| Herramienta de diseño | Editor de código | Librerías usadas |
|------------------------------|-------------------------|--|
| Qt Designer | Visual Studio Code | nibabel dicom2nifti matplotlib PyQt5 celluloid torchio torch pytorch_lightning numpy cv2 heapq |

Elaboración propia.

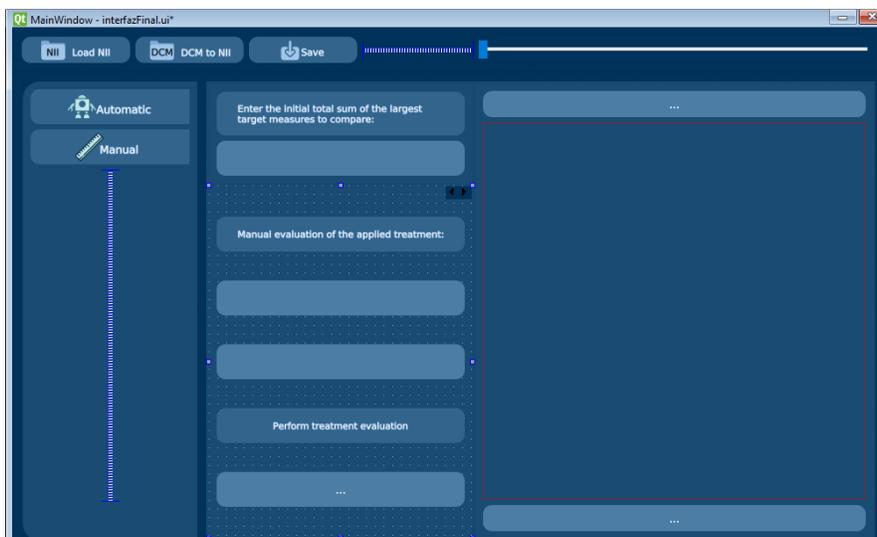
El diseño estético de la interfaz se llevó a cabo en Qt Designer, en donde se creó una ventana principal que posee los botones necesarios para la carga de archivos y guardado de los mismos, así como cajas de texto para el ingreso de datos, botones para el cambio de modo de trabajo (automático/manual) a través de páginas, un deslizador para el desplazamiento en los cortes de la imagen, y etiquetas para la impresión de datos y proyección de imagen volumétrica. En la imagen 12 y 13 se presenta la interfaz diseñada en sus dos modos de trabajo:

Imagen 12. Interfaz usuario / modo automático



Elaboración propia.

Imagen 13. Interfaz usuario / modo manual



Elaboración propia.

El botón “Load NII” además de cargar imágenes de tipo nifti comprimido, preprocesa las imágenes, realiza el proceso de segmentación hepática y de lesiones hepáticas, y permite finalmente la visualización de la imagen volumétrica en el *layout* correspondiente; este botón

genera un archivo “.nii.gz” que contiene la imagen cargada preprocesada, la ruta de guardado es seleccionada por el usuario. Por otro lado, el botón “DCM to NII” convierte un directorio que posea imágenes bidimensionales de un mismo estudio para su transformación en imágenes volumétricas de tipo “.nii.gz”, al igual que el botón anterior, permite al usuario elegir la ruta de guardado del archivo.

Cargada la imagen, el usuario podrá visualizar en un label, el nombre del archivo seguido del corte actual de la imagen (por defecto se carga en el corte medio) y el número total de cortes de la misma, a su vez, en otro label se imprime si se detectan lesiones, y de serlo así, proyecta la suma del diámetro mayor de aquellas 2 lesiones de tamaño más significativo (RECIST 1.1). En la siguiente imagen se presenta dicha descripción (Ver imagen 14).

Imagen 14. Interfaz usuario / Imagen CT y otros datos.

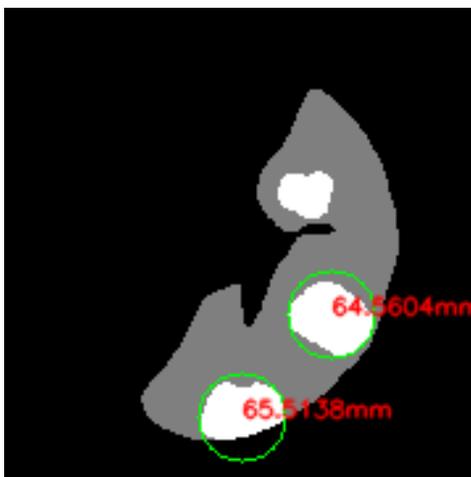


Elaboración propia.

Nota: La conversión de píxeles a milímetros viene dada por las dimensiones de los vóxeles de las imágenes.

Por otro lado, el botón de guardado proporciona la máscara de segmentación obtenida por la IA para un posterior uso de la misma, a su vez, entrega una imagen bidimensional en la que se indican aquellas lesiones de mayor tamaño y su diámetro mayor aproximado (Ver imagen 15). La segmentación entregada puede ser usada para verificar la correcta detección de lesiones en un software que permita el uso de las mismas, se recomienda el uso de 3D-Slicer.

Imagen 15. Imagen de salida / Diámetros máximos de lesiones.



Elaboración propia.

Finalmente, el usuario puede indicar el valor de comparación en una caja de texto, en donde en el modo automático se presenta el mensaje de la evaluación del tratamiento según RECIST 1.1, el cual se va actualizando a medida que se cambia de corte en la imagen. Para el modo manual, el especialista ingresa el valor inicial y los 2 valores correspondientes a los diámetros mayores de las lesiones diana seleccionadas, esto según criterio del profesional, para posteriormente entregar el

resultado de la evaluación del tratamiento según los criterios RECIST 1.1. Esto se expone en la imagen 16.

Imagen 16. Interfaz usuario / Calculo automático de RECIST 1.1

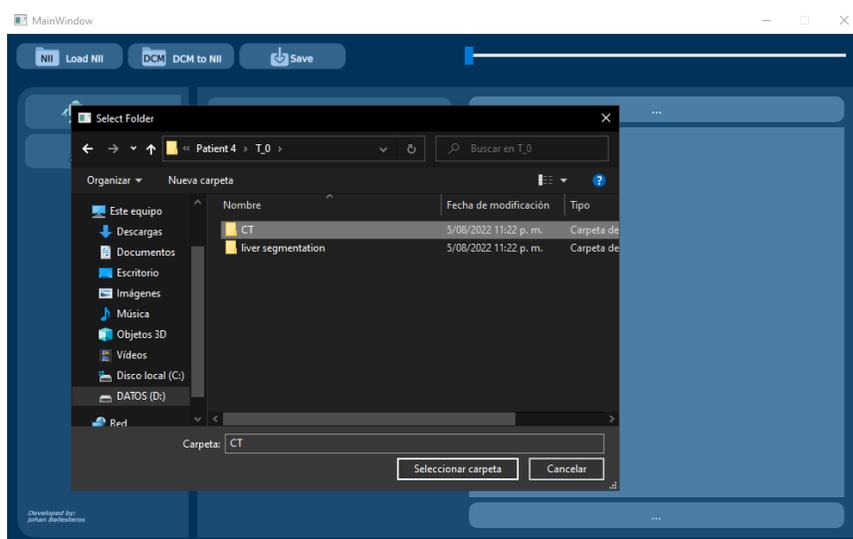


Elaboración propia.

3.3.Etapa 3. Evaluación del software

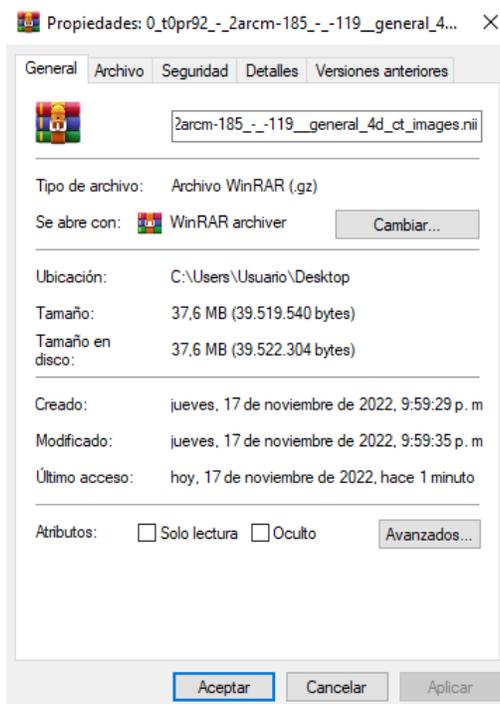
Para la evaluación del aplicativo, se ejecutaron todas las funciones que posee el mismo, con el fin de comprobar un funcionamiento global de este, es decir, que funcione correctamente con imágenes de TC de distinto tamaño y zonas de corte, además de que proporcione al usuario los archivos necesarios tras el guardado del análisis de segmentación. En las siguientes imágenes se expone la conversión de DCM a NII (Ver imágenes 17 y 18).

Imagen 17. Selección directorio DCM.



Elaboración propia.

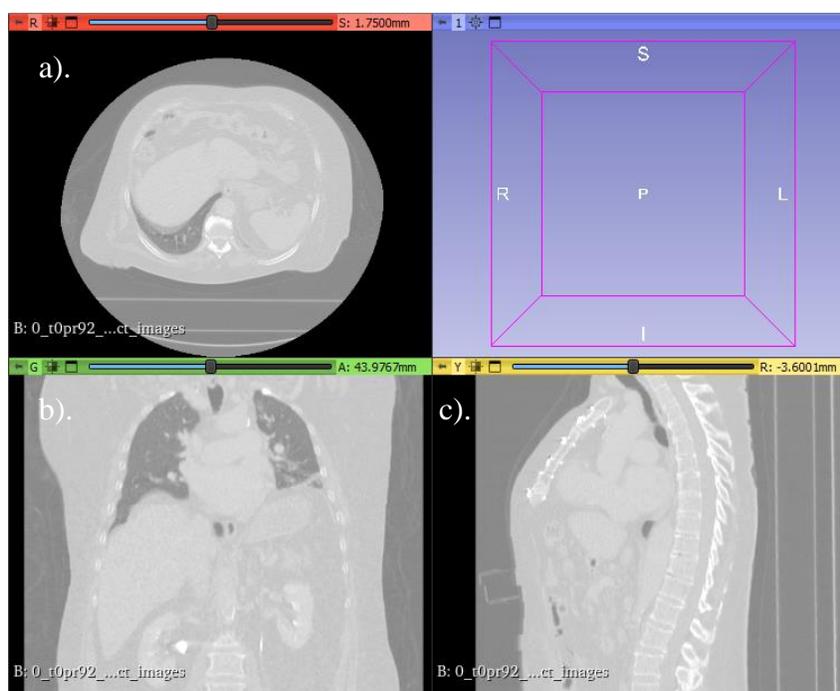
Imagen 18. Archivo NII de salida.



Elaboración propia.

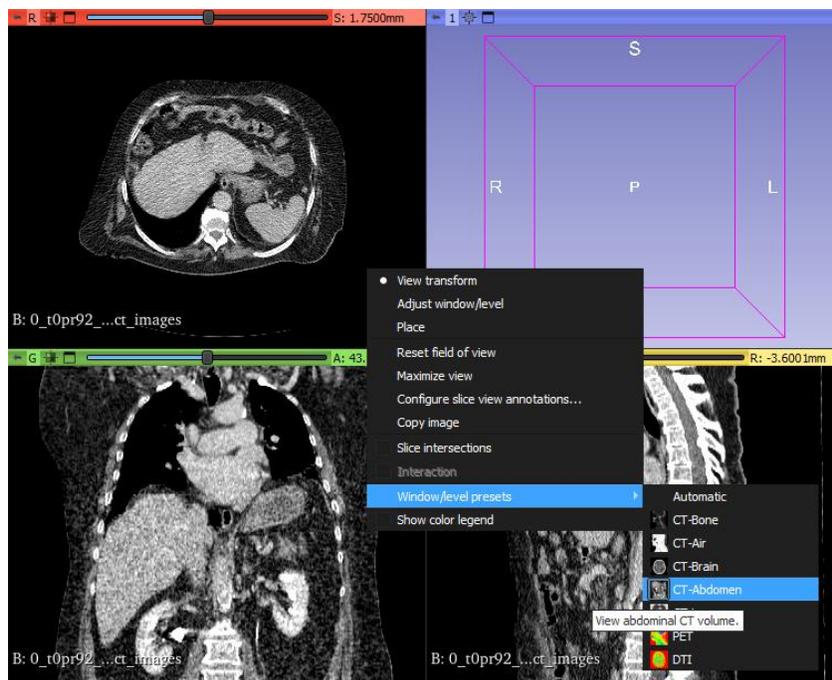
Obtenido el archivo de salida, se realiza la carga del mismo en 3D-Slicer para comprobar su correcta conversión. En la imagen 19 se visualiza que el archivo se encuentra demasiado iluminado, pero tras la aplicación de la ventana de vista para abdomen, se puede analizar fácilmente (Ver imagen 20).

Imagen 19. Imagen DCM convertida a NII / Ventana automática. a). Vista axial, b). Vista frontal, c). Vista sagital



Elaboración propia.

Imagen 20. Imagen DCM convertida a NII / Ventana abdomen.

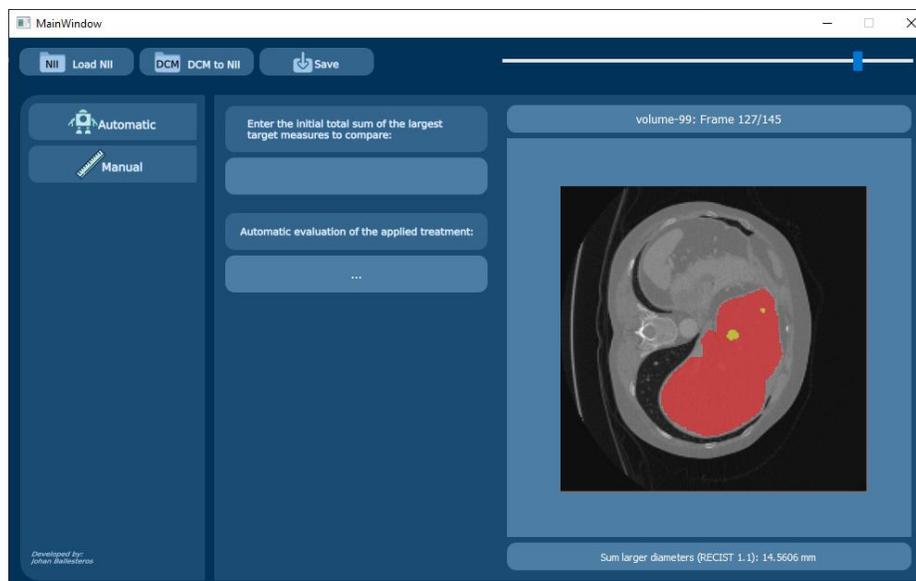


Elaboración propia.

Con lo anterior comprobamos que las imágenes se convirtieron correctamente, sin embargo, no se recomienda cargar este tipo de imágenes en la interfaz, puesto que al provenir de un directorio DCM, se requiere un procesamiento distinto al aplicado para imágenes NII, lo que puede ocasionar una segmentación de mala calidad y poco fiable.

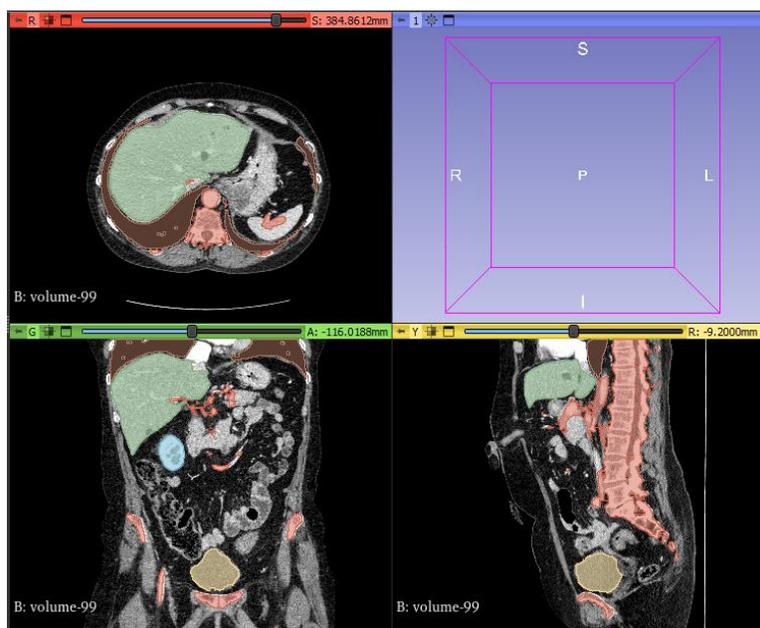
En cuanto al botón para cargar archivos NII, se carga la imagen llamada “volume-99.nii.gz”, obtenida a través del Archivo de Imágenes de Cáncer (TCIA), el cual proporciona un banco de 100 imágenes de CT que abarcan distintos órganos en su segmentación, con lo cual podemos comparar si efectivamente nuestra IA está segmentado de forma correcta el hígado y las posibles lesiones de este. Como se evidencia en las imágenes 21 y 22 la eficiencia del modelo entrenado.

Imagen 21. Interfaz usuario / Imagen CT “volume-99.nii.gz”



Elaboración propia.

Imagen 22. 3D-Slider / Imagen CT “volume-99.nii.gz” y su máscara “label-99.nii.gz”

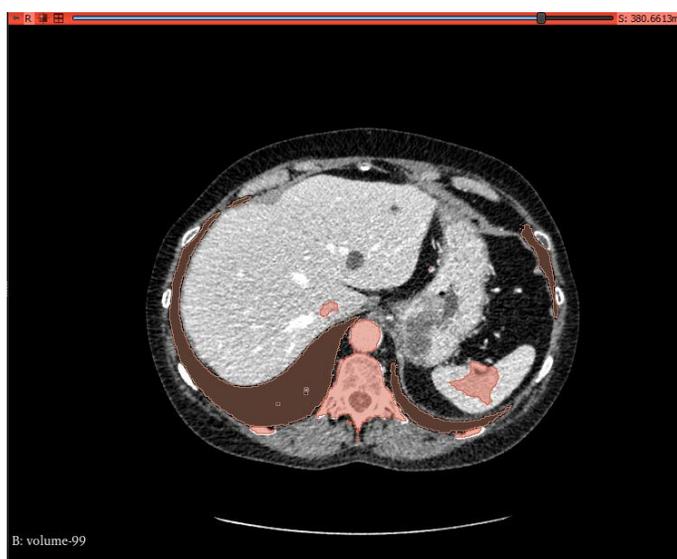


Elaboración propia.

La segmentación hepática se logra mediante evidencia visual, la cual es certificada por el Dr. Carlos, especialista en radiología, cuyo aval se encuentra en el apartado de anexos (Ver anexo 1).

Tal como se observa, la segmentación hepática es correcta, y al momento de evidenciar la presencia de posibles lesiones en la imagen original, observamos dos lesiones que se ubican en la misma posición que predijo la IA. La imagen 23 respalda lo dicho anteriormente.

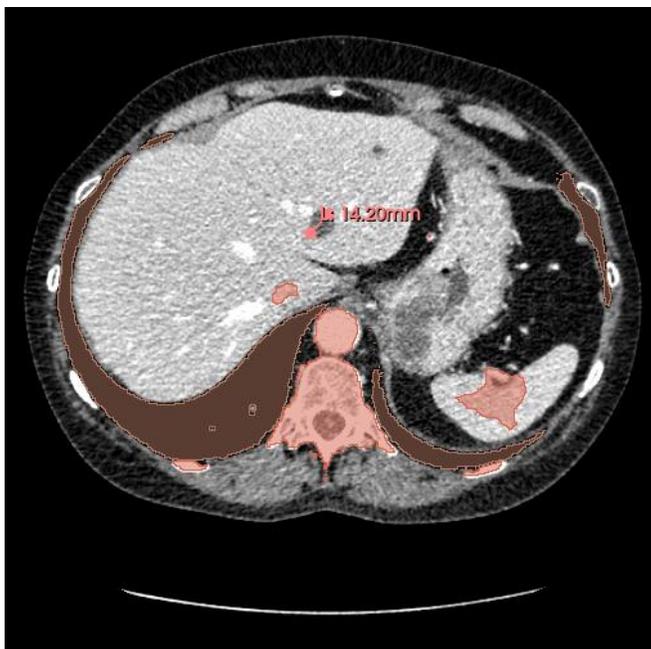
Imagen 23. 3D-Slider / Imagen CT “volume-99.nii.gz” – Lesiones



Elaboración propia.

Por otro lado, la medida de la lesión que arroja la interfaz diseñada corresponde a 14,5606 mm en su diámetro mayor, lo cual, al ser comparado con el diámetro mayor de dicha lesión obtenido manualmente que corresponde a 14,20 mm, indicando una gran precisión en la obtención de dicha variable (Ver imagen 24 y 25).

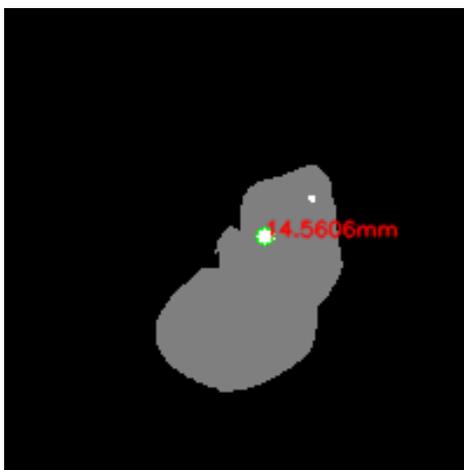
Imagen 24. 3D-Slider / Imagen CT “volume-99.nii.gz”- Diámetro de la lesión



Elaboración propia.

A continuación, se guarda el archivo de segmentación obtenido por nuestra IA, el cual termina de soportar la medida entregada anteriormente.

Imagen 25. Imagen de salida / Diámetro de la lesión aplicable a “lesión diana”



Elaboración propia.

La metodología presentada anteriormente, permitió realizar la adecuación de la base de datos, el diseño del modelo de segmentación a partir de CNN, el desarrollo de la interfaz de usuario y el análisis de los archivos de salida generados. La discusión y análisis de resultados obtenidos tras la comprobación del conjunto de datos destinado a validación se presenta en el siguiente capítulo.

Capítulo 4

Resultados

En el presente capítulo contiene los resultados obtenidos tras el entrenamiento del modelo de segmentación hepática, y la obtención de los diámetros mayores correspondientes a aquellas lesiones que aplican a la categoría diana, lo cual fue descrito en la metodología previamente expuesta. Tras la presentación de resultados se da un análisis de los mismos.

4.1. Presentación de resultados

4.1.1. Diseño del software

Tras el entrenamiento del modelo de segmentación se llevó a cabo la extracción de métricas de forma manual, puesto que a como se mencionó con anterioridad, Pytorch no permite la extracción de datos en tensores que contengan valores de tipo *string*, es por esto que con el 20% de la base de datos adecuada se realizó el proceso de validación de la IA desarrollada. Se extrajeron las métricas de exactitud, precisión, recuerdo y matriz de confusión del modelo entrenado.

En la tabla 6 se evidencian los datos obtenidos de dicha validación.

Tabla 6. Datos de funcionamiento del modelo de segmentación hepático entrenado.

| ARCHIVO | IMÁGENES CONTENIDAS | FN | FP | TN | TP |
|---------|------------------------|----|----|-----|----|
| 1 | 203 | 6 | 0 | 178 | 19 |
| 2 | 201 | 2 | 0 | 194 | 5 |
| 3 | 223 | 3 | 0 | 189 | 31 |
| 4 | 226 | 0 | 0 | 226 | 0 |
| 5 | 226 | 0 | 0 | 226 | 0 |
| 6 | 212 | 0 | 0 | 180 | 32 |

| | | | | | |
|--------------|-------------|-----------|----------|-------------|------------|
| 7 | 223 | 60 | 0 | 158 | 5 |
| 8 | 214 | 6 | 0 | 171 | 37 |
| 9 | 231 | 0 | 0 | 231 | 0 |
| 10 | 212 | 6 | 0 | 187 | 19 |
| 11 | 232 | 2 | 0 | 223 | 7 |
| 12 | 211 | 3 | 2 | 178 | 30 |
| 13 | 216 | 1 | 1 | 175 | 40 |
| 14 | 205 | 0 | 0 | 201 | 4 |
| 15 | 201 | 0 | 0 | 194 | 7 |
| 16 | 231 | 1 | 0 | 230 | 0 |
| 17 | 153 | 9 | 0 | 117 | 27 |
| 18 | 79 | 0 | 1 | 26 | 53 |
| TOTAL | 3699 | 99 | 4 | 3284 | 316 |

Elaboración propia.

Tabla 7. Métricas obtenidas.

| EXACTITUD | PRECISIÓN | RECUERDO |
|------------------|------------------|-----------------|
| 0,972184715 | 0,9875 | 0,761445783 |

Elaboración propia.

Tabla 8. Matriz de confusión.

| | |
|------------|-------------|
| 316 | 4 |
| 99 | 3284 |

Elaboración propia.

Expuestas las métricas mencionadas anteriormente, se procede dar la explicación de las mismas en la próxima sección del capítulo.

4.1.2. Evaluación del software

Dada la cantidad de datos a analizar, los cuales mediante la tabla anterior se obtienen que son 3699 imágenes de CT, la evaluación de la obtención de dimensiones por medio del software se ejecutó en un único archivo, de forma que se compara por un lado el diámetro mayor arrojado por el procesamiento aplicado sobre las máscaras de segmentación, contra el diámetro mayor que de forma manual se calcula mediante el software “3D-Slicer”.

A continuación, se presenta las tablas de medidas obtenidas mediante la interfaz diseñada y el software mencionado con anterioridad, en donde cada color y palabra número subrayado indica una lesión distinta, esto debido a la discriminación que aplica el software al elegir de forma automática las dos lesiones de mayor diámetro y que sea igual o superior a 10 mm, por lo que aquellas casillas marcadas en “0” indican que o bien no había una segunda lesión en dicho corte axial, o que la lesión no superaba o igualaba los 10 mm requeridos para ser considerada como lesión diana.

Tabla 9. Diámetros mayores por obtención automática.

| ARCHIVO: “LIVER 129” | DIÁMETRO AUTOMÁTICO (mm) | | SUMA DE LOS DIÁMETROS POR CORTE AXIAL (mm) |
|-------------------------|--------------------------|----------------|--|
| | LESIÓN 1 | LESIÓN 2 | |
| CORTE | | | |
| 13/78 | 17,0884 | 0 | 17,0884 |
| 14/78 | 35,4405 | 0 | 35,4405 |
| 15/78 | 41,7616 | 0 | 41,7616 |
| 16/78 | 49,5339 | 0 | 49,5339 |
| 17/78 | 56,64 | 0 | 56,64 |
| 18/78 | 59,5564 | 0 | 59,5564 |
| 19/78 | 56,3568 | 28,0286 | 84,3854 |
| 20/78 | 56,0151 | 34,4637 | 90,4788 |
| 21/78 | 56,0893 | 38,0793 | 94,1686 |
| 22/78 | 54,751 | 69,4266 | 124,1776 |
| 23/78 | 52,359 | 70,0004 | 122,3594 |
| 24/78 | 48,7234 | 72,8545 | 121,5779 |
| 25/78 | 44,6502 | 73,5237 | 118,1739 |

| | | | |
|-------|---------|---------|----------|
| 26/78 | 39,7393 | 73,6642 | 113,4035 |
| 27/78 | 22,9937 | 70,6447 | 93,6384 |
| 28/78 | 22,5097 | 66,1325 | 88,6422 |
| 29/78 | 34,1764 | 62,1293 | 96,3057 |
| 30/78 | 44,2723 | 57,2018 | 101,4741 |
| 31/78 | 50,0004 | 54,5248 | 104,5252 |
| 32/78 | 53,3671 | 58,8606 | 112,2277 |
| 33/78 | 55,7857 | 62,3096 | 118,0953 |
| 34/78 | 58,5813 | 63,4004 | 121,9817 |
| 35/78 | 62,8359 | 65,3188 | 128,1547 |
| 36/78 | 65,8586 | 65,7879 | 131,6465 |
| 37/78 | 66,5588 | 65,8854 | 132,4442 |
| 38/78 | 65,1464 | 65,1157 | 130,2621 |
| 39/78 | 65,5138 | 64,5604 | 130,0742 |
| 40/78 | 62,1488 | 64,0599 | 126,2087 |
| 41/78 | 61,6121 | 60,9266 | 122,5387 |
| 42/78 | 57,209 | 53,852 | 111,061 |
| 43/78 | 55,2395 | 39,9975 | 95,237 |
| 44/78 | 53,0802 | 52,9532 | 106,0334 |
| 45/78 | 47,5399 | 59,7025 | 107,2424 |
| 46/78 | 28,4257 | 62,7014 | 91,1271 |
| 47/78 | 28,1859 | 63,246 | 91,4319 |
| 48/78 | 38,9091 | 64,9284 | 103,8375 |
| 49/78 | 46,4565 | 65,9424 | 112,3989 |
| 50/78 | 52,9747 | 67,4309 | 120,4056 |
| 51/78 | 56,1124 | 68,718 | 124,8304 |
| 52/78 | 59,3813 | 70,1626 | 129,5439 |
| 53/78 | 63,246 | 69,5565 | 132,8025 |
| 54/78 | 67,2355 | 69,2556 | 136,4911 |
| 55/78 | 68,6839 | 68,9642 | 137,6481 |
| 56/78 | 70,0304 | 67,7527 | 137,7831 |
| 57/78 | 69,7175 | 67,8749 | 137,5924 |
| 58/78 | 68,6082 | 73,6528 | 142,261 |
| 59/78 | 67,7037 | 69,4266 | 137,1303 |
| 60/78 | 67,714 | 59,2288 | 126,9428 |
| 61/78 | 63,72 | 55,3177 | 119,0377 |
| 62/78 | 58,3099 | 50,0809 | 108,3908 |
| 63/78 | 50,8043 | 45,1736 | 95,9779 |
| 64/78 | 41,076 | 43,1745 | 84,2505 |
| 65/78 | 0 | 10,1984 | 10,1984 |

Elaboración propia.

Tabla 10. Diámetros mayores por obtención manual. Primera muestra.

| ARCHIVO: "LIVER 129" | DIÁMETRO MANUAL 1 (mm) | | SUMA DE LOS DIÁMETROS POR CORTE AXIAL (mm) |
|-------------------------|------------------------|----------|--|
| | LESIÓN 1 | LESIÓN 2 | |
| 13/78 | 17,66 | 0 | 17,66 |
| 14/78 | 34,08 | 0 | 34,08 |
| 15/78 | 41,48 | 0 | 41,48 |
| 16/78 | 47,64 | 0 | 47,64 |
| 17/78 | 54,95 | 0 | 54,95 |
| 18/78 | 62,51 | 0 | 62,51 |
| 19/78 | 55,56 | 29,21 | 84,77 |
| 20/78 | 57,85 | 33,44 | 91,29 |
| 21/78 | 57,69 | 38,41 | 96,1 |
| 22/78 | 55,45 | 69,03 | 124,48 |
| 23/78 | 50,09 | 70,39 | 120,48 |
| 24/78 | 46,09 | 71,82 | 117,91 |
| 25/78 | 42,52 | 70,04 | 112,56 |
| 26/78 | 39,07 | 69,69 | 108,76 |
| 27/78 | 24,27 | 69,22 | 93,49 |
| 28/78 | 26,27 | 65,68 | 91,95 |
| 29/78 | 34,97 | 61,09 | 96,06 |
| 30/78 | 42,53 | 57,26 | 99,79 |
| 31/78 | 52,3 | 54,47 | 106,77 |
| 32/78 | 53,25 | 58,32 | 111,57 |
| 33/78 | 58,05 | 61,97 | 120,02 |
| 34/78 | 60,66 | 64,04 | 124,7 |
| 35/78 | 62,33 | 65,73 | 128,06 |
| 36/78 | 66,34 | 64,93 | 131,27 |
| 37/78 | 68,94 | 65,3 | 134,24 |
| 38/78 | 65,99 | 65,21 | 131,2 |
| 39/78 | 63,89 | 66,77 | 130,66 |
| 40/78 | 65,12 | 67,79 | 132,91 |
| 41/78 | 61,83 | 63,7 | 125,53 |
| 42/78 | 58,14 | 54,51 | 112,65 |
| 43/78 | 55,29 | 42,01 | 97,3 |
| 44/78 | 54,11 | 56,57 | 110,68 |
| 45/78 | 50,95 | 61,26 | 112,21 |
| 46/78 | 30,57 | 64,23 | 94,8 |
| 47/78 | 29,81 | 60,62 | 90,43 |
| 48/78 | 41,83 | 62,66 | 104,49 |
| 49/78 | 43,64 | 63,46 | 107,1 |
| 50/78 | 52 | 67,58 | 119,58 |

| | | | |
|-------|--------------|-------|--------|
| 51/78 | <u>56,13</u> | 68,77 | 124,9 |
| 52/78 | <u>60,75</u> | 69,92 | 130,67 |
| 53/78 | <u>66,03</u> | 67,66 | 133,69 |
| 54/78 | <u>67,9</u> | 67,16 | 135,06 |
| 55/78 | <u>68,86</u> | 68,93 | 137,79 |
| 56/78 | <u>70,73</u> | 67,45 | 138,18 |
| 57/78 | <u>70,16</u> | 67,65 | 137,81 |
| 58/78 | <u>70,6</u> | 75,87 | 146,47 |
| 59/78 | <u>66,98</u> | 72,49 | 139,47 |
| 60/78 | <u>64,76</u> | 65,11 | 129,87 |
| 61/78 | <u>60,51</u> | 56,47 | 116,98 |
| 62/78 | <u>55,36</u> | 53,4 | 108,76 |
| 63/78 | <u>46,4</u> | 48,36 | 94,76 |
| 64/78 | <u>39,25</u> | 44,59 | 83,84 |
| 65/78 | 0 | 15,29 | 15,29 |

Elaboración propia.

Tabla 11. Diámetros mayores por obtención manual. Segunda muestra.

| ARCHIVO: "LIVER_129" | DIÁMETRO MANUAL 2 (mm) | | SUMA DE LOS DIÁMETROS POR CORTE AXIAL (mm) |
|-------------------------|------------------------|----------|--|
| | LESIÓN 1 | LESIÓN 2 | |
| 13/78 | 17,23 | 0 | 17,23 |
| 14/78 | 37,68 | 0 | 37,68 |
| 15/78 | 40,04 | 0 | 40,04 |
| 16/78 | 45,5 | 0 | 45,5 |
| 17/78 | 58,06 | 0 | 58,06 |
| 18/78 | 64,82 | 0 | 64,82 |
| 19/78 | 52,3 | 30,66 | 82,96 |
| 20/78 | 51,24 | 33,18 | 84,42 |
| 21/78 | 53,69 | 37,95 | 91,64 |
| 22/78 | 53,18 | 70,73 | 123,91 |
| 23/78 | 50,55 | 72,6 | 123,15 |
| 24/78 | 47,48 | 71,94 | 119,42 |
| 25/78 | 44,39 | 72,74 | 117,13 |
| 26/78 | 38,34 | 73,36 | 111,7 |
| 27/78 | 24,23 | 72,76 | 96,99 |
| 28/78 | 22,56 | 66,92 | 89,48 |
| 29/78 | 29,88 | 60,14 | 90,02 |
| 30/78 | 41,39 | 57,37 | 98,76 |
| 31/78 | 49,1 | 52,15 | 101,25 |
| 32/78 | 53,52 | 56,54 | 110,06 |

| | | | |
|-------|-------|-------|--------|
| 33/78 | 55,76 | 59,53 | 115,29 |
| 34/78 | 60,02 | 62,22 | 122,24 |
| 35/78 | 62,08 | 64,56 | 126,64 |
| 36/78 | 64,53 | 64,89 | 129,42 |
| 37/78 | 67,06 | 66,55 | 133,61 |
| 38/78 | 64,93 | 64,07 | 129 |
| 39/78 | 64,15 | 63,9 | 128,05 |
| 40/78 | 63,33 | 64,69 | 128,02 |
| 41/78 | 59,98 | 61,9 | 121,88 |
| 42/78 | 57,68 | 53,29 | 110,97 |
| 43/78 | 57,23 | 43,08 | 100,31 |
| 44/78 | 54,98 | 57,85 | 112,83 |
| 45/78 | 47,71 | 61,65 | 109,36 |
| 46/78 | 30,81 | 62,82 | 93,63 |
| 47/78 | 32,82 | 64 | 96,82 |
| 48/78 | 42,26 | 65,38 | 107,64 |
| 49/78 | 48,74 | 63,64 | 112,38 |
| 50/78 | 53,5 | 68,79 | 122,29 |
| 51/78 | 57,1 | 69,97 | 127,07 |
| 52/78 | 56,81 | 70,35 | 127,16 |
| 53/78 | 61,6 | 70,91 | 132,51 |
| 54/78 | 66,17 | 68,67 | 134,84 |
| 55/78 | 66,4 | 65,95 | 132,35 |
| 56/78 | 69,59 | 66,91 | 136,5 |
| 57/78 | 68,98 | 66,58 | 135,56 |
| 58/78 | 65,27 | 68,71 | 133,98 |
| 59/78 | 65,33 | 63,3 | 128,63 |
| 60/78 | 67,88 | 62,75 | 130,63 |
| 61/78 | 60,81 | 55,81 | 116,62 |
| 62/78 | 55,69 | 52,84 | 108,53 |
| 63/78 | 50,66 | 49,71 | 100,37 |
| 64/78 | 37,79 | 44,35 | 82,14 |
| 65/78 | 0 | 16,64 | 16,64 |

Elaboración propia.

Tabla 12. Diámetros mayores por obtención manual. Tercera muestra.

| ARCHIVO: "LIVER 129" | DIÁMETRO MANUAL 3 (mm) | | SUMA DE LOS DIÁMETROS POR CORTE AXIAL (mm) | |
|-------------------------|------------------------|----------|--|----------|
| | CORTE | LESIÓN 1 | | LESIÓN 2 |
| | 13/78 | 18,543 | 0 | 18,543 |
| | 14/78 | 35,784 | 0 | 35,784 |

| | | | |
|-------|---------|---------|----------|
| 15/78 | 43,554 | 0 | 43,554 |
| 16/78 | 50,022 | 0 | 50,022 |
| 17/78 | 57,6975 | 0 | 57,6975 |
| 18/78 | 65,6355 | 0 | 65,6355 |
| 19/78 | 58,338 | 30,6705 | 89,0085 |
| 20/78 | 60,7425 | 35,112 | 95,8545 |
| 21/78 | 60,5745 | 40,3305 | 100,905 |
| 22/78 | 58,2225 | 72,4815 | 130,704 |
| 23/78 | 52,5945 | 73,9095 | 126,504 |
| 24/78 | 48,3945 | 75,411 | 123,8055 |
| 25/78 | 44,646 | 73,542 | 118,188 |
| 26/78 | 41,0235 | 73,1745 | 114,198 |
| 27/78 | 25,4835 | 72,681 | 98,1645 |
| 28/78 | 27,5835 | 68,964 | 96,5475 |
| 29/78 | 36,7185 | 64,1445 | 100,863 |
| 30/78 | 44,6565 | 60,123 | 104,7795 |
| 31/78 | 54,915 | 57,1935 | 112,1085 |
| 32/78 | 55,9125 | 61,236 | 117,1485 |
| 33/78 | 60,9525 | 65,0685 | 126,021 |
| 34/78 | 63,693 | 67,242 | 130,935 |
| 35/78 | 65,4465 | 69,0165 | 134,463 |
| 36/78 | 69,657 | 68,1765 | 137,8335 |
| 37/78 | 72,387 | 68,565 | 140,952 |
| 38/78 | 69,2895 | 68,4705 | 137,76 |
| 39/78 | 67,0845 | 70,1085 | 137,193 |
| 40/78 | 68,376 | 71,1795 | 139,5555 |
| 41/78 | 64,9215 | 66,885 | 131,8065 |
| 42/78 | 61,047 | 57,2355 | 118,2825 |
| 43/78 | 58,0545 | 44,1105 | 102,165 |
| 44/78 | 56,8155 | 59,3985 | 116,214 |
| 45/78 | 53,4975 | 64,323 | 117,8205 |
| 46/78 | 32,0985 | 67,4415 | 99,54 |
| 47/78 | 31,3005 | 63,651 | 94,9515 |
| 48/78 | 43,9215 | 65,793 | 109,7145 |
| 49/78 | 45,822 | 66,633 | 112,455 |
| 50/78 | 54,6 | 70,959 | 125,559 |
| 51/78 | 58,9365 | 72,2085 | 131,145 |
| 52/78 | 63,7875 | 73,416 | 137,2035 |
| 53/78 | 69,3315 | 71,043 | 140,3745 |
| 54/78 | 71,295 | 70,518 | 141,813 |
| 55/78 | 72,303 | 72,3765 | 144,6795 |
| 56/78 | 74,2665 | 70,8225 | 145,089 |
| 57/78 | 73,668 | 71,0325 | 144,7005 |

| | | | |
|-------|----------------|---------|----------|
| 58/78 | <u>74,13</u> | 79,6635 | 153,7935 |
| 59/78 | <u>70,329</u> | 76,1145 | 146,4435 |
| 60/78 | <u>67,998</u> | 68,3655 | 136,3635 |
| 61/78 | <u>63,5355</u> | 59,2935 | 122,829 |
| 62/78 | <u>58,128</u> | 56,07 | 114,198 |
| 63/78 | <u>48,72</u> | 50,778 | 99,498 |
| 64/78 | <u>41,2125</u> | 46,8195 | 88,032 |
| 65/78 | 0 | 16,0545 | 16,0545 |

Elaboración propia.

Tabla 13. Diámetros mayores por obtención manual. Cuarta muestra.

| ARCHIVO: "LIVER 129" | DIÁMETRO MANUAL 4 (mm) | | SUMA DE LOS DIÁMETROS POR CORTE AXIAL (mm) |
|-------------------------|------------------------|----------|--|
| | LESIÓN 1 | LESIÓN 2 | |
| 13/78 | 15,507 | 0 | 15,507 |
| 14/78 | 33,912 | 0 | 33,912 |
| 15/78 | 36,036 | 0 | 36,036 |
| 16/78 | 40,95 | 0 | 40,95 |
| 17/78 | 52,254 | 0 | 52,254 |
| 18/78 | 58,338 | 0 | 58,338 |
| 19/78 | 47,07 | 27,594 | 74,664 |
| 20/78 | 46,116 | 29,862 | 75,978 |
| 21/78 | 48,321 | 34,155 | 82,476 |
| 22/78 | 47,862 | 63,657 | 111,519 |
| 23/78 | 45,495 | 65,34 | 110,835 |
| 24/78 | 42,732 | 64,746 | 107,478 |
| 25/78 | 39,951 | 65,466 | 105,417 |
| 26/78 | 34,506 | 66,024 | 100,53 |
| 27/78 | 21,807 | 65,484 | 87,291 |
| 28/78 | 20,304 | 60,228 | 80,532 |
| 29/78 | 26,892 | 54,126 | 81,018 |
| 30/78 | 37,251 | 51,633 | 88,884 |
| 31/78 | 44,19 | 46,935 | 91,125 |
| 32/78 | 48,168 | 50,886 | 99,054 |
| 33/78 | 50,184 | 53,577 | 103,761 |
| 34/78 | 54,018 | 55,998 | 110,016 |
| 35/78 | 55,872 | 58,104 | 113,976 |
| 36/78 | 58,077 | 58,401 | 116,478 |
| 37/78 | 60,354 | 59,895 | 120,249 |
| 38/78 | 58,437 | 57,663 | 116,1 |
| 39/78 | 57,735 | 57,51 | 115,245 |

| | | | |
|-------|---------------|---------------|----------------|
| 40/78 | 56,997 | 58,221 | <i>115,218</i> |
| 41/78 | 53,982 | 55,71 | <i>109,692</i> |
| 42/78 | 51,912 | 47,961 | <i>99,873</i> |
| 43/78 | 51,507 | 38,772 | <i>90,279</i> |
| 44/78 | 49,482 | 52,065 | <i>101,547</i> |
| 45/78 | 42,939 | 55,485 | <i>98,424</i> |
| 46/78 | 27,729 | 56,538 | <i>84,267</i> |
| 47/78 | 29,538 | 57,6 | <i>87,138</i> |
| 48/78 | 38,034 | 58,842 | <i>96,876</i> |
| 49/78 | 43,866 | 57,276 | <i>101,142</i> |
| 50/78 | 48,15 | 61,911 | <i>110,061</i> |
| 51/78 | 51,39 | 62,973 | <i>114,363</i> |
| 52/78 | 51,129 | 63,315 | <i>114,444</i> |
| 53/78 | 55,44 | 63,819 | <i>119,259</i> |
| 54/78 | 59,553 | 61,803 | <i>121,356</i> |
| 55/78 | 59,76 | 59,355 | <i>119,115</i> |
| 56/78 | 62,631 | 60,219 | <i>122,85</i> |
| 57/78 | 62,082 | 59,922 | <i>122,004</i> |
| 58/78 | 58,743 | 61,839 | <i>120,582</i> |
| 59/78 | 58,797 | 56,97 | <i>115,767</i> |
| 60/78 | 61,092 | 56,475 | <i>117,567</i> |
| 61/78 | 54,729 | 50,229 | <i>104,958</i> |
| 62/78 | 50,121 | 47,556 | <i>97,677</i> |
| 63/78 | 45,594 | 44,739 | <i>90,333</i> |
| 64/78 | 34,011 | 39,915 | <i>73,926</i> |
| 65/78 | 0 | 14,976 | <i>14,976</i> |

Elaboración propia.

Posterior a la adquisición de datos manuales y automáticos, realizados por el grupo de estudiantes y especialista en radiología, se procede a hallar el valor promedio de la suma de los diámetros mayores de las lesiones diana identificadas, y de esta forma, obtener un porcentaje de “error” con el cual podamos obtener dicha variación por dato. Lo anterior se explica en las tablas 14 y 15.

Tabla 14. Promedio suma diámetros mayores manuales.

| CORTE | PROMEDIO DE LA SUMA DE LOS DIÁMETROS MAYORES (MM) |
|--------------|--|
| 13/78 | 17,235 |
| 14/78 | 35,364 |
| 15/78 | 40,2775 |
| 16/78 | 46,028 |
| 17/78 | 55,740375 |
| 18/78 | 62,825875 |
| 19/78 | 82,850625 |
| 20/78 | 86,885625 |
| 21/78 | 92,78025 |
| 22/78 | 122,65325 |
| 23/78 | 120,24225 |
| 24/78 | 117,153375 |
| 25/78 | 113,32375 |
| 26/78 | 108,797 |
| 27/78 | 93,983875 |
| 28/78 | 89,627375 |
| 29/78 | 91,99025 |
| 30/78 | 98,053375 |
| 31/78 | 102,813375 |
| 32/78 | 109,458125 |
| 33/78 | 116,273 |
| 34/78 | 121,97275 |
| 35/78 | 125,78475 |
| 36/78 | 128,750375 |
| 37/78 | 132,26275 |
| 38/78 | 128,515 |
| 39/78 | 127,787 |
| 40/78 | 128,925875 |
| 41/78 | 122,227125 |
| 42/78 | 110,443875 |
| 43/78 | 97,5135 |
| 44/78 | 110,31775 |
| 45/78 | 109,453625 |
| 46/78 | 93,05925 |
| 47/78 | 92,334875 |
| 48/78 | 104,680125 |
| 49/78 | 108,26925 |
| 50/78 | 119,3725 |
| 51/78 | 124,3695 |
| 52/78 | 127,369375 |

| | |
|-------|------------|
| 53/78 | 131,458375 |
| 54/78 | 133,26725 |
| 55/78 | 133,483625 |
| 56/78 | 135,65475 |
| 57/78 | 135,018625 |
| 58/78 | 138,706375 |
| 59/78 | 132,577625 |
| 60/78 | 128,607625 |
| 61/78 | 115,34675 |
| 62/78 | 107,29125 |
| 63/78 | 96,24025 |
| 64/78 | 81,9845 |
| 65/78 | 15,740125 |

Elaboración propia.

Tabla 15. Variación obtenida a través del porcentaje de error.

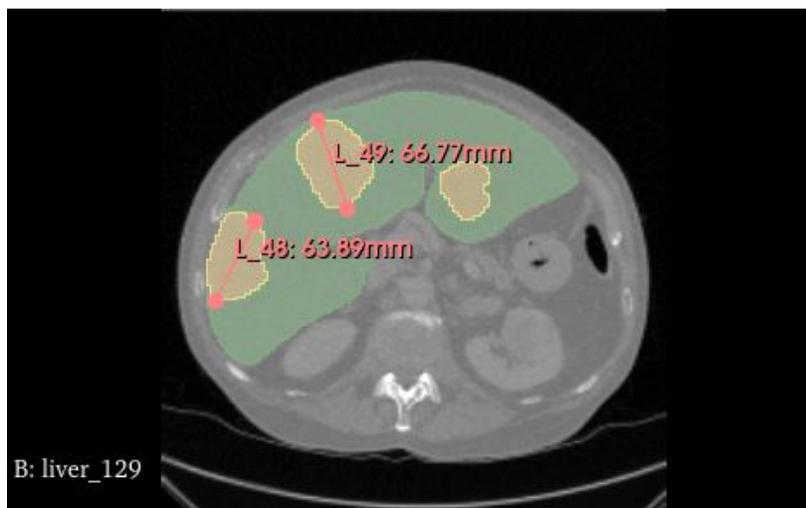
| CORTE | PORCENTAJE DE ERROR |
|--------------|----------------------------|
| 13/78 | 0,85059472 |
| 14/78 | 0,216321683 |
| 15/78 | 3,684687481 |
| 16/78 | 7,616885374 |
| 17/78 | 1,613955773 |
| 18/78 | 5,204026207 |
| 19/78 | 1,852460377 |
| 20/78 | 4,135522994 |
| 21/78 | 1,496385276 |
| 22/78 | 1,242812563 |
| 23/78 | 1,760737178 |
| 24/78 | 3,77669444 |
| 25/78 | 4,279906021 |
| 26/78 | 4,234032188 |
| 27/78 | 0,367589653 |
| 28/78 | 1,09918984 |
| 29/78 | 4,691203687 |
| 30/78 | 3,488635654 |
| 31/78 | 1,66498279 |
| 32/78 | 2,53025986 |
| 33/78 | 1,567259811 |
| 34/78 | 0,007337705 |
| 35/78 | 1,884131423 |
| 36/78 | 2,249410924 |
| 37/78 | 0,137189042 |
| 38/78 | 1,359452204 |

| | |
|--------------|--------------------|
| 39/78 | <i>1,789853428</i> |
| 40/78 | <i>2,107548233</i> |
| 41/78 | <i>0,254914774</i> |
| 42/78 | <i>0,558767972</i> |
| 43/78 | <i>2,33454855</i> |
| 44/78 | <i>3,883645198</i> |
| 45/78 | <i>2,020239165</i> |
| 46/78 | <i>2,076257868</i> |
| 47/78 | <i>0,977934935</i> |
| 48/78 | <i>0,804952229</i> |
| 49/78 | <i>3,814240886</i> |
| 50/78 | <i>0,865442208</i> |
| 51/78 | <i>0,370589252</i> |
| 52/78 | <i>1,707258907</i> |
| 53/78 | <i>1,022471942</i> |
| 54/78 | <i>2,41908646</i> |
| 55/78 | <i>3,119839606</i> |
| 56/78 | <i>1,568946167</i> |
| 57/78 | <i>1,90623701</i> |
| 58/78 | <i>2,562697641</i> |
| 59/78 | <i>3,433969344</i> |
| 60/78 | <i>1,294499451</i> |
| 61/78 | <i>3,199873425</i> |
| 62/78 | <i>1,024827281</i> |
| 63/78 | <i>0,272599043</i> |
| 64/78 | <i>2,763937086</i> |
| 65/78 | <i>35,20763018</i> |

Elaboración propia.

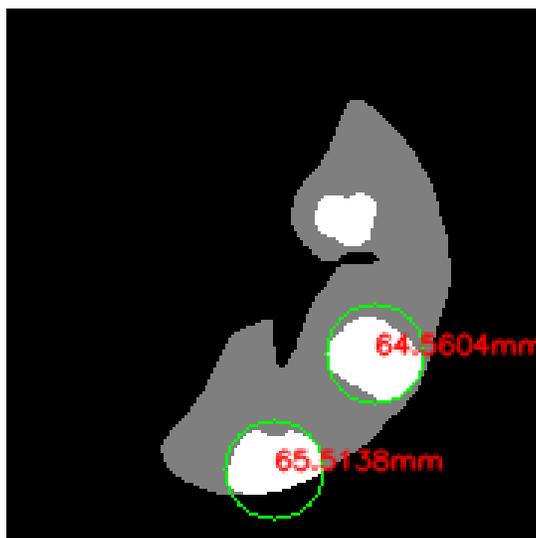
Expuestas las dimensiones de las lesiones de forma manual y automática en las tablas anteriores, se procede a evidenciar dichas medidas manuales obtenidas mediante el software “3D-Slicer” y aquellas máscaras de segmentación generadas por la IA con los respectivos diámetros de las lesiones diana (Ver imágenes 26 y 27).

Imagen 26. Medidas manuales correspondientes al corte 39/78 de la imagen volumétrica.



Elaboración propia.

Imagen 27. Medidas automáticas correspondientes al corte 39/78 de la imagen volumétrica.



Elaboración propia.

4.2. Análisis de resultados

4.2.1. Diseño del software

Durante el proceso de entrenamiento del modelo de segmentación hepática se presentaron distintos inconvenientes. Primeramente, los recursos computacionales en disposición de los estudiantes, puesto que el entrenamiento conlleva un gran gasto computacional de los equipos, por lo que en algunas ocasiones el entrenamiento no se desarrollaba hasta la época indicada o la capacidad de memoria RAM no era la indicada para el trabajo con archivos de grandes dimensiones. Para la solución de dicho inconveniente, fue necesario usar los computadores del laboratorio de sistemas puesto que sus componentes aceleraron el proceso de entrenamiento, sin embargo, en estos computadores aun fue complicado el entrenamiento de los archivos volumétricos en bruto, por lo que de igual manera fue necesario aplicar el procesamiento de los mismos, pero aumentando la cantidad de épocas de entrenamiento, las cuales fueron 1000.

Se selecciono dicho valor de épocas dado que, al mantener reuniones con el especialista en radiología, se notó que la segmentación hepática y tumoral hepática realizada con 200 épocas de entrenamiento era insatisfactoria, puesto que la máscara de segmentación se entregaba en una baja resolución, provocando la pérdida de información en el procesamiento de la imagen. El error mencionado se solucionó con el aumento de numero de épocas de entrenamiento.

Como ultimo inconveniente presentado en el diseño y evaluación del modelo de segmentación, se dificulto la adquisición automática de métricas de evaluación, ya que como se mencionó con anterioridad, los tensores de salida generados por el modelo de segmentación al contener valores de tipo *string*, imposibilitaban el cálculo de métricas como lo es la exactitud,

precisión, recuerdo y matriz de confusión. Este inconveniente solo pudo solucionarse de forma manual, puesto que la alternativa de trabajo con matrices de tipo numpy requería la extracción de imágenes individuales, por lo que no existiría un archivo volumétrico sino plano, lo cual contrariaba el desarrollo de este proyecto, el cual se enfoca en el procesamiento de imágenes de estudios de CT y MRI.

Mencionado lo anterior, al analizar las métricas de exactitud, precisión, recuerdo y matriz de confusión, se observa un porcentaje de exactitud correspondiente al 97,21%, lo que indica una alta eficiencia en la aproximación del valor real de las clases identificadas y segmentadas. Por otro lado, la precisión fue de 98,75% indicando una menor dispersión de datos. La sensibilidad o recuerdo, obtuvo un porcentaje de 76,14%, que si bien es alto, presenta una gran diferencia en cuanto a las otras métricas, este valor tan reducido se debe a que el modelo de segmentación no reconoce lesiones que ocupen un área reducida en la imagen, refiriéndonos a menos de 2 mm, puesto que no logra detallar correctamente los valores de los píxeles correspondientes al órgano y lesión, lo que en RECIST no afecta demasiado debido a la discriminación de diámetros que se aplican según sus criterios, sin embargo, se decidió tener en cuenta dichas segmentaciones pasadas por alto, clasificadas como falsos negativos, para una evaluación más objetiva del modelo entrenado.

Por último, en la matriz de confusión se evidencia que la cantidad de falsos negativos supera a aquellos clasificados como falsos positivos con creces, esto se debe a lo comentado en el párrafo anterior, ya que más de la mitad de las imágenes clasificadas como FN segmentaron eficientemente lesiones visibles, mientras que aquellas de dimensiones muy reducidas no se reconocieron. En cuanto a lo demás, se nota una gran cantidad de datos clasificados como

verdaderos positivos y verdaderos negativos, lo que hace de nuestro modelo entrenado, confiable en la segmentación y obtención de máscaras para imágenes volumétricas de CT.

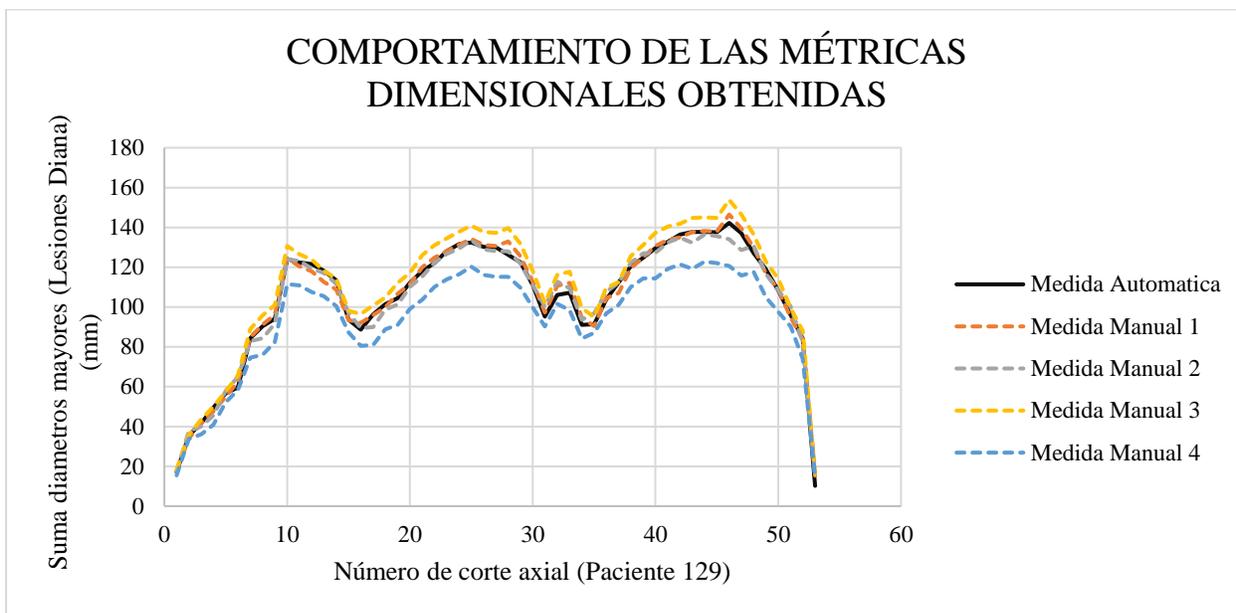
Cabe mencionar que, para obtener dichas métricas fue necesario analizar corte por corte de las imágenes volumétricas entregadas por el modelo entrenado, así como de la base de datos proporcionada por MSD, la cual como ya se mencionó, fue diseñada por especialistas en imágenes médicas.

4.2.2. Evaluación del software

Al analizar las dimensiones “reales” de los diámetros mayores entregadas por el modelo computacional desarrollado y las que se hallaron de forma manual, se evidencia una gran similitud en sus valores, lo que indica un gran acercamiento a la medida real de la lesión, dando solución de esta manera a nuestra problemática. Ahora bien, según el análisis realizado, el porcentaje de “error” de nuestro modelo respecto a las 4 medidas obtenidas manualmente indica un error no mayor al 5% en todas las imágenes muestreadas a excepción de una, en la cual se presenta un error del 35% que puede deberse a una ineficiente segmentación en el corte estudiado de la imagen volumétrica procesada.

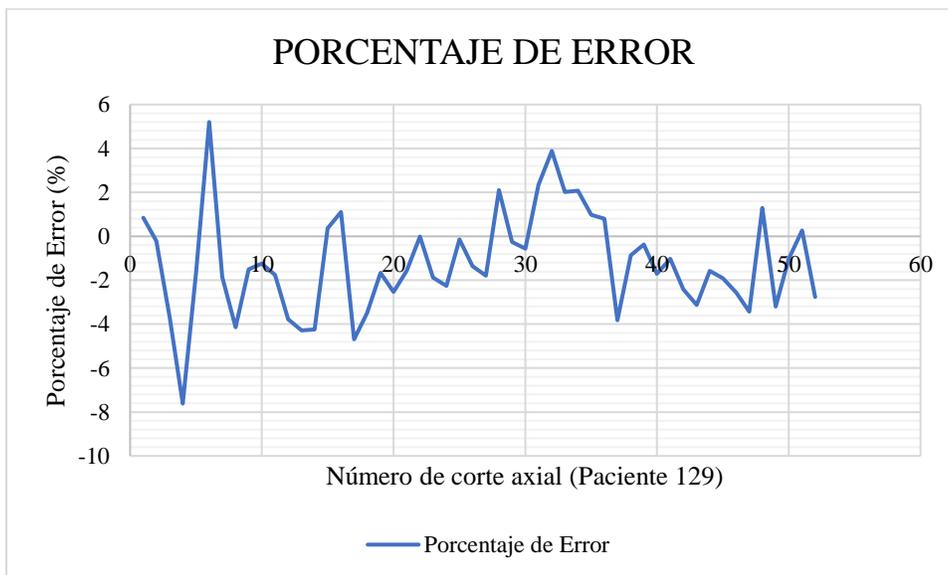
En la gráfica 1 se presencia el comportamiento de la métrica automática respecto a las cuatro (4) obtenidas de forma manual, en donde el eje “x” corresponde al número del corte axial en que se posiciona la lesión, y el eje “y” indica la suma de los dos diámetros mayores (si los hay) de las lesiones presentes. Por otro lado, la gráfica 2 indica el comportamiento del porcentaje de error relativo obtenido tras la extracción de las métricas dimensionales de la lesión de forma automática respecto al promedio de aquellas adquiridas de forma manual.

Grafica 1. Comportamiento de las métricas dimensionales obtenidas



Elaboración propia.

Grafica 2. Porcentaje de error.



Elaboración propia.

Sin más, se procede a dar las conclusiones y recomendaciones del aplicativo diseñado.

Capítulo 5

Conclusiones y recomendaciones

5.1. Conclusiones

A través del análisis realizado en el capítulo anterior, es importante definir las clases que estamos obteniendo y como estas pueden llegar a resolver el problema planteado para el objetivo del proyecto. Debido al uso de distintos formatos de imagen médicas, así como de las tecnologías que se ven relacionadas con estas, los resultados obtenidos pueden generar distintas respuestas de predicción y algunas limitantes.

Tras reuniones con el asesor externo del proyecto, se definió como único medio de obtención de imágenes médicas el tomógrafo, ya que este obtiene una imagen de alta información, lo cual permite realizar un mejor análisis de la misma y visualizar a su vez, una mejor identificación de estructuras internas del paciente, esto dado a la naturaleza de las imágenes de CT, las cuales tienden a ser más brillantes y de mejor calidad que aquellas que se obtienen mediante resonancia magnética. Por otro lado, la implementación de imágenes en formato DICOM se vio afectada puesto que en su gran mayoría, las imágenes generadas por dichos estudios son en formato nifti, las cuales fueron usadas para el entrenamiento del modelo, lo que al aplicar la predicción y segmentación de lesiones y órgano, mantiene una muy alta posibilidad de que la IA entrenada extraiga información de la imagen generada de forma errónea, que aunque aproxima la segmentación de hígado y posibles tumores, no es completamente fiable al compararse con aquellos archivos cuyo origen se da como formato “.nii.gz”.

Los diámetros calculados automáticamente a partir de una imagen preprocesada varían en ciertos valores porcentuales respecto a una imagen en bruto, dado que la IA entrenada fue diseñada para estudiar y analizar imágenes de un máximo aproximado de 256 píxeles de resolución en su corte axial, lo que al comparar con una imagen común que tiende a poseer una dimensión de 512x512 píxeles, expone un notorio grado de alejamiento respecto al valor real.

Finalmente, de las métricas obtenidas de la inteligencia entrenada se concluye que posee un alto grado de exactitud y precisión en el reconocimiento de lesiones, que, si bien puede que no reconozca aquellas inferiores a ciertos diámetros, expone una máscara de segmentación capaz de contener aquellas posibles lesiones de gran valor informativo.

5.2.Recomendaciones

Es de importancia reconocer la capacidad del sistema de cómputo a usarse, puesto que al trabajar con imágenes volumétricas, la densidad de parámetros obtenidos tiende a ser mayor respecto a aquellos que trabajan con imágenes en 2D, es por esto, que al contar con buenos requerimientos, en especial una GPU adecuada, el porcentaje de exactitud del modelo entrado puede elevarse o por lo menos, cumplir con la gran mayoría de imágenes sin necesidad de aplicar un preprocesamiento que reduzca las dimensiones de la imagen cargada, lo cual puede afectar notoriamente la calidad de la misma y a su vez, los datos extraídos de esta.

Se recomienda aplicar el entrenamiento de la IA a través de datos en su máxima resolución, o en lo posible, la mínima reducción posible en sus dimensiones, con el fin de obtener una imagen precisa y cercana a las dimensiones reales que pueden describir a la lesión identificada.

Se recomienda ampliar el preprocesamiento de imágenes a formato DICOM y a imágenes de resonancia magnética, de manera que se pueda incorporar la mayor cantidad de estudios posibles, no limitándose al trabajo de una única tecnología.

REFERENCIAS

Antonelli, M., Reinke, A., Bakas, S., Farahani, K., Kopp-Schneider, A., Landman, B. A., Litjens, G., Menze, B., Ronneberger, O., Summers, R. M., van Ginneken, B., Bilello, M., Bilic, P., Christ, P. F., Do, R. K. G., Gollub, M. J., Heckers, S. H., Huisman, H., Jarnagin, W. R., ... Cardoso, M. J. (2022a). The Medical Segmentation Decathlon. *Nature Communications* 2022 13:1, 13(1), 1–13. <https://doi.org/10.1038/s41467-022-30695-9>

Antonelli, M., Reinke, A., Bakas, S., Farahani, K., Kopp-Schneider, A., Landman, B. A., Litjens, G., Menze, B., Ronneberger, O., Summers, R. M., van Ginneken, B., Bilello, M., Bilic, P., Christ, P. F., Do, R. K. G., Gollub, M. J., Heckers, S. H., Huisman, H., Jarnagin, W. R., ... Cardoso, M. J. (2022b). The Medical Segmentation Decathlon. *Nature Communications*, 13(1). <https://doi.org/10.1038/S41467-022-30695-9>

Bali, M. A., Pullini, S., Metens, T., Absil, J., Chao, S.-L., Marechal, R., Matos, C., Peerboccus, B. M., & van Laethem, J.-L. (2018). Assessment of response to chemotherapy in pancreatic ductal adenocarcinoma: Comparison between diffusion-weighted MR quantitative parameters and RECIST. *European Journal of Radiology*, 104, 49–57. <https://doi.org/10.1016/j.ejrad.2018.04.024>

Cancer Today. (n.d.). Retrieved April 4, 2022, from https://gco.iarc.fr/today/online-analysismap?v=2020&mode=population&mode_population=continents&population=900&populations=900&key=asr&sex=0&cancer=39&type=0&statistic=5&prevalence=0&population_group=0&ages_group%5B%5D=0&ages_group%5B%5D=17&nb_items=10&group_cancer=1&include_nmssc=0&include_nmssc_other=0&projection=naturalearth&color_palette=default&map_sca

le=quantile&map_nb_colors=5&continent=0&show_ranking=0&rotate=%255B10%252C0%25

D

Carreño-Dueñas, J. A., Sánchez, J. O., Bermúdez-Silva, C. D., & Mesa, M. (2014). Errores en la formulación de quimioterapia. *Revista Colombiana de Cancerología*, 18(4), 179–185. <https://doi.org/10.1016/j.rccan.2014.08.003>

Cervera Deval, J. (2014a). RECIST y el radiólogo. *Radiología*, 56(3), 193–205. <https://doi.org/10.1016/J.RX.2012.03.010>

Common Cancer Types - NCI. (n.d.-a). Retrieved November 22, 2022, from <https://www.cancer.gov/types/common-cancers>

CT-ORG: CT volumes with multiple organ segmentations - The Cancer Imaging Archive (TCIA) Public Access - Cancer Imaging Archive Wiki. (n.d.). Retrieved April 27, 2022, from <https://wiki.cancerimagingarchive.net/display/Public/CTORG%3A+CT+volumes+with+multiple+organ+segmentations>

Decreto 1360 de 1989 - Gestor Normativo - Función Pública. (n.d.). Retrieved April 27, 2022, from <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=10575>

Decreto 1474 de 2002 Nivel Nacional. (n.d.). Retrieved May 5, 2022, from <https://www.alcaldiabogota.gov.co/sisjur/normas/Normal.jsp?i=6076&dt=S>

Fenerty, K. E., Folio, L. R., Patronas, N. J., Martí, J. L., Gulley, J. L., & Heery, C. R. (2016). Predicting clinical outcomes in chordoma patients receiving immunotherapy: a

comparison between volumetric segmentation and RECIST. *BMC Cancer*, 16(1), 672.
<https://doi.org/10.1186/s12885-016-2699-x>

Gambino, O., Vitabile, S., lo Re, G., la Tona, G., Librizzi, S., Pirrone, R., Ardizzone, E., & Midiri, M. (2010). Automatic Volumetric Liver Segmentation Using Texture Based Region Growing. 2010 International Conference on Complex, Intelligent and Software Intensive Systems, 146–152. <https://doi.org/10.1109/CISIS.2010.118>

History and License — Python 3.10.4 documentation. (n.d.). Retrieved April 27, 2022, from <https://docs.python.org/3/license.html>

Introduction to Magnetic Resonance Imaging (MRI). (n.d.). Retrieved April 4, 2022, from <https://www.maximintegrated.com/en/design/technical-documents/tutorials/4/4681.html>

Ley 23 de 1982 - Gestor Normativo - Función Pública. (n.d.). Retrieved April 27, 2022, from <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=3431>

Ley 44 de 1993 Nivel Nacional. (n.d.). Retrieved May 5, 2022, from <https://www.alcaldiabogota.gov.co/sisjur/normas/Norma1.jsp?i=3429>

Medical Image Segmentation. (n.d.). Retrieved April 4, 2022, from <https://www5.cs.fau.de/research/groups/medical-image-segmentation/index.html>

Medical Imaging | FDA. (n.d.). Retrieved April 4, 2022, from <https://www.fda.gov/radiation-emittingproducts/radiation-emitting-products-and-procedures/medical-imaging>

Moltz, J. hendrik, Bornemann, L., Dicken, V., & Peitgen, H.-O. (2008). Segmentation of Liver Metastases in CT Scans by Adaptive Thresholding and Morphological Processing. The MIDAS Journal. <https://doi.org/10.54294/msg94u>

¿Qué es inteligencia artificial? | IBM. (n.d.). Retrieved April 4, 2022, from <https://www.ibm.com/coes/analytics/journey-to-ai>

RECIST. (n.d.). Retrieved April 4, 2022, from <https://recist.eortc.org/>

RECIST 1.1 - Calyx Informatics. (n.d.). Retrieved April 4, 2022, from <https://www.recist.com/recist/recist-inpractice/01.php>

Segmentación de imágenes - MATLAB & Simulink - MathWorks América Latina. (n.d.). Retrieved May 5, 2022, from <https://la.mathworks.com/help/images/image-segmentation.html>

Seo, H., Huang, C., Bassenne, M., Xiao, R., & Xing, L. (2020). Modified U-Net (mU-Net) With Incorporation of Object-Dependent High Level Features for Improved Liver and Liver-Tumor Segmentation in CT Images. IEEE Transactions on Medical Imaging, 39(5), 1316–1325. <https://doi.org/10.1109/TMI.2019.2948320>

Shanbhogue, A. K. P., Karnad, A. B., & Prasad, S. R. (2010). Tumor Response Evaluation in Oncology. Journal of Computer Assisted Tomography, 34(4), 479–484. <https://doi.org/10.1097/RCT.0b013e3181db2670>

SICE - Comunidad Andina - Decisión 351. (n.d.). Retrieved April 27, 2022, from <http://www.sice.oas.org/trade/junac/decisiones/dec351s.asp>

Tan, M., Li, Z., Qiu, Y., McMeekin, S. D., Thai, T. C., Ding, K., Moore, K. N., Liu, H., & Zheng, B. (2015). A New Approach to Evaluate Drug Treatment Response of Ovarian Cancer Patients Based on Deformable Image Registration. *IEEE Transactions on Medical Imaging*, 35(1), 316–325. <https://doi.org/10.1109/TMI.2015.2473823>

Taner, A., Öztekin, Y. B., & Duran, H. (2021). Performance analysis of deep learning cnn models for variety classification in Hazelnut. *Sustainability (Switzerland)*, 13(12). <https://doi.org/10.3390/SU13126527>

Tang, Y., Tang, Y., Zhu, Y., Xiao, J., & Summers, R. M. (2020). E²Net: An Edge Enhanced Network for Accurate Liver and Tumor Segmentation on CT Scans. <http://arxiv.org/abs/2007.09791>

TorchIO. (n.d.). Retrieved November 22, 2022, from <https://torchio.readthedocs.io/index.html>

What is Deep Learning? | IBM. (n.d.). Retrieved April 4, 2022, from <https://www.ibm.com/cloud/learn/deeplearning>

What Is Diagnostic Imaging? - Health Images. (n.d.). Retrieved April 4, 2022, from <https://www.healthimages.com/what-is-diagnostic-imaging/>

What is Machine Learning? | IBM. (n.d.). Retrieved April 4, 2022, from <https://www.ibm.com/cloud/learn/machine-learning>

Zhang, X., Tian, J., Deng, K., Wu, Y., & Li, X. (2010). Automatic Liver Segmentation Using a Statistical Shape Model With Optimal Surface Detection. *IEEE Transactions on Biomedical Engineering*, 57(10), 2622–2626. <https://doi.org/10.1109/TBME.2010.2056369>

Zhang, Y., Peng, C., Peng, L., Xu, Y., Lin, L., Tong, R., Peng, Z., Mao, X., Hu, H., Chen, Y.-W., & Li, J. (2021). DeepRecS: From RECIST Diameters to Precise Liver Tumor Segmentation. *IEEE Journal of Biomedical and Health Informatics*, 26(2), 614–625. <https://doi.org/10.1109/JBHI.2021.3091900>

ANEXOS

Los anexos se encuentran como documentos ajenos al libro, por lo que se presentan de manera completa en la entrega del proyecto realizado.

a) Anexo 1: Carta de soporte del especialista

CARTA DE SOPORTE

Bucaramanga, Colombia, 28 de noviembre de 2022

A QUIEN CORRESPONDA

PRESENTE

Por medio del presente documento, Yo, **Carlos Andrés Arias Duran** de nacionalidad colombiana y con número de cedula de ciudadanía 1.098.666.645, expedida en la ciudad de Bucaramanga , expreso mi respaldo y participación en las pruebas de eficiencia aplicadas sobre el software "*Programa informático de apoyo para la evaluación del desarrollo de tumores mediante el método RECIST aplicando procesamiento digital de imágenes biomédicas.*", desarrollado por los estudiantes **Johan Steven Ballesteros Rincón** y **Oskar Daliegt Guzmán Trillos** del programa de ingeniería biomédica, avalando así el correcto ejercicio de extracción de datos biométricos y a su vez, el adecuado análisis de las métricas obtenidas del aplicativo implementado. En virtud de lo anterior, agradezco considerar lo mencionado con fines académicos para los estudiantes.



Carlos Andrés Arias Duran

C.C. 1.098.666.645 de Bucaramanga

b) Anexo 2: Manual de usuario

| | |
|---|---|
|  | Programa informático de apoyo para la evaluación del desarrollo de tumores mediante el método RECIST aplicando procesamiento digital de imágenes biomédicas a través de inteligencia artificial |
|---|---|

MANUAL DE USUARIO**RECIST 1.1 AUTOMATIZADO****DESARROLLADO POR:**

JOHAN STEVEN BALLESTEROS RINCÓN

OSKAR DALIEGT GUZMÁN TRILLOS

DICIEMBRE 2022

c) Anexo 3: Guía de manejo rápido

| | | |
|--|---|---------------------|
| | GUÍA DE MANEJO RÁPIDO | |
| | RECIST 1.1 AUTOMATIZADO | Fecha: 1/12/2022 |
| Aplicativo: Segmentador y evaluador de lesiones hepáticas | | |
| | <p>Descripción: Aplicativo computacional que permite identificar y medir lesiones hepáticas con el fin de evaluar tratamientos oncológicos aplicados a pacientes mediante la implementación de criterios RECIST 1.1.</p> | |
| Servicio: Imagenología. | | |
| <p>Operación del aplicativo:</p> <ul style="list-style-type: none"> • Inicie el aplicativo. • Seleccione el archivo NIFTI o DICOM a trabajar. • Indique la carpeta en que desee guardar los archivos volumétricos preprocesados. • Espere la obtención de las máscaras de segmentación procesadas. • Indique los valores de referencia a comparar tanto en modo manual como automático. • Guarde los archivos generados en el directorio que desee. | | |
| Secciones de la interfaz de usuario: | | |