



CardioAR3D: Tomografía cardiaca 3D mejorada con realidad aumentada

Brayan Daniel Oviedo Barreto

Trabajo de grado presentado para optar al título de Bioingeniero

Modalidad de práctica

Semestre de Industria

Asesora:

Isabella Ariza Cuberos, Bioingeniera

Universidad de Antioquia

Facultad de Ingeniería

Bioingeniería

Medellín

2024

Referencia

- [1] D. Oviedo Barreto, "CardioAR3D: Tomografía cardíaca 3D mejorada con realidad aumentada", Trabajo de grado profesional, Bioingeniería, Universidad de Antioquia, Medellín, Antioquia, Colombia, 2024.

Estilo IEEE (2020)



Centro de Documentación de Ingeniería (CENDOI).

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes.

Decano: Julio César Saldarriaga Molina.

Jefe departamento: John Fredy Ochoa Gómez

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

Este logro se lo quiero dedicar a mi abuela Maria Luisa, pues todo esto pude lograrlo gracias a cada gota de esfuerzo que dió por mí desde que tengo memoria, por cada madrugada y comida que me hizo con mucho amor mientras estudiaba, por cada sermón para que saliera de mi zona de confort y motivarme a estudiar para ser un buen profesional y un gran ser humano, hoy lo puedo lograr gracias a ella y a cada una de sus oraciones.

Esto también se lo dedico a mis padres por su apoyo a lo largo de estos años, y creer en esa locura de dejar mi casa y mudarme a una ciudad que no conocía para poder estudiar lo que quería. También, se lo dedico a don Jaime y doña Teresa por hacerme entender que tenía potencial para lograr grandes cosas, pero que mi futuro solo dependía de mí y de lo que hiciera con él. Este logro no es solo mío, sino de cada una de las personas que hizo parte de este largo trayecto, felizmente podré decir que he culminado formación académica para ser Bioingeniero.

Infinitas gracias a cada uno, los quiero.

Agradecimientos

Agradezco principalmente a la Universidad de Antioquia por acogerme y darme un lugar que pude sentir siempre como mi segunda casa. A la clínica CardioVID por abrirme sus puertas para realizar mis prácticas y tener mi primer acercamiento profesional a esta maravillosa industria. A mi asesora allí, la Dra. Sydney Goldfeder por confiar en mí para desarrollar este proyecto; a cada miembro de cardiología pediátrica que estuvieron siempre dispuestos a enseñarme con paciencia este gigante mundo de cardio y entender que cada aporte puede cambiar vidas. A mis compañeros y amigos de la universidad que siempre me alentaron y me devolvieron la motivación para poder lograr cada paso en esta etapa. A mi asesora Isabella por acompañarme durante este proceso. A Maye por darme terapia cuando sentía que no estaba haciendo las cosas bien y hacer valorar todo lo que hacía.

También quiero hacer un agradecimiento especial a Andrés Díaz-Pinto por su tiempo, consejos y todo el asesoramiento técnico durante el desarrollo de este proyecto, por enseñarme lo que los grandes profesionales hacen en nuestra industria y ser un gran modelo a seguir.

TABLA DE CONTENIDO

RESUMEN	9
ABSTRACT	10
I. INTRODUCCIÓN	11
II. PLANTEAMIENTO DEL PROBLEMA	13
A. Antecedentes	14
III. JUSTIFICACIÓN	17
IV. OBJETIVOS	18
A. Objetivo general	18
B. Objetivos específicos	18
V. MARCO TEÓRICO	19
A. Imágenes diagnósticas por tomografía computarizada: fundamentos y aplicaciones clínicas	19
A. MONAI: Un marco para la segmentación de imágenes médicas	20
1. Aplicación de radiología (Radiology App)	22
2. Aplicación de patología (Pathology App)	22
3. Aplicación de paquetes (MONAIBUNDLE App)	22
4. Aplicación de endoscopia (Endoscopy App)	22
B. Redes neuronales en imágenes médicas y SegResNet	22
1. Fundamentos teóricos de SegResNet para segmentación de imágenes médicas	23
2. Arquitectura y principios de funcionamiento	24
3. Ventajas en el contexto de imágenes médicas	24
4. Métricas de rendimiento: Coeficiente Dice y Accuracy	25
4.1 Coeficiente de Dice	25
4.2 Accuracy (Exactitud)	26
C. Técnicas de imágenes diagnósticas	26
D. Cardiopatías congénitas: aproximaciones y tratamientos	28
E. Potencial de la realidad aumentada y virtual en la planificación y ejecución de procedimientos cardiovasculares	30
F. Informática en la nube	32
VI. METODOLOGÍA	34
A. Construcción de la base de datos	35
B. Realización del modelo	37
1. Preparación del entorno de trabajo	37
2. Importación de Datos	38
3. Entrenamiento del Modelo	38
3.1 Adaptaciones para imágenes médicas 3D	39
3.2 Consideraciones de entrenamiento	40

3.3 Evaluación y validación	41
C. Diseño del entorno de manipulación	43
1. Implementación del módulo personalizado	44
2. Optimización de la interfaz de usuario	44
3. Validación y pruebas	44
VII. RESULTADOS	46
A. Base de datos	46
B. Rendimiento del modelo	52
1. Coeficiente de Dice en el conjunto de entrenamiento	54
2. Coeficiente de Dice en el Conjunto de Validación	54
3. Coeficiente de Dice por canal	55
4. Pérdida de entrenamiento	56
C. Entorno de manipulación	57
1. Módulo de 3D Slicer	57
2. GUI para conectar instancia EC2 e iniciar el servidor de MONAI Label	61
VIII. DISCUSIÓN	63
IX. CONCLUSIONES	67
REFERENCIAS	70
ANEXOS	76

LISTA DE TABLAS

TABLA I. BASE DE DATOS DE PACIENTES CON CoA	49
TABLA II. RESULTADOS DEL ENTRENAMIENTO DEL MODELO	54

LISTA DE FIGURAS

Fig. 1 Tomografía axial computarizada.	22
Fig. 2 Módulo de MONAI Label en 3D Slicer.	23
Fig. 3 Funcionamiento de la SegResNet	26
Fig. 4 Ecocardiografía tridimensional.	29
Fig. 5 Imagen de tomografía computarizada cardíaca, etiquetas de segmentación manual de subestructuras cardíacas e imagen superpuesta.	30
Fig. 6 Ductus arterioso permeable visto de una TAC.	32
Fig. 7 Uso de VR para observar estructuras anatómicas del corazón.	33
Fig. 8 Principales ventajas de los servicios de AWS.	34
Fig. 9 Diagrama de flujo para desarrollo del proyecto.	36
Fig. 10 Interfaz de visualización de VUE PACS Client.	38
Fig.11 Esquema de conexión con la instancia EC2 y equipo local.	39
Fig. 12 Hiperparámetros ajustables para entrenamiento en la interfaz de MONAI Label.	42
Fig. 13 Flujo para el entorno de visualización y manipulación.	45
Fig. 14 Lista de imágenes de los 20 pacientes anonimizadas.	50
Fig. 15 Volumen antes y después del post-procesamiento.	51
Fig. 16 Resultado de segmentación de un paciente y su representación tridimensional.	52
Fig. 17 Cargue de la base de datos usando WinSCP.	53
Fig. 18 Gráfico de Dice promedio durante el entrenamiento.	56
Fig. 19. Gráfico de Dice promedio en el conjunto de validación.	57
Fig. 20 Gráfico de Dice promedio en el conjunto de validación por cada canal de salida.	58
Fig. 21 Gráfico de pérdida durante el entrenamiento.	59
Fig. 22 Qt Designer del módulo SimplifiedMONAILabel.	61
Fig. 23 Módulo implementado de SimplifiedMONAILabel.	62
Fig. 24 GUI para conectar la instancia EC2 e iniciar el servidor de MONAI Label.	64

SIGLAS, ACRÓNIMOS Y ABREVIATURAS

TC	Tomografía computarizada
DICOM	Digital Imaging and Communication In Medicine
CoA	Coartación Aórtica Comunicación interauricular
IA	Inteligencia Artificial
TAC	Tomografía Axial computarizada
MONAI	Medical Open Network for AI
RM	Resonancia magnética
Eco-3D	Ecografía Tridimensional
AR	Realidad aumentada
VR	Realidad virtual
PACS	Picture Archiving and communication system
NIfTI	Neuroimaging Informatics Technology Initiative
AWS	Amazon Web Services
EC2	Amazon Elastic Compute Cloud
SSH	Secure Shell
GUI	Graphical User Interface
UdeA	Universidad de Antioquia

RESUMEN

Los médicos que trabajan en la cardiología intervencionista a menudo enfrentan el desafío de obtener una comprensión completa de la anatomía cardíaca del paciente antes de realizar procedimientos invasivos. Aunque las tomografías computarizadas cardíacas son una herramienta útil al ser una imagen 3D, la visualización que se realiza en dos dimensiones puede no mostrar todas las complejidades de las estructuras tridimensionales. El objetivo de este proyecto fue crear un método integral para mejorar la visualización y el diagnóstico en cardiología intervencionista mediante la segmentación precisa de tomografías computarizadas cardíacas y su representación en tres dimensiones.

Se implementó una estrategia multifase para generar modelos 3D detallados del corazón y los vasos sanguíneos adyacentes. En primer lugar, se accedió al sistema PACS de la institución para recopilar las imágenes médicas de pacientes pediátricos. A continuación, utilizando la plataforma de visualización 3D Slicer, se integraron estas imágenes en reconstrucciones tridimensionales a través de un proceso de segmentación. Esta metodología permitió a los especialistas realizar una evaluación virtual exhaustiva de la anatomía cardíaca de cada paciente antes de cualquier procedimiento, desde múltiples ángulos y perspectivas.

Los resultados de este proyecto incluyeron un modelo pre entrenado alojado en un servidor remoto capaz de segmentar la morfología del corazón en pacientes pediátricos, un módulo de 3D Slicer para manipular las segmentaciones de salida y una interfaz gráfica que facilitara el arranque del servidor. Lo anterior, con la finalidad de una mejor comprensión de la anatomía cardíaca individual, una planificación más precisa de los procedimientos y, en última instancia, mejores resultados para los pacientes que recibieron intervenciones cardíacas. Finalmente, se examinó la integración de tecnología de realidad aumentada y si era posible su uso para realizar planeación previa a las intervenciones.

***Palabras clave* — tomografía computarizada, realidad aumentada, cardiopatías congénitas, preprocesamiento, intervención médica, diagnóstico mejorado.**

ABSTRACT

Clinicians working in interventional cardiology often face the challenge of obtaining a complete understanding of the patient's cardiac anatomy before performing invasive procedures. Although cardiac CT scans are a useful tool, two-dimensional images may not show all the complexities of three-dimensional structures. The aim of this project is to create a comprehensive method to improve visualization and diagnosis in interventional cardiology by accurately reconstructing cardiac CT scans in three dimensions.

A multiphase strategy was implemented to generate detailed 3D models of the heart and adjacent blood vessels. First, the institution's PACS system was accessed to collect medical images of pediatric patients. Then, using the Slicer 3D visualization platform, these images were integrated into three-dimensional reconstructions through a segmentation process. This methodology allowed specialists to perform a comprehensive virtual assessment of each patient's cardiac anatomy prior to any procedure, from multiple angles and perspectives.

The results of this project included a pre-trained model hosted on a remote server capable of segmenting the morphology of the heart in pediatric patients, a 3D Slicer module to manipulate the output segmentations, and a graphical interface to facilitate server start-up. This was aimed at a better understanding of individual cardiac anatomy, more accurate planning of procedures, and ultimately better outcomes for patients receiving cardiac interventions. Finally, we examined the integration of augmented reality technology and whether it could be used for preprocedural planning.

Keywords — **computed tomography, 3D reconstructions, congenital heart disease, preprocessing, medical intervention, enhanced diagnosis.**

I. INTRODUCCIÓN

La tomografía computarizada (TC), una técnica de imagen médica no invasiva, crea imágenes transversales detalladas del cuerpo mediante el uso de rayos X. Las tomografías cardíacas han demostrado ser una herramienta útil en la cardiología para el diagnóstico y la planificación del tratamiento de enfermedades cardiovasculares. Sin embargo, las imágenes de tomografía computarizada en dos dimensiones no siempre reflejan la complejidad tridimensional de la anatomía cardíaca, a pesar de su precisión [1].

Actualmente, el proceso de reconstrucción 3D de tomografías cardíacas implica la segmentación manual de las estructuras de interés en cada imagen transversal, un proceso poco intuitivo y propenso a errores. A partir de lo anterior, se crea un modelo 3D combinando estas segmentaciones. No obstante, los métodos actuales con frecuencia generan reconstrucciones incorrectas o incompletas, lo que dificulta la comprensión y la visualización de la anatomía cardíaca [2, 3].

La mejora de la calidad de las reconstrucciones 3D es esencial para abordar esta problemática ya que puede afectar directamente la eficacia de las intervenciones médicas y el diagnóstico preciso de enfermedades cardíacas [4]. En comparación con las imágenes 2D convencionales, la reconstrucción 3D precisa permite a los médicos explorar virtualmente la anatomía cardíaca desde múltiples ángulos y perspectivas, brindando una comprensión más detallada y completa.

En este contexto, el proyecto CardioAR3D presenta un enfoque innovador que combina técnicas de preprocesamiento y adaptación para mejorar la calidad de las reconstrucciones 3D con el objetivo de brindar a los médicos una representación más clara y detallada de la anatomía cardíaca [5]. Adicionalmente, se considerará la incorporación de tecnología de realidad aumentada, que podría mejorar aún más la capacidad diagnóstica de los profesionales de la salud al superponer reconstrucciones 3D en un entorno de manipulación más detallado previo a los procedimientos [6].

En el campo de la cardiología y cirugía pediátrica, se utilizará un enfoque interdisciplinario que integre la tecnología médica, la informática y la medicina para desarrollar esta solución integral. Además, se ha optado por tomografías computarizadas debido a su capacidad para capturar detalles anatómicos con alta resolución, lo cual es esencial para crear reconstrucciones 3D precisas. La segmentación manual de las estructuras cardíacas en cada imagen transversal es un proceso difícil y propenso a errores, lo que justifica el desarrollo de métodos automatizados para realizar esta tarea con grandes volúmenes de datos.

II. PLANTEAMIENTO DEL PROBLEMA

La interpretación y el análisis de los datos de las tomografías computarizadas del corazón son difíciles debido a la falta de herramientas y protocolos especializados para segmentar de manera precisa las estructuras del corazón en imágenes 3D. La falta de métodos automatizados y estandarizados para la segmentación y visualización de imágenes cardíacas en formato DICOM hace que el diagnóstico de cardiopatías congénitas sea menos efectivo y preciso, lo que puede tener un impacto negativo en la atención y tratamiento de pacientes pediátricos en su primer estadio de vida que padecen estas afecciones.

Como premisa, la clínica CardioVID utiliza un sistema PACs para almacenar las tomografías computarizadas cardíacas de sujetos con coartación aórtica (CoA), no obstante, no todos los pacientes con dicho diagnóstico han sido remitidos a realizarse este tipo de estudio. Sin embargo, una reunión del grupo de cardiólogos pediátricos determinó los criterios de inclusión y exclusión según la edad y el tipo de cardiopatía. Posterior a esto, se determinó que la coartación aórtica era la cardiopatía congénita más frecuente y de la cual se podía obtener un mayor número de imágenes.

Durante el desarrollo del proyecto, como decisión conjunta del equipo se vio obligado a buscar soluciones de software ‘*open-source*’ como 3D Slicer y MONAI Label debido a la falta de recursos para utilizar herramientas de software especializadas bajo licencia que faciliten la segmentación y visualización de imágenes 3D. Los recursos limitados pueden afectar la eficiencia y precisión de los procesos de segmentación y visualización. Esto puede tener un impacto en la colaboración entre especialistas médicos y radiólogos en la interpretación de los resultados y la toma de decisiones clínicas.

La comprensión clínica y académica de la anatomía y patología del corazón es compleja debido a la falta de un entorno interactivo ideal para visualizar y manipular reconstrucciones 3D del corazón, adicionalmente que sea de un acceso general para los diferentes especialistas que tratan un paciente. Usualmente, quien se encarga de procesar y presentar imágenes de interés para los médicos tratantes, son los radiólogos clínicos que manipulan y entregan imágenes

previamente procesadas junto con un diagnóstico preliminar al médico tratante. La falta de herramientas unificadas, así como un flujo de trabajo más estándar para visualizar imágenes cardíacas puede dificultar la comunicación entre los profesionales de la salud y reducir la eficacia en la planificación de tratamientos individualizados para pacientes con cardiopatías congénitas.

A. Antecedentes

La práctica de la cardiología está cambiando debido a la rápida evolución de las tecnologías de la información y las ciencias de la computación. El procesamiento automático de señales biomédicas y análisis de imágenes cardíacas se ha vuelto posible, lo que ha mejorado la eficiencia de los diagnósticos y ha reducido la carga de trabajo de los especialistas. En tareas como el diagnóstico a partir de electrocardiogramas, ecocardiogramas y otras modalidades de imagen, la inteligencia artificial (IA) ha demostrado ser igual o superior al de expertos humanos gracias a nuevas técnicas de aprendizaje profundo. En adición, la IA está ayudando a desarrollar modelos de predicción de riesgo más sólidos y mapear fenotipos de enfermedades cardiovasculares más precisos. En contraste, tecnologías como la impresión 3D, la realidad virtual/aumentada y la robótica están abriendo nuevas perspectivas en la planificación de intervenciones, la enseñanza médica y los procedimientos mínimamente invasivos. El concepto de "hospital inteligente" se refiere a la utilización de sistemas informáticos para optimizar la gestión de recursos y flujos de trabajo. Finalmente, desde la "medicina de sistemas", que se basa en modelos computacionales integradores, tiene como principal objetivo mejorar la medicina de precisión personalizada. [7]

La segmentación automatizada de estructuras cardíacas ha emergido como un proceso relevante en el ámbito de la cardiología debido a la necesidad de diagnósticos precisos y eficientes de enfermedades cardiovasculares. Un estudio reciente demostró que la segmentación automática de la aurícula izquierda en imágenes de TC cardíaca puede identificar esta estructura con una precisión del 95%. [8] Sin embargo, la investigación ha analizado la segmentación automática de la aorta ascendente y la válvula aórtica, destacando la importancia de técnicas avanzadas para generar segmentaciones automáticas precisas en imágenes cardíacas,

especialmente en un contexto donde las enfermedades cardíacas son la principal causa de mortalidad a nivel mundial. [9]

En un enfoque comparativo, se evaluaron algoritmos para la segmentación de imágenes de corazón. Esto reveló que, debido a la complejidad de los movimientos cardíacos no rígidos, los problemas de contraste y los artefactos presentes en las imágenes, es necesario configurar cuidadosamente los componentes y ajustar los parámetros para lograr una segmentación más efectiva y precisa [10]. Además, se ha llevado a cabo una investigación continua sobre los métodos de segmentación cardíaca con el fin de abordar los problemas técnicos y clínicos asociados con la segmentación de estructuras cardíacas utilizando una variedad de técnicas de adquisición de imágenes. Esta investigación ha destacado la necesidad de desarrollar técnicas sólidas y efectivas validadas clínicamente para abordar este problema en la cardiología.

Por otra parte, M. Vera propone una técnica para dividir automáticamente la aurícula izquierda (LA) en diez imágenes de tomografía computarizada multicorte tridimensional de un solo sujeto. La estrategia incluye preprocesamiento y segmentación. En la etapa de preprocesamiento, se utiliza una técnica de realce por similitud global para reducir el artefacto escalera y el ruido Poisson. Luego, los datos de las estructuras anatómicas se organizan para crear una imagen utilizando un detector de bordes. La etapa de segmentación utiliza una técnica de crecimiento de regiones para lograr la segmentación final de la aurícula izquierda. Los resultados muestran una precisión del 95% en la segmentación de la aurícula izquierda. [11]

La segmentación automática de la aorta ascendente y la válvula aórtica en imágenes de TC cardíacas es el tema de este estudio. Los autores proponen una estrategia para dividir estas estructuras cardíacas mediante el uso de algoritmos de aprendizaje automático y técnicas de procesamiento de imágenes. El objetivo es crear una técnica efectiva y confiable para dividir volúmenes de imágenes cardíacas tomadas por tomografía computarizada. Los resultados muestran una precisión del 90 % en la segmentación de la válvula aórtica y la aorta ascendente. [12]

Un estudio comparativo examinó un algoritmo totalmente automático para imágenes cardíacas y un algoritmo de segmentación inicializado manualmente. Los investigadores descubrieron que la configuración cuidadosa de los componentes y el ajuste de los parámetros de los algoritmos de segmentación son esenciales para obtener resultados efectivos y precisos. Esto se debe a la presencia de artefactos y ruido en las imágenes, la complejidad de los movimientos cardíacos no rígidos y la falta de contraste entre estructuras. El estudio destaca la importancia de desarrollar técnicas sólidas y efectivas que puedan ser validadas clínicamente para abordar el problema de la segmentación de imágenes cardíacas. [13]

III. JUSTIFICACIÓN

Debido a la falta actual de herramientas y protocolos especializados que permitan una interpretación y análisis precisos de las estructuras cardíacas en imágenes 3D de tomografía computarizada, el desarrollo de un protocolo de segmentación y visualización de imágenes 3D de tomografía computarizada juega un papel importante para el diagnóstico de cardiopatías congénitas como la coartación aórtica. La falta de métodos automatizados y estandarizados para la segmentación y visualización de imágenes cardíacas en formato DICOM dificulta el diagnóstico efectivo y preciso de estas condiciones, lo que puede afectar negativamente la atención y el tratamiento de pacientes pediátricos en sus primeros años de vida.

Un protocolo integral que aborde estas limitaciones actuales permitirá a los médicos comprender mejor la anatomía del corazón de los pacientes, lo que facilitará el diagnóstico y la planificación del tratamiento adecuado. Esto es especialmente relevante para las enfermedades cardíacas congénitas, que requieren una intervención temprana y precisa para prevenir complicaciones graves en el desarrollo del niño [14].

Este proyecto contribuirá al avance del conocimiento en el campo de la segmentación y visualización de imágenes médicas al promover el desarrollo de técnicas y enfoques innovadores que puedan ser aplicados no solo en la cardiología pediátrica sino también en otras disciplinas médicas donde se requiere un análisis detallado de estructuras anatómicas complejas.

Con lo anterior, lo que se busca aportar con este proyecto al interior de la clínica CardioVID, es el desarrollo de un protocolo de segmentación y visualización de imágenes 3D de tomografía computarizada para abordar las limitaciones actuales en el diagnóstico y tratamiento de cardiopatías congénitas en pacientes pediátricos. Esto impulsará el avance en el campo de la ingeniería biomédica y el procesamiento de imágenes médicas al interior de la institución, además de brindar beneficios directos a los pacientes.

IV. OBJETIVOS

A. Objetivo general

Desarrollar un protocolo de segmentación y visualización de imágenes 3D de tomografía computarizada para apoyo diagnóstico de pacientes pediátricos con cardiopatía congénita de coartación aórtica de la clínica CardioVID.

B. Objetivos específicos

1. Construir un conjunto de datos de imágenes de tomografía computarizada cardíaca de sujetos pediátricos con cardiopatía de coartación aórtica de la clínica CardioVID, considerando criterios de inclusión y exclusión por edad.
2. Realizar un modelo de segmentación semi-automática para imágenes tomográficas cardíacas en formato DICOM utilizando el software 3D Slicer.
3. Implementar un entorno interactivo para la visualización y manipulación de las reconstrucciones 3D cardíacas.

V. MARCO TEÓRICO

A. Imágenes diagnósticas por tomografía computarizada: fundamentos y aplicaciones clínicas

Las imágenes diagnósticas son representaciones visuales del interior del cuerpo humano obtenidas a través de diversas técnicas, como rayos X, ultrasonido, resonancia magnética y tomografía. Estas imágenes son fundamentales en la medicina moderna, ya que permiten a los profesionales de la salud visualizar estructuras anatómicas, detectar anomalías y realizar diagnósticos precisos sin necesidad de procedimientos invasivos. La tomografía axial computarizada es una técnica de diagnóstico por imágenes que combina rayos X con tecnología computarizada para producir imágenes detalladas de los órganos internos, huesos, tejidos blandos y vasos sanguíneos [13, 15]. La TAC utiliza una fuente de rayos X y un detector de rayos X que rotan alrededor del cuerpo, registrando las medidas de radiografías tomadas desde múltiples ángulos. Estas medidas se envían a una computadora, que las convierte en imágenes bidimensionales que se asemejan a cortes transversales del cuerpo. Además, la computadora puede construir imágenes tridimensionales a partir de las imágenes grabadas [15].

Las tomografías computarizadas son una herramienta de diagnóstico de gran utilidad en diversas áreas de la medicina, como la oncología, la cardiología y la traumatología. En oncología, este tipo de imágenes se utiliza para detectar y diagnosticar tumores, medir su tamaño, precisar su localización y determinar cuánto se ha diseminado hacia los tejidos cercanos [15]. En el campo de la cardiología, las tomografías computarizadas se emplean para evaluar la anatomía y la función cardiovascular, así como para detectar enfermedades cardiovasculares [19]. En traumatología, estas imágenes médicas son utilizadas para evaluar fracturas y lesiones en huesos, articulaciones y tejidos blandos [16]. Adicionalmente, conllevan ciertos riesgos asociados, como la exposición a la radiación, que es uno de los principales riesgos de este tipo de estudios, ya que el procedimiento utiliza rayos X para producir las imágenes [13]. Sin embargo, la mayoría de los equipos de tomografía computarizada como se observa en la **Fig. 1** tienen la capacidad de disminuir la dosis de radiación [13]. Otra limitación es el uso de un medio de contraste, que puede causar reacciones alérgicas y dañar la función renal en algunas personas [13].




Fig. 1 Tomografía axial computarizada.

La segmentación de imágenes médicas es el proceso de dividir una imagen en múltiples segmentos o conjuntos de píxeles que representan diferentes objetos o regiones de interés dentro de la imagen. Este proceso es fundamental para la visualización y el análisis de estructuras anatómicas específicas, como el corazón y los vasos sanguíneos. Existen diferentes técnicas de segmentación, como los enfoques basados en umbral, los métodos basados en bordes, las técnicas de crecimiento de regiones y los algoritmos de segmentación basados en modelos deformables [19]. Dentro de este tópico, se van uniendo diferentes herramientas que hace parte del proceso, como lo son las reconstrucciones en tres dimensiones que se pueden hacer a partir de la segmentación de una imagen y en determinadas estructuras anatómicas de interés, en este caso es el corazón.

A. MONAI: Un marco para la segmentación de imágenes médicas

MONAI (Medical Open Network for AI), es un marco de código abierto creado por NVIDIA y King's College London, es una herramienta en constante desarrollo para la segmentación de imágenes médicas. MONAI ofrece una serie de redes neuronales pre entrenadas y flujos de trabajo optimizados para tareas como segmentar órganos, lesiones y tumores en imágenes médicas como tomografías computarizadas, resonancias magnéticas e imágenes microscópicas [20]. MONAI Label es una aplicación de anotación de imágenes médicas dentro

del ecosistema de MONAI que facilita la segmentación y el etiquetado manual de estructuras anatómicas. Esta aplicación es esencial para generar conjuntos de datos anotados que puedan ser utilizados para entrenar modelos de aprendizaje profundo, y como agregado tiene un módulo dedicado en 3D Slicer. La extensión de MONAI Label integrable al software 3D Slicer ofrece una interfaz fácil de entender como se muestra en la **Fig. 2** y herramientas de segmentación semi-automáticas, lo que hace que el proceso de anotación sea más sencillo y reduce la carga de trabajo manual. Esta herramienta ha demostrado ser útil en una variedad de disciplinas, como la cardiología, donde la segmentación precisa de las estructuras cardíacas es fundamental para el diagnóstico y la planificación de tratamientos [21, 22].




Fig. 2 Módulo de MONAI Label en 3D Slicer.

Dentro del marco de MONAI Label, existen diversos ejemplos de aplicación de los frameworks desarrollados, donde destacan los siguientes:

1. *Aplicación de radiología (Radiology App)*

Esta aplicación proporciona modelos de muestra para segmentar imágenes radiográficas (3D) de forma automática e interactiva, incluida la segmentación automática de diversos órganos abdominales utilizando los modelos de aprendizaje profundo más recientes (por ejemplo, UNet, UNETR). Para mejorar activamente los modelos de entrenamiento y el despliegue, es posible utilizar herramientas interactivas como DeepEdit y Deepgrow [22].

2. *Aplicación de patología (Pathology App)*

En este programa se incluyen ejemplos de modelos para la segmentación tanto interactiva como automatizada sobre imágenes de patología, incluida la segmentación multietiqueta de núcleos para células neoplásicas, inflamatorias, de tejido conectivo/blando, muertas y epiteliales. DeepEdits, una de las herramientas interactivas que ofrece la aplicación, permite la segmentación interactiva de núcleos [22].

3. *Aplicación de paquetes (MONAIBUNDLE App)*

Los usuarios pueden personalizar modelos para la inferencia, el entrenamiento o el procesamiento previo y posterior de cualquier anatomía objetivo con la aplicación de paquetes (*'Bundle'*). Para el etiquetado personalizado (como el etiquetado de la corteza renal, la médula y el sistema pélvico con un modelo de transformador de terceros), la especificación para la integración MONAI Label de la aplicación de paquetes enlaza con modelos archivados de Model-Zoo [21, 22].

4. *Aplicación de endoscopia (Endoscopy App)*

La aplicación endoscópica permite utilizar modelos de segmentación y clasificación interactivos y automáticos en imágenes 2D para casos de uso endoscópico. Cuando se utiliza junto con la herramienta de anotación de visión por ordenador (CVAT por sus siglas en inglés), mostrará cómo entrenar y optimizar un modelo utilizando un enfoque de aprendizaje activo totalmente automatizado [22].

B. *Redes neuronales en imágenes médicas y SegResNet*

Las redes neuronales han evolucionado significativamente en el ámbito de la segmentación de imágenes médicas, con diversas arquitecturas que han demostrado su eficacia en

esta tarea. Las redes neuronales convolucionales (CNN) se utilizan ampliamente debido a su habilidad para extraer características pertinentes de las imágenes. Para facilitar la identificación precisa de estructuras patológicas y anatómicas, arquitecturas como U-Net y nnU-Net se han creado con el propósito de segmentar [23]. SegResNet es una opción importante en este contexto porque combina los principios de las redes residuales con la segmentación, lo que facilita el aprendizaje de modelos más complejos y profundos. Su eficacia en la identificación de tumores y el análisis de tejidos en imágenes médicas se ve mejorada por el uso de grandes conjuntos de datos; además, puede realizar segmentaciones en una variedad de tareas.

1. Fundamentos teóricos de SegResNet para segmentación de imágenes médicas

SegResNet, acrónimo de Red de Segmentación Residual, representa una estructura de red neuronal profunda creada especialmente para la segmentación en imágenes médicas tridimensionales [24]. Esta estructura fusiona los fundamentos de las redes totalmente convolucionales (FCN, por sus siglas en inglés) con las conexiones residuales presentes en la ResNet [25]. La ResNet, introducida por Kaiming He y sus colaboradores en 2015, revolucionó el campo del aprendizaje profundo al demostrar que las redes neuronales podían ser significativamente más profundas sin sufrir problemas de degradación del rendimiento, gracias a la introducción de conexiones residuales que permiten el aprendizaje de funciones de identidad [26]. Este concepto fue importante para el desarrollo de SegResNet, que adapta la idea de aprendizaje residual al ámbito de la segmentación de imágenes médicas.

Los orígenes de SegResNet se encuentran en la necesidad de mejorar la precisión y la eficiencia en la segmentación de imágenes médicas, un desarrollo que ayudaría en el diagnóstico y tratamiento de diversas patologías. Las redes totalmente convolucionales, que se centran en la segmentación pixel a pixel, proporcionaron un marco inicial, pero a menudo presentan limitaciones en la captura de características complejas y en la generalización a diferentes tipos de imágenes. Al incorporar las conexiones residuales de ResNet, SegResNet aborda estas limitaciones, permitiendo que la red aprenda representaciones más complejas sin sacrificar la estabilidad durante el entrenamiento.

2. Arquitectura y principios de funcionamiento

La estructura de SegResNet se fundamenta en el concepto de codificador-decodificador, una estructura comúnmente utilizada en la segmentación de imágenes. El codificador, también llamado ruta de contracción, disminuye progresivamente la resolución espacial de la imagen de entrada a medida que aumenta la cantidad de características extraídas como se aprecia en la **Fig. 3**. Por otro lado, el decodificador, o ruta de expansión, incrementa gradualmente la resolución espacial para generar un mapa de segmentación con la misma resolución que la imagen original.




Fig. 3 Funcionamiento de la SegResNet [27].

La principal característica distintiva de la SegResNet radica en la inclusión de bloques residuales tanto en el codificador como en el decodificador. Estos bloques residuales, inspirados en la arquitectura ResNet, facilitan el flujo directo de información a través de conexiones de salto (*skip connections*).

3. Ventajas en el contexto de imágenes médicas

La arquitectura SegResNet presenta múltiples ventajas importantes para la segmentación de imágenes médicas:

- *Manejo de gradientes desvanecientes*: Las conexiones residuales permiten que los gradientes fluyan directamente a través de la red durante la retropropagación, lo que ayuda a mitigar el problema de los gradientes desvanecientes en redes profundas [28].
- *Conservación de detalles de alta resolución*: Las conexiones de salto entre el codificador y el decodificador posibilitan la transmisión de información de alta resolución, lo cual es fundamental para lograr precisión en la segmentación de estructuras anatómicas finas [28].
- *Eficiencia computacional*: A pesar de su profundidad, SegResNet mantiene un número manejable de parámetros gracias a su diseño eficiente, lo que resulta especialmente beneficioso para el procesamiento de volúmenes de imágenes médicas en 3D [28].
- *Robustez ante variaciones*: La capacidad de la red para aprender representaciones jerárquicas la hace resistente ante variaciones en la apariencia de las estructuras anatómicas, un punto de atención en el ámbito de las imágenes médicas [28].

4. Métricas de rendimiento: Coeficiente Dice y Accuracy

La evaluación precisa del rendimiento de los modelos de aprendizaje automático es fundamental para garantizar la eficacia de los sistemas de segmentación de imágenes médicas. Dos métricas ampliamente utilizadas en este contexto son el coeficiente de Dice y la exactitud (accuracy).

4.1 Coeficiente de Dice

El coeficiente de Dice es una métrica que cuantifica la similitud entre dos conjuntos, en el contexto de imágenes médicas, entre las predicciones del modelo y el etiquetado manual de expertos. Se define como el doble de la intersección de los conjuntos dividido por la suma de sus cardinalidades [29]. Matemáticamente, se expresa en (1):

$$Dice = \frac{2 \times |X \cap Y|}{|X| + |Y|} \quad (1)$$

donde X representa el conjunto de elementos que el modelo predice como positivos y Y representa el conjunto de elementos que, según las anotaciones de expertos, son verdaderamente

positivos. La puntuación máxima de 1 en el coeficiente de Dice indica una coincidencia completa entre las predicciones y las anotaciones [30].

4.2 Accuracy (Exactitud)

La precisión, también conocida como precisión, es una medida que cuantifica la proporción de predicciones correctas realizadas por el modelo en relación con el total de predicciones. Se calcula como el cociente entre la cantidad de predicciones correctas y la cantidad total de predicciones. La fórmula para calcular la precisión se presenta en (2).

$$Accuracy = \frac{\text{Número de predicciones correctas}}{\text{Número total de predicciones}} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

donde TP (True Positives) representa los verdaderos positivos, TN (True Negatives) los verdaderos negativos, FP (False Positives) los falsos positivos y FN (False Negatives) los falsos negativos. La accuracy toma valores entre 0 y 1, siendo 1 indicativo de que todas las predicciones fueron correctas [31].

Esta métrica puede no reflejar adecuadamente el rendimiento del modelo en conjuntos de datos desbalanceados, donde algunas clases tienen muy pocos ejemplos en comparación con otras. Por ejemplo, si un modelo predice siempre la clase mayoritaria en un conjunto de datos donde el 90% de las instancias pertenecen a esa clase, el modelo podría tener una accuracy del 90% sin realmente ser útil [32]. Al considerar tanto los verdaderos positivos como los falsos negativos, el coeficiente de Dice puede proporcionar una medida más justa en estos casos.

C. Técnicas de imágenes diagnósticas

La reconstrucción 3D de imágenes cardíacas es un método prometedor que puede mejorar significativamente el diagnóstico y el tratamiento de enfermedades cardiovasculares al proporcionar una representación tridimensional detallada de las estructuras del corazón. Este enfoque se basa en la segmentación de imágenes bidimensionales, como las obtenidas mediante TC o RM, lo que permite identificar y separar con precisión las estructuras cardíacas de interés de los tejidos circundantes [33]. Una vez que se han segmentado las estructuras relevantes en cada

corte 2D, estos segmentos se combinan y reconstruyen en un modelo tridimensional utilizando algoritmos de reconstrucción 3D [34]. Esta representación 3D proporciona una visualización más completa y detallada de la anatomía cardíaca, lo que puede ser de gran utilidad para la planificación de intervenciones quirúrgicas, la evaluación de anomalías congénitas y la comprensión de la fisiopatología de diversas enfermedades cardíacas [35, 36].

La Eco-3D, la TAC y la RM son solo algunos de los muchos métodos disponibles para la reconstrucción de imágenes cardíacas en tres dimensiones. La Eco-3D observada en la **Fig. 4** puede obtener imágenes en tiempo real sin necesidad de realizar una reconstrucción off-line, lo que ha aumentado su uso en la práctica clínica diaria [36]. Se pueden identificar y localizar puntos de interés en las estructuras cardíacas mediante imágenes TAC y RM en volumen completo, en tiempo real y en múltiples planos [36, 37].




Fig. 4 Ecocardiografía tridimensional.

La reconstrucción 3D de imágenes cardíacas ha demostrado ser útil para evaluar la anatomía y la función del corazón, lo que ha permitido obtener información importante sobre la estructura y la función del corazón en pacientes con enfermedades cardiovasculares. Por ejemplo, el conocimiento excepcional de la anatomía y las funciones del ventrículo izquierdo ha ayudado a planificar cirugías e intervenciones percutáneas [38].

Como precedente, la reconstrucción 3D de imágenes cardíacas es una herramienta muy importante para el diagnóstico y el tratamiento de enfermedades cardiovasculares. Varios métodos de reconstrucción 3D, incluidos Eco-3D, TAC y RM, permiten visualizar estructuras cardíacas en tres dimensiones y obtener información importante sobre su estructura y

funcionamiento. En ese orden de ideas, la segmentación de imágenes médicas a partir de las técnicas enunciadas anteriormente, nace como otra alternativa para obtener una representación tridimensional a partir de las máscaras de segmentación generadas como se puede apreciar en la **Fig 5**.



Fig. 5 Imagen de tomografía computarizada cardíaca, etiquetas de segmentación manual de subestructuras cardíacas e imagen superpuesta [40].

D. Cardiopatías congénitas: aproximaciones y tratamientos

Por otra parte, las cardiopatías congénitas son anomalías estructurales del corazón o de los grandes vasos intratorácicos que pueden afectar a los niños. La prevalencia global de cardiopatías congénitas se estima en 11.9 por cada 1,000 nacimientos [41]. Al menos un tercio de los pacientes con cardiopatías congénitas requieren algún tipo de intervención antes del primer año de vida, y la mortalidad quirúrgica ha disminuido significativamente en los últimos años, pasando del 15% en 1990 al 5% en el año 2000 [42].

Hay varios tipos de cardiopatías congénitas que son comunes en niños:

- **Comunicación interauricular (CIA):** Es una anomalía en la que los dos ventrículos del corazón se conectan directamente, lo que puede causar una sobrecarga de volumen en las cavidades cardíacas [43].
- **Comunicación interventricular (CIV):** Es una anomalía en la que los dos ventrículos del corazón se conectan directamente, lo que puede causar una sobrecarga de volumen en las cavidades cardíacas [43].

- **Ductus arterioso permeable (DAP):** Es una anomalía en la que el ductus arterioso, un vaso sanguíneo que conecta el corazón con las arterias pulmonares, se mantiene abierto después del nacimiento, lo que puede causar una sobrecarga de volumen en las cavidades cardíacas [43].
- **Hipoplasia pulmonar:** Es una anomalía en la que el corazón no desarrolla adecuadamente las arterias pulmonares, lo que puede causar una insuficiencia cardíaca [43].
- **Trastornos del septo:** Son anomalías en las que el septo, una pared que separa los dos ventrículos del corazón, no se desarrolla adecuadamente, lo que puede causar una sobrecarga de volumen en las cavidades cardíacas [43].
- **Cardiopatías congénitas asociadas a cromosomopatías:** Son anomalías en las que la cardiopatía congénita se asocia con una anomalía genética, como el síndrome de Down [43].
- **Coartación aórtica:** En la coartación de aorta que se muestra en la **Fig. 6**, una parte de la aorta es más estrecha de lo normal, normalmente en la aorta descendente. Este estrechamiento provoca una disminución del flujo sanguíneo a la parte inferior del cuerpo y obliga al ventrículo izquierdo del corazón a trabajar más para bombear la sangre a través de la aorta estrechada [43].

La detección y el diagnóstico de las cardiopatías congénitas son importantes para el tratamiento adecuado y la prevención de secuelas. Los médicos pueden utilizar diversas técnicas, como la ecocardiografía fetal, la radiografía torácica, el electrocardiograma y la ecocardiografía, para diagnosticar estas anomalías. En algunos casos, se puede utilizar un cateterismo cardíaco para obtener información detallada sobre el corazón y su funcionamiento [42].

El tratamiento de las cardiopatías congénitas puede incluir medicamentos para manejar la falla cardíaca, procedimientos quirúrgicos para cerrar defectos congénitos o procedimientos por

hemodinamia a través de la colocación de dispositivos endovasculares para cerrar el defecto. La elección del método de cierre depende del tamaño del defecto, su ubicación y el tamaño del paciente [43].




Fig. 6 Ductus arterioso permeable visto de una TAC [44].

E. Potencial de la realidad aumentada y virtual en la planificación y ejecución de procedimientos cardiovasculares

Muy de la mano de la detección de enfermedades del corazón, dentro de las herramientas informáticas empleadas en el ámbito médico, la realidad aumentada (AR) es una tecnología que mejora la comprensión y visualización de estructuras anatómicas y procesos fisiológicos en el diagnóstico médico al combinar información digital con el mundo real [45]. Varios campos de la medicina, como la cirugía y la cardiología, han utilizado la AR para mejorar la planificación y ejecución de procedimientos quirúrgicos y proporcionar información adicional en tiempo real durante procedimientos cardíacos.

En cirugía, la AR ha sido utilizada en cirugía para crear modelos de estructuras anatómicas en tres dimensiones, lo que ha facilitado la comprensión de la anatomía y la planificación de incisiones y procedimientos. Durante la cirugía, la AR también se ha utilizado para proporcionar información adicional en tiempo real, ayudando a los cirujanos a identificar estructuras importantes y evitar daño a las estructuras cercanas [46].

En cardiología, la AR se ha utilizado en cardiología para mejorar la comprensión de la fisiología y la anatomía cardiovascular. Se ha utilizado, por ejemplo, para crear modelos

tridimensionales de corazones con anomalías congénitas, lo que facilita la comprensión de la anatomía y la planificación de procedimientos. Durante procedimientos cardiacos, la AR también se ha utilizado para proporcionar información adicional en tiempo real, ayudando a los médicos a detectar anomalías y planificar tratamientos [45, 46].

La AR también se ha utilizado en el entrenamiento de profesionales médicos, lo que les ayuda a comprender conceptos complejos y realizar procedimientos. Se han utilizado, por ejemplo, para crear simuladores de procedimientos quirúrgicos y cardíacos, lo que ayuda a los residentes y estudiantes a mejorar sus habilidades y prepararse para el trabajo clínico [46].

De esta manera, la realidad aumentada es una tecnología prometedora para el diagnóstico médico que facilita la comprensión y visualización de procesos fisiológicos y estructuras anatómicas. Se ha utilizado en varios campos de la medicina, como la cirugía y la cardiología, para mejorar la planificación y ejecución de procedimientos quirúrgicos y proporcionar información adicional en tiempo real durante procedimientos cardiacos. La VR también se ha utilizado para enseñar a los médicos, ayudando a comprender conceptos complejos y realizar procedimientos como se aprecia en la **Fig. 7**.




Fig. 7 Uso de VR para observar estructuras anatómicas del corazón [47].

De la mano de la VR, hay una variedad de herramientas disponibles en línea que permiten visualizar modelos 3D de imágenes médicas, cada uno con sus propias características y funciones. MeshLab, Embodi3D y InVesalius son algunos de los más utilizados. Embodi3D es una plataforma en la nube que permite la carga y visualización de modelos tridimensionales de

estructuras anatómicas, así como la realización de mediciones y anotaciones [48]. InVesalius es una alternativa de código abierto que se enfoca en la reconstrucción de modelos 3D de imágenes médicas, como tomografías computarizadas o resonancias magnéticas [49].

F. Informática en la nube

La informática en la nube ha revolucionado el paradigma de la gestión de recursos tecnológicos en diversas industrias, incluyendo la atención médica y la investigación [50]. Esta tecnología permite a las organizaciones acceder a recursos computacionales y de almacenamiento de manera flexible y escalable, lo que facilita la implementación de soluciones a la vanguardia. Entre los proveedores de servicios en la nube, Amazon Web Services (AWS) se destaca por su amplia gama de servicios, entre los cuales se encuentran las instancias Elastic Compute Cloud (EC2) que permite a los usuarios lanzar y gestionar instancias de servidores virtuales en la nube, ofreciendo una capacidad de computación escalable bajo demanda.

Uno de los beneficios significativos de la informática en la nube es la agilidad operativa. Las organizaciones pueden provisionar recursos de manera rápida, lo que permite el desarrollo y la implementación de aplicaciones en tiempos reducidos [51]. Este aspecto es especialmente relevante en el contexto de la segmentación de imágenes médicas, donde la capacidad de realizar iteraciones rápidas en modelos de aprendizaje automático puede mejorar la precisión diagnóstica y optimizar el flujo de trabajo clínico como una de sus principales ventajas. En la **Fig. 8** se aprecian los puntos de valor agregado de la informática en la nube.



Fig. 8 Principales ventajas de los servicios de AWS.

Además, la informática en la nube ofrece un modelo de costos basado en el uso, eliminando la necesidad de inversiones iniciales significativas en infraestructura física. Este modelo es particularmente ventajoso para instituciones de salud que buscan implementar soluciones avanzadas de segmentación de imágenes sin comprometer su presupuesto operativo. Las organizaciones pueden ajustar su gasto en función de la utilización real de los recursos, lo que contribuye a una gestión financiera más efectiva.

VI. METODOLOGÍA

La metodología propuesta en este proyecto consta de varias etapas como se muestra en la **Fig. 9**. En primer lugar, se realizó la construcción de la base de datos que contiene varios elementos necesarios para llevar a cabo los pasos posteriores. Luego, se realizó el desarrollo del entrenamiento del modelo de segmentación semi-automática y entorno de manipulación.




Fig. 9 Diagrama de flujo para desarrollo del proyecto.

A. Construcción de la base de datos

Para la construcción de la base de datos utilizada en este proyecto, se tuvieron en cuenta criterios de inclusión que hacen referencia a las características que deben cumplir los pacientes potenciales para ser elegibles e incluidos en el estudio. Estos criterios definen la población objetivo y garantizan que los participantes sean relevantes para el proyecto. Los criterios de inclusión fueron:

1. Imágenes de pacientes pediátricos no superiores a los 10 años de edad.
2. Diagnóstico confirmado de CoA.
3. Disponibilidad de imágenes de tomografía computarizada cardíaca en formato DICOM.
4. Imágenes de TC adquiridas previas a una intervención de la cardiopatía.

Por otra parte, para el proyecto fueron considerados los siguientes criterios de exclusión:

1. Imágenes de pacientes adultos
2. Presencia de otras cardiopatías congénitas complejas además de la CoA.
3. Imágenes de TC cardíaca de baja calidad o con artefactos significativos que impidan un adecuado análisis.
4. Imágenes de pacientes que hayan sido sometidos a cirugía cardíaca previa o intervención endovascular para la coartación aórtica.
5. Imágenes de pacientes con contraindicaciones para la realización de una tomografía computarizada.

Se solicitó adicionalmente, acceder al sistema PACS de la clínica CardioVID en caso de hallar la limitación en la disponibilidad de datos públicos adecuados. Lo antes mencionado, para obtener imágenes médicas digitales de manera local, esto permitiría obtener TC cardíacas de pacientes pediátricos con diagnósticos de la cardiopatía congénita relevante para el estudio.

Para el proceso anterior, se solicitó acceso al sistema PACS de la clínica CardioVID y al departamento de sistemas encargado de gestionar los permisos, así como de realizar el proceso de instalación del software *VUE PACS Client* de Philips que es un entorno de fácil manipulación

para la búsqueda y visualización de imágenes al interior de la clínica [52], como se muestra en la **Fig. 10**. Por otro lado, se solicitó al departamento de estadística de la clínica que hiciera una filtración de todos los pacientes con coartación aórtica que hubieran sido sometidos a algún procedimiento clínico no superior a 5 años para crear la lista inicial de pacientes con el diagnóstico. Con esto, al obtener las imágenes DICOM, era necesario convertir dichas imágenes a un archivo comprimido para su posterior organización, por lo cual, se optó por convertirlas a formato NIfTI para su manipulación.




Fig. 10 Interfaz de visualización de VUE PACS Client.

Por último, para cumplir con el último criterio de inclusión, que requería imágenes de tomografía computarizada cardíaca de alta calidad y sin artefactos significativos que pudieran impedir un análisis adecuado, se llevó a cabo un análisis de calidad por inspección visual de las imágenes obtenidas.

El uso del filtro anisotrópico y el filtro de mediana para el preprocesamiento antes del entrenamiento del modelo, buscaba mejorar la calidad de las imágenes de entrada, lo que busca impactar en una mejora de rendimiento y resultados más acertados en la segmentación y análisis de las estructuras cardíacas. Estos dos filtros se emplean para preservar los bordes de la imagen y eliminar el ruido de *'sal y pimienta'* que por inspección, se encontraron en las imágenes.

B. Realización del modelo

El desarrollo del modelo de segmentación semi-automática para TC cardíacas empleando el software 3D Slicer se llevó a cabo en varias etapas:

1. Preparación del entorno de trabajo

En primer lugar, se creó una instancia EC2 de AWS de tipo *g5.2xlarge* para alojar el conjunto de datos de imágenes en formato NIfTI y las máscaras de segmentación. La instancia EC2 *g5.2xlarge* de AWS se seleccionó como plataforma computacional para alojar el conjunto de datos de imágenes TC y las máscaras de segmentación debido que, ofrece una combinación ideal de potencia de procesamiento con 8 vCPUs, memoria de 24 GiB y almacenamiento de 450 Gb, lo que la hace adecuada para tareas de entrenamiento y evaluación de modelos de aprendizaje automático como la segmentación de imágenes médicas [53].




Fig. 11 Esquema de conexión con la instancia EC2 y equipo local.

La conexión SSH se estableció como un canal seguro para acceder remotamente a la instancia EC2 desde el equipo local donde se desarrolló el proyecto como se explica en la **Fig. 11**, añadiendo una regla de entrada a la instancia para poder acceder a la misma. Esta conexión permitió la transferencia de archivos, la ejecución de comandos y el control de las herramientas de segmentación instaladas en la instancia [54].

2. Importación de Datos

Luego, para la transferencia de archivos entre la computadora local y la instancia, se utilizó el software WinSCP, este es un cliente FTP/SFTP/WebDAV/SFTP gratuito y de código abierto para Windows que permite la transferencia segura de archivos y la gestión de directorios remotos [55]. La estructura empleada para construir la base de datos, siguiendo las recomendaciones especificadas por el proyecto MONAI [22, 56], se dispuso de la siguiente manera:

```
dataset
|-- Paciente1.nii.gz
|-- Paciente2.nii.gz
|
| ...
|
└── labels
    ├── final
    |   |-- Paciente1.nii.gz
    |   |-- Paciente2.nii.gz
    |   |
    |   | ...
```

3. Entrenamiento del Modelo

La etapa central del proyecto consistió en el entrenamiento del modelo de segmentación semi-automática usando la librería de código abierto MONAI Label. Como punto de partida se seleccionó la red neuronal SegResNet, y se dividió el conjunto de datos en conjuntos de entrenamiento, validación y prueba. Por defecto, la interfaz de MONAI Label ya tiene algoritmos predefinidos que facilitan este proceso, por esta razón, no es necesario separar manualmente de la base de datos los volúmenes de entrenamiento y validación, sino que se escoge el porcentaje de

división de los datos. Para este entrenamiento, se buscaba establecer una división de los datos es una relación 80-20, que corresponde que de la base de datos se emplean el 80% de los volúmenes para entrenamiento, y el 20% restante para la validación.

3.1 Adaptaciones para imágenes médicas 3D

En este caso, se seleccionó de los frameworks disponibles de MONAI Label el uso de la aplicación de radiología y la plantilla de ‘Segmentation’ para entrenar un modelo desde cero. Dicha selección, implementa la SegResNet como red neuronal por las diferentes ventajas enunciadas anteriormente en el marco teórico, y esta ha sido modificado para abordar la segmentación de estructuras cardíacas en volúmenes 3D, utilizando convoluciones 3D en lugar de las convencionales 2D. De esta manera, la red es capaz de procesar los volúmenes de entrada en su totalidad, lo que le permite capturar información contextual en todas las dimensiones espaciales [57].

El diseño de la red destaca principalmente dentro de esta aplicación por los siguientes parámetros:

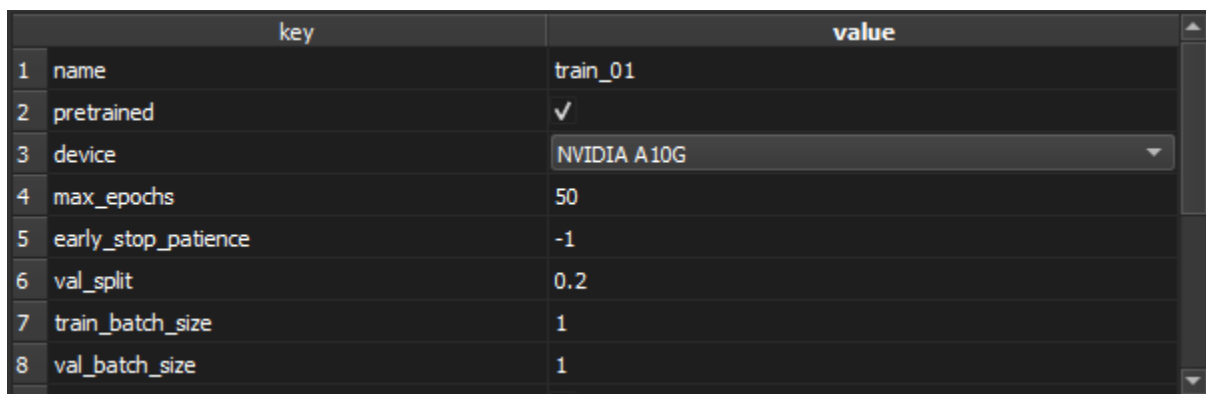
```
spatial_dims=3
in_channels=1
out_channels=len(self.labels) + 1
blocks_down=(1, 2, 2, 4)
blocks_up=(1, 1, 1)
dropout_prob=0.2
```

Las dimensiones espaciales y los canales de entrada y salida reflejan la capacidad para procesar imágenes médicas monocromáticas 3D y producir mapas de segmentación multiclase. Adicionalmente, la estructura de bloques superiores e inferiores define la profundidad y complejidad de las rutas de contracción y expansión, respectivamente.

3.2 Consideraciones de entrenamiento

El proceso de entrenamiento de SegResNet para la segmentación cardíaca se realizó empleando el módulo de MONAI Label y se buscaba experimentar con ajustes de hiperparámetros debido a la complejidad de la cardiopatía de interés que puede ocasionar diferencias entre las anatomía de cada paciente de prueba. La inclusión de *dropout* actúa como un mecanismo de regularización, disminuyendo el riesgo de sobreajuste, lo cual impacta al trabajar con conjuntos de datos médicos limitados. Asimismo, la inicialización de la red con pesos pre-entrenados, tal como se recomienda en el código que se encuentra en el repositorio público de este proyecto: [CardioAR3D](#), puede acelerar de manera significativa el proceso de convergencia y mejorar el rendimiento final del modelo al aprovechar el conocimiento transferido de tareas relacionadas.

Los hiperparámetros manipulados durante el entrenamiento estaban especificados en la interfaz de la extensión de MONAI Label como se muestra en la **Fig. 12**:



	key	value
1	name	train_01
2	pretrained	✓
3	device	NVIDIA A10G
4	max_epochs	50
5	early_stop_patience	-1
6	val_split	0.2
7	train_batch_size	1
8	val_batch_size	1

Fig. 12 Hiperparámetros ajustables para entrenamiento en la interfaz de MONAI Label.

Cada uno de estos hiperparámetros que era posible ajustar, se refieren a las siguientes características especificadas en la documentación de la librería de MONAI Label [57]:

- *name*: Es el nombre asignado a este entrenamiento específico.
- *pretrained*: Indica que el modelo está utilizando pesos pre-entrenados, lo que puede ayudar a acelerar el entrenamiento y mejorar el rendimiento.

- *device*: Especifica el hardware utilizado para el entrenamiento, en este caso una GPU NVIDIA A10G.
- *max_epochs*: Define el número máximo de épocas para el entrenamiento.
- *early_stop_patience*: Un valor de -1 generalmente significa que no se está utilizando *early stopping*, permitiendo que el modelo se entrene durante todas las épocas especificadas.
- *val_split*: Indica que el 20% de los datos se utilizan para validación y el restante para entrenamiento.
- *train_batch_size*: El tamaño del lote para los datos de entrenamiento.
- *val_batch_size*: El tamaño del lote para los datos de validación.

3.3 Evaluación y validación

Una vez se hubiese entrenado el modelo, se aplicó al conjunto de datos de prueba para obtener segmentaciones automáticas de las estructuras cardíacas. Las segmentaciones generadas se buscaban comparar con las máscaras de segmentación manuales creadas inicialmente y validadas por un especialista médico, calculando métricas que se pueden observar en la TABLA I del apartado de resultados. Este proceso proporciona detalles sobre varios aspectos del rendimiento y comportamiento del modelo:

- **Evaluación del rendimiento**: Las estadísticas permiten cuantificar la precisión del modelo en los conjuntos de datos de entrenamiento y validación, utilizando métricas como el coeficiente de Dice [58].
- **Detección de sobreajuste**: La comparación entre los resultados de entrenamiento y validación facilita la identificación de sobreajuste, un fenómeno donde el modelo se adapta excesivamente a los datos de entrenamiento, comprometiendo su capacidad de generalización al ingresar datos nuevos [59].
- **Monitoreo del progreso**: El seguimiento época por época revela la evolución del rendimiento del modelo, indicando si continúa mejorando o si el modelo llegó a un punto de estancamiento.

- **Optimización de la duración del entrenamiento:** La identificación del punto donde se alcanzan las mejores puntuaciones de validación ayuda a determinar la duración óptima del entrenamiento, evitando el sobreajuste innecesario.
- **Gestión de recursos:** Los datos sobre tiempos de entrenamiento son importantes para la planificación y asignación eficiente de recursos computacionales en futuros entrenamientos o escalamiento del modelo.
- **Selección de modelos:** Estas métricas proporcionan una base objetiva para comparar y seleccionar entre diferentes modelos o estrategias de entrenamiento [60].
- **Detección de anomalías:** La presencia de patrones inusuales en las estadísticas puede indicar problemas en el proceso de entrenamiento, los datos o la arquitectura del modelo [61].
- **Validación del proceso:** Las estadísticas confirman que el proceso de entrenamiento está funcionando según lo previsto y que el modelo está aprendiendo características relevantes de los datos.
- **Reproducibilidad:** La documentación detallada de estas estadísticas es de gran utilidad para la reproducibilidad de los resultados y la comparación con futuras iteraciones del modelo.

Para el desarrollo de este proyecto, donde la precisión pesa en orden de importancia, este análisis asegura que el modelo no solo alcance un alto rendimiento, sino que también mantenga su consistencia y fiabilidad en la segmentación de diversas estructuras cardíacas. Esta evaluación permite tener diferentes consideraciones sobre la implementación del modelo en aplicaciones clínicas reales. Adicionalmente, con la finalidad de hacer este proceso de evaluación más sencillo, se evalúa el uso de herramientas como TensorFlow, una plataforma de código abierto

para el aprendizaje automático que facilita la creación, implementación y evaluación de modelos [62]. TensorFlow permite el entrenamiento y la implementación de modelos de forma sencilla, ya sea en servidores, dispositivos perimetrales o en la nube, sin importar el lenguaje o la plataforma utilizada [63].

C. Diseño del entorno de manipulación

Para el desarrollo del entorno de visualización, se planteó inicialmente identificar y seleccionar las herramientas necesarias para la manipulación de las segmentaciones generadas por el modelo de machine learning por parte del equipo médico. Para esto, se optó por diseñar un flujo intuitivo para especialistas en cardiología sin conocimiento previo del software 3D Slicer, por tanto, se eligió contar con el espacio de conexión a la instancia remota, la selección del modelo, un botón para ejecutar inferencia y finalmente, los controles de la sección de *Segment Editor* que ya se encuentra dentro de 3D Slicer.

El flujo se estructuró como se muestra en la **Fig. 13** a continuación:




Fig. 13 Flujo para el entorno de visualización y manipulación.

De esta manera, se planteó un uso más centralizado al estar todo integrado dentro de una misma herramienta y que permitió un desarrollo más a futuro si se busca integrar con otras funcionalidades dentro de 3D Slicer. Para lo anterior, se decidió desarrollar un módulo personalizado en 3D Slicer utilizando Python y la API de 3D Slicer [64].

1. *Implementación del módulo personalizado*

Este módulo incorporó las siguientes funciones:

- **Conexión a la instancia remota de AWS:** Se implementó una interfaz para establecer una conexión segura con la instancia virtual donde se aloja el modelo.
- **Selección del modelo:** Se integró un menú desplegable que permitirá al usuario seleccionar el modelo de segmentación deseado entre las opciones disponibles.
- **Ejecución de inferencia:** Se añadió un botón que, al ser presionado, enviará los datos de imagen al modelo seleccionado y recibirá los resultados de la segmentación.
- **Integración con Segment Editor:** Se integró los controles del módulo Segment Editor de 3D Slicer, permitiendo a los usuarios realizar ajustes detallados en las segmentaciones generadas.

2. *Optimización de la interfaz de usuario*

Se prestó especial atención al diseño de una interfaz de usuario intuitiva y eficiente:

- **Disposición lógica:** Los elementos de la interfaz se organizaron de manera que sigan el flujo de trabajo natural del usuario, desde la carga de imágenes hasta la manipulación final de las segmentaciones.
- **Retroalimentación visual:** Se implementaron indicadores visuales claros para informar al usuario sobre el estado de cada proceso (por ejemplo, progreso de la inferencia, segmentación, etc.).
- **Ayuda contextual:** Se incluyeron tooltips y mensajes de ayuda breves para guiar a los usuarios menos familiarizados con la herramienta.

3. *Validación y pruebas*

Se llevó a cabo un proceso iterativo de validación y pruebas:

- **Pruebas de usabilidad:** Se realizaron sesiones con cardiólogos para evaluar la facilidad de uso del módulo y recopilar retroalimentación.

- **Evaluación de precisión:** Se compararon la calidad de las segmentaciones generadas por el modelo con segmentaciones manuales realizadas por expertos.
- **Optimización de rendimiento:** Se realizaron pruebas de carga para asegurar que el módulo funcione eficientemente con diversos tamaños de conjuntos de datos.

VII. RESULTADOS

A. Base de datos

A partir de la metodología explicada anteriormente, se realizó la búsqueda de una base de datos pública que contuviera imágenes de tomografía computarizada cardíaca de pacientes pediátricos para obtención de las imágenes. No obstante, a pesar de una extensa búsqueda, no fue posible encontrar conjuntos de datos públicos que cumplieran con los requisitos del proyecto. La mayoría de las bases de datos disponibles se centran en imágenes de pacientes adultos y de un tipo de estudio diferente como lo es la resonancia magnética, o en su defecto, no proporcionaban información específica sobre las cardiopatías congénitas de interés.

Con base en lo anterior, se optó por usar la base de datos obtenida localmente, al tener acceso y el aplicativo del sistema PACS debidamente instalado y la información suministrada por el departamento de estadística, se empleó dicha información para obtener imágenes de pacientes seleccionados con el diagnóstico. Una lista de 17 pacientes con coartación aórtica se encontró en esta búsqueda, de los cuales 13 tenían imágenes de tomografía computarizada cardíaca disponibles en el sistema PACS, los restantes o no contaban con un estudio de TC o poseían estudios de imágenes no relacionados con la patología cardíaca. La base del conjunto de datos estaba compuesta por estas 13 imágenes, pero posteriormente se agregaron 7 imágenes adicionales de pacientes sin el diagnóstico para formar una base de datos con un total de 20 imágenes.

De igual manera, se realizó una segunda revisión manual de las imágenes obtenidas del sistema PACS para descartar imágenes que tuvieran posibles artefactos o volúmenes incompletos que impidieron que fueran elegibles para ser parte del proyecto. Con lo anterior, como se muestra en la **TABLA I**. La base de datos quedó conformada por 20 imágenes en total donde se especifican rangos de edad de todas las imágenes que corresponden a pacientes pediátricos con la patología de interés, y de manera similar, los datos de edad de los otros 7 volúmenes agregados a la base de datos.

TABLA I
BASE DE DATOS DE PACIENTES CON CoA

Paciente	Edad	Sexo	Diagnóstico
1	0	Masculino	Coartación de la aorta
2	0	Femenino	Coartación de la aorta
3	0	Masculino	Coartación de la aorta
4	0	Masculino	Coartación de la aorta
5	0	Femenino	Coartación de la aorta
6	0	Femenino	Coartación de la aorta
7	0	Femenino	Coartación de la aorta
8	3	Femenino	Coartación de la aorta
9	0	Masculino	Coartación de la aorta
10	2	Masculino	Coartación de la aorta
11	0	Femenino	Coartación de la aorta
12	0	Masculino	Coartación de la aorta
13	7	Masculino	Coartación de la aorta
14	6	Femenino	Sin diagnóstico
15	6	Masculino	Sin diagnóstico
16	4	Femenino	Sin diagnóstico
17	8	Femenino	Sin diagnóstico
18	3	Masculino	Sin diagnóstico
19	3	Femenino	Sin diagnóstico
20	2	Masculino	Sin diagnóstico

Nota: Los pacientes del 14 al 20 son pacientes pediátricos de diferentes edades que fueron proporcionados como sujetos sin diagnóstico confirmado de cardiopatía.

Como se observa, se seleccionaron pacientes de las edades delimitadas con los criterios anteriormente mencionados con diagnóstico confirmado de coartación aórtica, incluidos niños en su primer año de vida (indicados con la edad '0' en el registro). Para proteger la privacidad de los pacientes, se recopilaron y se procedió a anonimizar las imágenes de tomografía computarizada cardíaca de estos pacientes, así como la conversión de los ficheros DICOM a formato Neuroimaging Informatics Technology Initiative (NIfTI) empleando la librería dcm2nii integrada en el software de visualización de MRICron para optimizar costo computacional y optimización de tiempo [65]. Los criterios de inclusión y exclusión de estas imágenes se cumplieron para tener la cantidad mayor de datos posibles de la cardiopatía de interés. El conjunto de datos que resultó consistió en veinte imágenes de tomografía computarizada cardíaca en formato NIfTI para su análisis y posterior procesamiento como se muestra en la **Fig. 14**.




Fig. 14 Lista de imágenes de los 20 pacientes anonimizados.

Como parte de este proceso de construcción de la base de datos, se revisó cada volumen para iniciar con el proceso de filtrado de las imágenes que lo requirieron, pues era necesario que la base de datos tuviera la mejor calidad posible. Se utilizó un filtro de mediana y un filtro anisotrópico de 3D Slicer para eliminar el ruido de ‘sal y pimienta’ de las imágenes durante el preprocesamiento.

El filtro anisotrópico es una técnica de procesamiento de imágenes que permite suavizar las regiones homogéneas de una imagen mientras se mantienen los bordes y los detalles estructurales y anatómicos que se observan en las imágenes. En imágenes médicas, este filtro es particularmente útil porque puede reducir el ruido sin afectar la nitidez de las estructuras anatómicas [66].

El filtro de mediana, por otro lado, es un filtro no lineal que elimina el ruido de ‘sal y pimienta’, que se presentan como píxeles aislados con valores muy altos o muy bajos en

comparación con sus vecinos. Este tipo de ruido puede ser causado por errores en la transmisión o problemas con el sensor del dispositivo que toma las imágenes [67].

El uso de estos filtros de preprocesamiento antes del entrenamiento del modelo buscaba mejorar la calidad de las imágenes de entrada, esto se puede apreciar en la **Fig. 15**.




Fig. 15 Volumen antes y después del post-procesamiento.

Adicionalmente, se consultó con el departamento de radiología si las imágenes encontradas poseían sus respectivas máscaras de segmentación, esto con la finalidad de conformar la base datos que requiere el modelo para su entrenamiento. No obstante, ninguna de las imágenes obtenidas contaba con sus máscaras de segmentación, por lo que se procedió a crear las segmentaciones de los 20 volúmenes manualmente.

Posterior al pre-procesamiento de los volúmenes, se realizaron las segmentaciones ejecutando inferencia sobre dichas imágenes empleando el modelo de Auto3DSeg de MONAI Label [57, 68], para lograr homogeneidad en las máscaras de segmentación, así como optimización de tiempo y correcciones manuales de las estructuras cardíacas relevantes en cada imagen. Aunque fue empleando una metodología manual, este proceso permitió garantizar que las imágenes elegidas fueran adecuadas para el entrenamiento posterior del modelo de segmentación semi-automática. Para este proceso, se utilizaron segmentaciones manuales para

guiar y evaluar el desempeño del modelo durante la fase de entrenamiento, para aumentar así la precisión y confiabilidad de los resultados obtenidos. La morfología a segmentar para estandarizar las estructuras que serán posteriormente pasadas como máscaras al modelo corresponden a:

1. Ventrículo izquierdo.
2. Ventrículo derecho.
3. Aurícula izquierda.
4. Aurícula derecha.
5. Aorta.
6. Arteria pulmonar.
7. Miocardio.

De esta forma, dentro de las consideraciones para la elección de dichas estructuras cardiacas, es poder permitir que el modelo en la etapa de entrenamiento también pueda reconocer la morfología principal del corazón. Posteriormente, al ejecutar la inferencia sobre las imágenes y de eliminar información no referente a las estructuras de interés, así como refinamiento de las segmentaciones, se puede observar la representación tridimensional de dicha segmentación en la **Fig. 16**.




Fig. 16 Resultado de segmentación de un paciente y su representación tridimensional.

Como paso final, estas segmentaciones contenían consideraciones importantes para su homogeneidad, como lo fue segmentar las siete estructuras en el mismo orden para mantener los índices de manera general en todas las máscaras de segmentación (primero ventrículo izquierdo, segundo ventrículo derecho, etc). Seguidamente, se exportaron las máscaras en formato NIFTI con el nombre correspondiente del paciente para mantener el orden y relación entre los volúmenes y las segmentaciones.

Con lo anterior, se cumplía con todos los criterios necesarios para la base de datos que se emplearía para pasar a la etapa de entrenamiento. De esta manera, empleando WinSCP se realizó la conexión con la instancia EC2 para organizar la base de datos según los requisitos de entrenamiento de MONAI Label [21, 60]. Así, la estructura de los datos quedó organizada como se muestra en la **Fig. 17** en el espacio derecho que corresponde a la instancia.




Fig. 17 Carga de la base de datos usando WinSCP.

Todo el proceso previo, fue detallado en un repositorio de GitHub donde se encuentran las guías de todos los aspectos técnicos tenidos en cuenta durante el desarrollo, así como lo es la

configuración de la instancia EC2, la instalación de dependencias al interior de la misma y el proceso de segmentación de las imágenes. De manera similar, también se encuentran especificados errores encontrados durante el proceso de instalación y las soluciones que se encontraron. Todo lo anterior, en el repositorio público de este proyecto: [CardioAR3D](#).

B. Rendimiento del modelo

Como se enunció inicialmente, para entrenar el modelo, se usó el módulo de MONAI Label integrable a 3D Slicer que era más versátil e integrable dentro de otros flujos de trabajo. Al interior de los resultados encontrados, los primeros datos a analizar fueron los diferentes entrenamientos a los que se sometió el modelo variando la cantidad de épocas en cada entrenamiento, esto con la finalidad de encontrar un valor de diferencia entre el Dice de entrenamiento y de validación adecuada.

La diferencia porcentual se midió entre el "Final Train Mean Dice" y el "Final Val Mean Dice". Esto ayuda a cuantificar el posible exceso de ajuste en cada fase del entrenamiento.

TABLA II
RESULTADOS DEL ENTRENAMIENTO DEL MODELO .

Epochs	Training Time	Best Val Epoch	Best Val Mean Dice	Final Train Mean Dice	Final Val Mean Dice	Train-Val Difference (%)
50	00:11:47	44	0.4239	0.2654	0.4099	-54.45%
200	00:23:40	200	0.1589	0.0393	0.1589	-304.33%
500	00:57:45	438	0.6066	0.5934	0.5430	8.49%
800	01:31:25	763	0.6420	0.7098	0.5718	19.44%
1200	02:18:16	1183	0.6711	0.8567	0.5584	34.82%

Nota: Los tiempos de entrenamiento fueron calculados al correr sobre una gráfica NVIDIA A10g en una instancia EC2 de AWS.

La columna que calcula la diferencia entre el Dice de entrenamiento y final, se calcula matemáticamente mediante (3).

$$\frac{\text{Final Train Mean Dice} - \text{Final Val Mean Dice}}{\text{Final Train Mean Dice}} * 100 \quad (3)$$

Ahora bien, como principal información relevante a partir de los datos anteriores por cada entrenamiento realizado, una interpretación de los datos encontrados es:

1. Para 50 y 200 épocas, se observaron porcentajes negativos. Esto indica que el rendimiento de validación fue mejor que el rendimiento de entrenamiento.
2. A partir de 500 épocas, se comenzaron a observar porcentajes positivos, lo que indica que el rendimiento del entrenamiento supera al de la validación.
3. La diferencia entre el rendimiento de entrenamiento y el de validación crece de forma constante de 500 a 1200 épocas:
 - A 500 épocas: 8,49% de diferencia
 - A 800 épocas: 19,44% de diferencia
 - A 1200 épocas: 34,82% de diferencia
4. El aumento de la diferencia porcentual sugirió que el sobreajuste es más pronunciado a medida que había avanzado el entrenamiento. A las 1200 épocas, el rendimiento del entrenamiento es un 34,82% mejor que el de la validación, lo que suponía una diferencia significativa.
5. La ejecución de 200 épocas mostró una diferencia negativa extremadamente grande (-304,33%) que fue atípico respecto a los otros entrenamientos.

En consecuencia, dentro de la arquitectura interna de MONAI Label, se reportó una precisión general del modelo del 67% como una de las métricas proporcionadas. Además, los archivos internos generados durante el entrenamiento incluían datos sobre la métrica del coeficiente de Dice en diferentes etapas del proceso, prestando especial atención a los valores reportados en el conjunto de validación. Estos datos fueron analizados utilizando las librerías de uso libre de TensorBoard, que consisten en un conjunto de herramientas de visualización que forma parte de TensorFlow y que resulta muy apropiado para la experimentación y el análisis de modelos de aprendizaje automático [69].

Una de las principales ventajas de TensorBoard es su capacidad para representar el proceso de entrenamiento. Durante la fase de entrenamiento, el desempeño del modelo se puede monitorear y comparar utilizando las métricas y gráficos proporcionados por estas librerías, lo que facilita la optimización y depuración de los modelos de aprendizaje profundo [70]. Adicionalmente, los datos fueron descargados en archivos `.csv` para generar un análisis complementario por cada canal de salida.

1. Coeficiente de Dice en el conjunto de entrenamiento

Dentro de las métricas monitoreadas, se evaluó el coeficiente de Dice promedio en el conjunto de entrenamiento observado en la **Fig. 18**. Con esto, se prestó principal atención al valor de Dice en el conjunto de validación, a pesar de que este valor es útil para vigilar el progreso del modelo durante el entrenamiento, resulta más relevante supervisar durante la validación. Un buen rendimiento en el conjunto de entrenamiento no garantiza que el modelo funcione correctamente en datos no vistos; esto podría resultar en un fenómeno de sobreajuste.

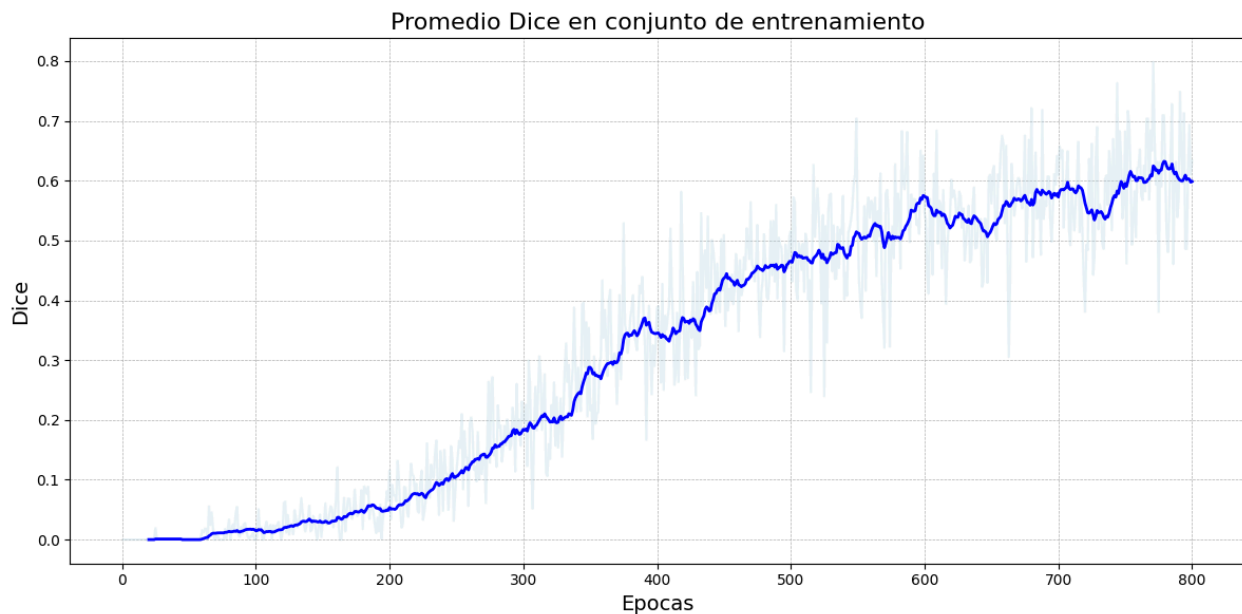


Fig. 18 Gráfico de Dice promedio durante el entrenamiento.

2. Coeficiente de Dice en el Conjunto de Validación

Cada una de las estructuras anatómicas examinadas, que incluyen el miocardio, la arteria pulmonar, el atrio derecho, el ventrículo derecho, la aorta, el atrio izquierdo y ventrículo izquierdo, se ponderaron con el coeficiente de Dice promedio en el conjunto de validación como se muestra en la **Fig. 19**. Para evaluar la similitud entre la segmentación producida por el modelo y la segmentación de referencia, esta métrica brinda información importante de manera cuantitativa. La concordancia que se acerca a ser muy buena entre las dos segmentaciones es indicada por un valor de Dice que se aproxima a 1, lo que indica que el modelo funciona bien en la identificación de estructuras anatómicas.

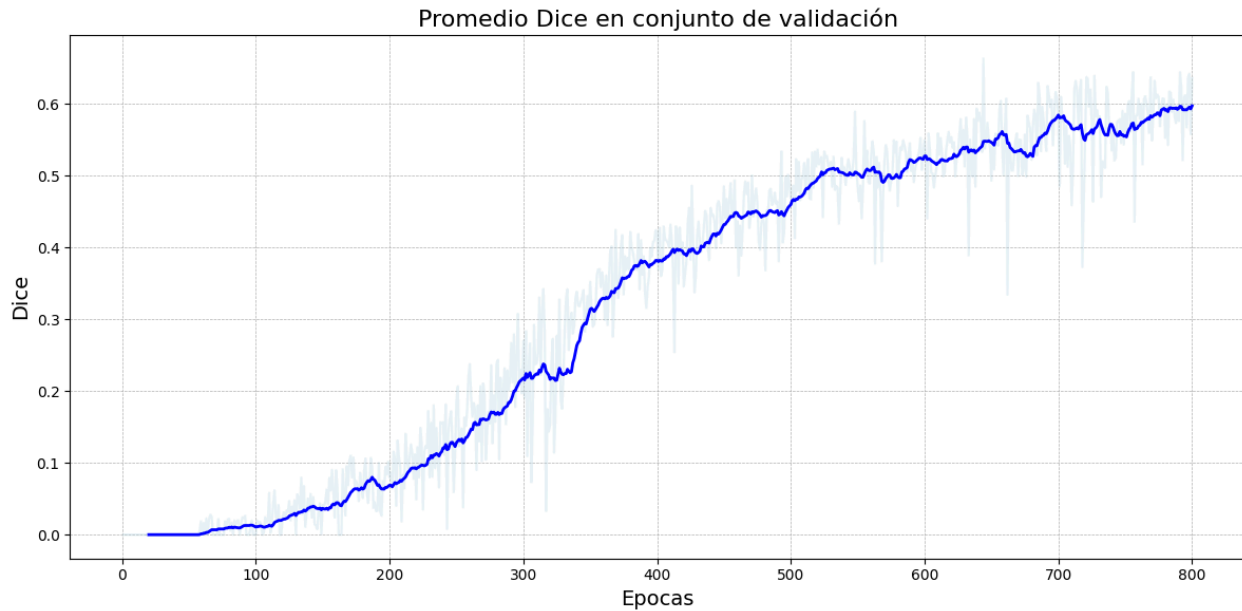


Fig. 19 Gráfico de Dice promedio en el conjunto de validación.

3. *Coefficiente de Dice por canal*

Por otra parte, con el coeficiente de Dice por canal se encontró una aproximación más detallada de la segmentación, al revelar las variaciones en la precisión del modelo para cada canal de salida como se observa en la **Fig. 20**, las cuales podrían corresponderse a vistas o cortes de imágenes diferentes para encontrar estructuras particulares que podrían estar presentando problemas durante la segmentación.

Para cada canal de salida, el análisis de la evolución del coeficiente Dice durante los períodos de entrenamiento reveló patrones relevantes en la estabilidad y el rendimiento del modelo. Se encontró que los canales del ventrículo izquierdo y del atrio izquierdo alcanzaron los valores más altos de Dice al final del entrenamiento, superando el 0.6. Esto indica que estas estructuras cardíacas serían segmentadas de manera más precisa. Por el contrario, el canal del miocardio demostró el desempeño más bajo; se mantuvo por debajo de 0.5 en el coeficiente Dice, lo que indica que podría haber problemas para identificar durante el entrenamiento adecuadamente este tejido. La estabilidad del entrenamiento varió entre los canales; algunos, como la arteria pulmonar y la aorta, mostraron fluctuaciones más marcadas en los primeros tiempos antes de llegar a valores más estables. Además, se observó que, a medida que avanzaba

el entrenamiento, la mayoría de los canales mostraban una tendencia ascendente en su rendimiento, aunque con diferentes niveles de estabilización y mejora.




Fig. 20 Gráfico de Dice promedio en el conjunto de validación por cada canal de salida.

4. Pérdida de entrenamiento

Se evaluó la pérdida de entrenamiento a lo largo del tiempo; esto sirvió como una medida de cuán bien el modelo se adaptó a los datos de entrenamiento y esto se observa en la **Fig. 21**. El modelo está aprendiendo de manera efectiva si hay una disminución en esta pérdida. Es importante tener en cuenta, que una disminución excesivamente rápida podría indicar sobreajuste; esto podría comprometer la habilidad del modelo para extenderse a datos no vistos.




Fig. 21 Gráfico de pérdida durante el entrenamiento.

De manera general, a medida que aumenta el número de épocas, la mayoría de las curvas del coeficiente de Dice en el conjunto de validación convergen hacia un valor estable. Este comportamiento indica que el modelo ha aprendido a dividir las estructuras de interés con una precisión razonable; esto es una indicación favorable del proceso de entrenamiento.

Así mismo, se han observado diferencias notables en el funcionamiento del modelo al dividir varias estructuras anatómicas. Por ejemplo, en comparación con otras estructuras, el ventrículo izquierdo parece ser segmentado con mayor precisión; esto indica que el modelo podría beneficiarse de un ajuste particular para mejorar la segmentación de las estructuras con un rendimiento inferior.

C. Entorno de manipulación

1. Módulo de 3D Slicer

En el marco del proyecto, se llevó a cabo el desarrollo de un módulo simplificado para 3D Slicer denominado 'SimplifiedMONAILabel'. Este módulo fue diseñado como una versión optimizada y más accesible del plugin MONAI Label existente. El código original fue analizado en su totalidad para prescindir de las funciones no necesarias del código base (*Active learning*, *Deep Edit*, *Deep Grow*, etc) para finalmente, dejar la lógica empleada para conectar con el servidor, cargar la imagen, ejecutar inferencia y manipular la segmentación obtenida. El código

base se encuentra detallado en el repositorio público del proyecto MONAI Label [71]. Lo expuesto, con el objetivo de facilitar la integración de modelos de aprendizaje automático previamente entrenados en el flujo de trabajo de segmentación de imágenes médicas.

El módulo 'SimplifiedMONAILabel' se implementó también como una clase derivada de *ScriptedLoadableModule*, siguiendo las convenciones de desarrollo de 3D Slicer para la base de desarrollo de todo nuevo módulo [72]. Se incorporaron funcionalidades que permiten al usuario interactuar con modelos de segmentación entrenados mediante MONAI Label, sin necesidad de conocimientos profundos en aprendizaje automático o programación, simplificando el flujo de trabajo como se mostró en el planteamiento de la **Fig. 11**.

Entre las características principales del módulo se incluyen:

- **Interfaz de usuario intuitiva:** Se diseñó una interfaz gráfica que permite a los usuarios seleccionar modelos de segmentación, cargar imágenes y visualizar resultados de manera sencilla.
- **Integración con servidor MONAI Label:** Se implementó la comunicación con un servidor MONAI Label remoto, permitiendo la ejecución de inferencias y la actualización de modelos de forma transparente para el usuario.
- **Gestión de segmentaciones:** El módulo facilita la creación de nodos mediante inferencia y manipulación de la segmentación obtenida mediante el *Segment Editor* nativo 3D Slicer, permitiendo la visualización y edición de los resultados obtenidos.
- **Compatibilidad con formatos de imagen médica:** Se garantizó la compatibilidad con formatos comunes en imagen médica, como NIFTI, DICOM y NRRD, para facilitar la integración en flujos de trabajo clínicos existentes.

Los módulos de 3D Slicer programados en Python generalmente utilizan una lógica de programación orientada a eventos junto con un enfoque modular basado en clases. La estructura del código se basa en la herencia de clases del marco de Slicer, como '*VTKObservationMixin*' y '*ScriptedLoadableModule*', lo que facilita la integración con el entorno de Slicer. Mediante la sobrescritura de métodos predefinidos para inicialización, manejo de interfaces gráficas y respuesta a eventos del usuario, este método permite crear comportamientos personalizados [73].

Como parte del desarrollo del módulo, los elementos fueron dispuestos de la siguiente manera empleando el Qt Designer como se muestra en la **Fig. 22**.




Fig. 22 Qt Designer del módulo SimplifiedMONAILabel.

Destacando lo más clave dentro de la programación del módulo, el mismo representa una versión simplificada del proyecto MONAI Label como se mencionó anteriormente. A través de la

clase principal se asegura la correcta inicialización y categorización del módulo, lo cual es necesario para su visibilidad y usabilidad dentro de la plataforma de 3D Slicer.

Por otra parte, otro ítem importante es el panel de configuración del servidor de MONAI que facilita la interacción del usuario ingresando al servidor específico donde realizará la segmentación, brindando una manera intuitiva para ingresar y recordar direcciones de servidor. El diseño centrado en el usuario mejora significativamente la adaptabilidad del módulo a diferentes entornos de trabajo.

Finalmente, las opciones de automatización, como la ejecución de inferencia al adquirir una nueva imagen, destacan el enfoque del módulo en la optimización del flujo de trabajo. Estas características reducen significativamente la carga de trabajo manual, lo cual es especialmente ventajoso para aplicaciones clínicas e investigativas donde el tiempo y la precisión juegan un rol importante.

La interfaz del módulo ya implementado y en funcionamiento se observa a continuación en la **Fig. 23**.




Fig. 23 Módulo implementado de SimplifiedMONAILabel.

En síntesis, toda la información referente a la lógica de programación junto con todos los archivos necesarios para ejecutar el módulo e integrarlo en cualquier versión de Slicer, se

encuentran detallados en el repositorio público de este proyecto: [CardioAR3D](#), en el apartado '*3D Slicer extension*'.

2. GUI para conectar instancia EC2 e iniciar el servidor de MONAI Label

Adicionalmente, se diseñó una interfaz gráfica de usuario conocida como GUI (del inglés *graphical user interface*) para facilitar el uso de la herramienta, pues para el equipo médico que está destinada esta herramienta, no se encuentran familiarizados con el uso de ventana de comandos de Windows (en inglés: 'Command Prompt') y esta interfaz hace la implementación más sencilla dentro del flujo de trabajo.

La interfaz gráfica de usuario desarrollada para este proyecto que se muestra en la **Fig. 24** facilita la conexión remota y la ejecución de MONAI Label en una instancia Amazon EC2 dedicada al procesamiento de imágenes médicas. Implementada en Python utilizando la biblioteca Tkinter, la aplicación presenta una estructura organizada y visualmente coherente.

La interfaz se divide en tres secciones principales: una para la entrada de datos de conexión, otra para los controles de ejecución, y una tercera para la visualización de la salida del servidor. En la sección de entrada, el usuario puede especificar la dirección IPv4 pública del servidor EC2 y seleccionar el archivo de clave PEM correspondiente mediante un cuadro de diálogo de selección de archivos. La sección de controles contiene tres botones secuenciales: "Connect", "Activate Environment" y "Start Server", que guían al usuario a través del proceso de conexión SSH, activación del entorno Conda, e iniciación del servidor MONAI Label, respectivamente.

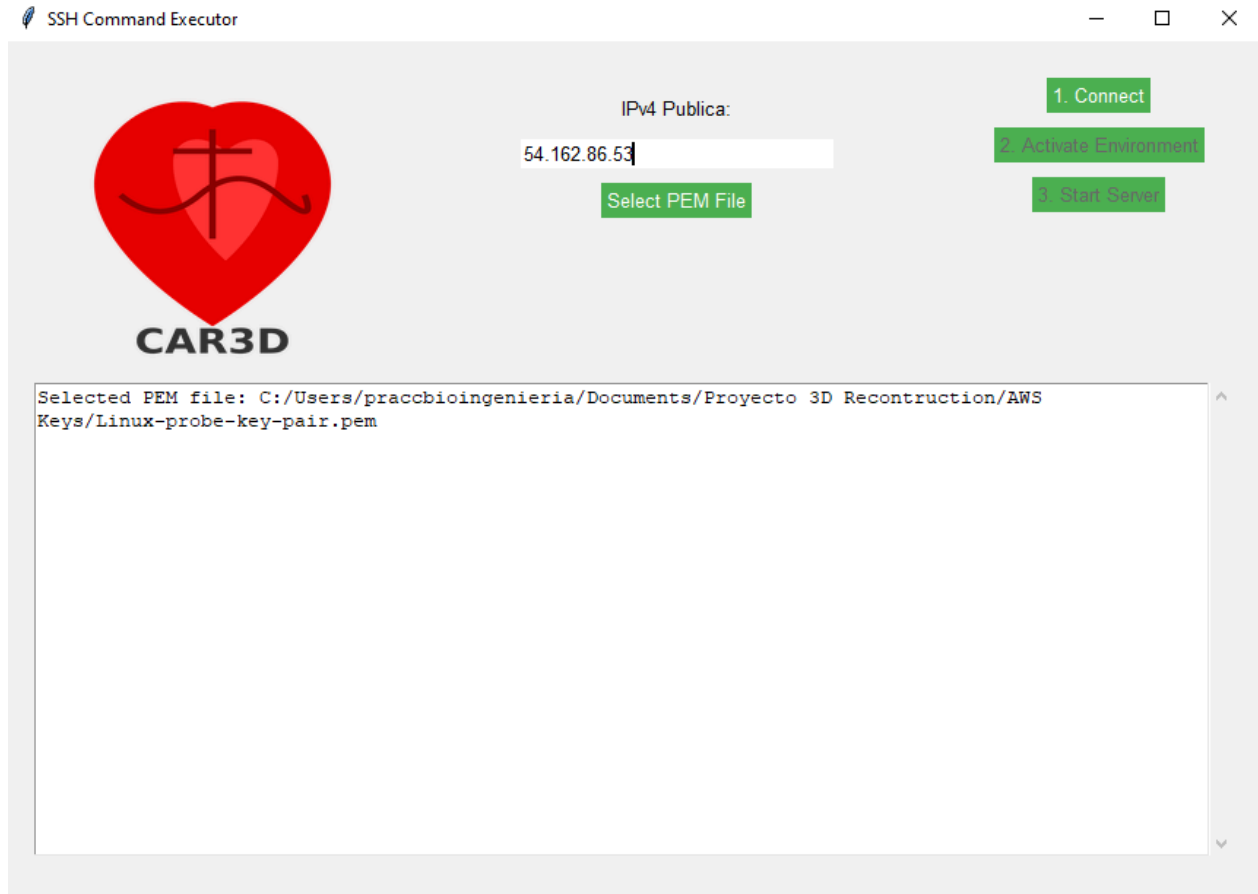


Fig. 24 GUI para conectar la instancia EC2 e iniciar el servidor de MONAI Label.

Estos botones dispuestos en la GUI, se habilitan progresivamente a medida que se completan los pasos previos, implementando un flujo de trabajo lógico y previniendo errores de usuario. La sección inferior de la interfaz consiste en un área de texto desplazable que muestra en tiempo real la salida del servidor, facilitando el seguimiento del proceso y la detección de posibles errores. La GUI implementa un manejo asíncrono de las operaciones de red mediante hilos (threads), lo que previene el bloqueo de la interfaz durante las operaciones de larga duración. Además, se han incorporado elementos de diseño como un esquema de colores amigables, fuentes personalizadas y botones estilizados para mejorar la estética y la experiencia del usuario.

VIII. DISCUSIÓN

El análisis de los resultados del entrenamiento del modelo permitió discernir varios aspectos importantes sobre su rendimiento y áreas de mejora potencial. La constante disminución de la pérdida de entrenamiento indica que el modelo está aprendiendo de manera eficaz. Sin embargo, es importante mantener un equilibrio en esta disminución, ya que una caída demasiado rápida podría ser un indicador de sobreajuste, lo cual podría comprometer la capacidad del modelo ante nuevos datos. Se observó que para 50 y 200 épocas, el modelo podría estar todavía en una fase temprana de aprendizaje o que había algunas irregularidades en estas ejecuciones de entrenamiento. Especialmente en 200 épocas, se sugiere que esta ejecución en particular pudo haber tenido algunos problemas o irregularidades.

Se observaron variaciones significativas en el Coeficiente de Dice tanto en el conjunto de entrenamiento como en el de validación, particularmente por cada canal de salida. La complejidad intrínseca de cada estructura, la calidad de las imágenes, la calidad de las anotaciones empleadas y la cantidad de datos de entrenamiento disponibles para cada canal son algunas de las causas de estas variaciones. Este análisis puede servir como guía para las estrategias de recolección de datos y anotaciones futuras, con el objetivo de aumentar la precisión del modelo. Además, el análisis reforzó la observación de que, aunque un entrenamiento más prolongado mejora el rendimiento del modelo en los datos de entrenamiento, no se traduce necesariamente en un mejor rendimiento en el conjunto de validación. La creciente diferencia entre el rendimiento de entrenamiento y el de validación sugiere que las estrategias para mitigar el sobreajuste (como la regularización, el aumento de datos o la detención temprana) podrían ser beneficiosas, especialmente en las últimas fases del entrenamiento.

Aunque no se ha evidenciado un sobreajuste claro en los gráficos analizados en los resultados obtenidos, es recomendable en futuras implementaciones continuar monitoreando la discrepancia entre el desempeño en el conjunto de entrenamiento y el conjunto de validación. Un aumento significativo en esta diferencia podría ser un indicativo de que el modelo está comenzando a sobre-ajustarse a los datos de entrenamiento. La implementación de técnicas de mejora dirigidas, como la incorporación de más datos de entrenamiento para esos canales que

presentaron inconvenientes o la modificación de los algoritmos de segmentación, es posible gracias a esta información, que permite identificar áreas particulares donde el modelo podría ser optimizado. Como se muestra en la **Fig. 19**, estos hallazgos no solo ayudarán a la mejora continua del modelo, sino que también brindan una base para investigaciones futuras en el campo de la segmentación de imágenes médicas.

Es importante destacar que la variabilidad en el rendimiento del modelo entre diferentes canales y estructuras anatómicas subraya la necesidad de un enfoque adaptativo en el desarrollo de modelos de segmentación de imágenes médicas. Las estructuras que mostraron un rendimiento inferior podrían beneficiarse de técnicas de aumento de datos específicas o de arquitecturas de red neuronal más especializadas. Además, la definición de una ROI (del inglés '*Region of interest*') o relaciones espaciales entre estructuras podría mejorar la precisión y la consistencia de las segmentaciones. Futuros estudios podrían explorar la integración del método de '*Active learning*' integrado dentro de MONAI Label o el uso de arquitecturas de red más avanzadas, como las redes de atención, para abordar los inconvenientes específicos identificados en este análisis.

Por otra parte, el desarrollo del módulo SimplifiedMONAILabel, basado en el módulo preexistente de MONAI Label, genera un entorno de trabajo más directo e intuitivo para el personal médico al que está dirigido. Este módulo ofrece una serie de ventajas que mejoran la experiencia del usuario y optimizan el flujo de trabajo en tareas de segmentación.

Una de las principales fortalezas del SimplifiedMONAILabel radica en su enfoque en la simplificación y la usabilidad. Al reducir la complejidad de la interfaz de usuario y centrarse en las funcionalidades esenciales de segmentación, el módulo logra disminuir la curva de aprendizaje para los usuarios, especialmente aquellos que no requieren todas las características avanzadas del módulo original. Esta simplificación no solo facilita el uso del módulo, sino que también puede aumentar la eficiencia en el procesamiento de imágenes médicas en entornos clínicos y de investigación.

La integración mejorada con 3D Slicer es otro aspecto destacable del SimplifiedMONAILabel. Al utilizar widgets y nodos nativos de Slicer, el módulo brinda una experiencia más fluida dentro del entorno de trabajo. Esta integración sencilla, pero a la vez robusta al aprovechar la capacidad de una instancia remota, permite también al usuario final aprovechar las capacidades de Slicer de manera más efectiva, mejorando el flujo de trabajo general en el análisis de TC enfocado en cardiología pediátrica.

Es importante resaltar que, a pesar de su simplicidad, el módulo mantiene una flexibilidad considerable. La capacidad de seleccionar entre múltiples modelos de segmentación, realizar inferencias en servidores remotos y personalizar ciertas configuraciones permite a los usuarios adaptar el módulo a sus necesidades específicas.

El enfoque en la seguridad y la generalización son características adicionales que amplían la utilidad y accesibilidad del módulo. La implementación de un sistema de autenticación descentralizado al estar alojado en la nube de AWS para el manejo de datos médicos sensibles, mientras que el soporte para múltiples idiomas que se encuentra como parte del código de la extensión facilita su adopción en diversos contextos donde quiera ser implementada.

Finalmente, como parte integral del desarrollo del flujo de trabajo, se implementó una interfaz gráfica de usuario (GUI) para facilitar la conexión y la inicialización del servidor MONAI Label en una instancia remota. Esta GUI, desarrollada en Python utilizando la biblioteca Tkinter, mejora aún más el flujo de trabajo diseñado inicialmente.

La interfaz gráfica se diseñó con un enfoque en la simplicidad y la eficiencia, proporcionando una serie de funcionalidades importantes. En primer lugar, permite a los usuarios ingresar la dirección IPv4 pública de la instancia EC2 y seleccionar el archivo PEM necesario para la autenticación SSH. Esta característica simplifica significativamente el proceso de conexión, eliminando la necesidad de que los usuarios interactúen directamente con la línea de comandos para establecer la conexión con la instancia.

Una vez establecida la conexión, la GUI ofrece una secuencia guiada de pasos para activar el entorno conda apropiado e iniciar el servidor MONAI Label. Este enfoque paso a paso no solo reduce la probabilidad de errores de usuario, sino que también proporciona una visualización clara del progreso del proceso de inicialización. Además, la interfaz incluye un área de salida de texto desplazable que muestra en tiempo real la respuesta del servidor, permitiendo a los usuarios monitorear el estado del proceso y diagnosticar cualquier problema durante la ejecución de los comandos. Con lo anterior, se permite que un grupo más amplio de profesionales médicos e investigadores accedan y utilicen estas capacidades avanzadas de segmentación sin necesidad de poseer conocimientos técnicos profundos en administración de servidores o línea de comandos.

Además, la arquitectura modular de la GUI, que separa claramente las funcionalidades de conexión SSH, activación del entorno e inicio del servidor, facilita futuras expansiones y mejoras. Por ejemplo, se podrían incorporar fácilmente opciones adicionales para la selección de diferentes conjuntos de datos o modelos de segmentación, aumentando aún más la flexibilidad y utilidad de la herramienta.

IX. CONCLUSIONES

- El uso de herramientas como 3D Slicer y MONAI Label permitió superar las limitaciones financieras para acceder a software comercial, demostrando que el uso de soluciones de código abierto puede obtener buenos resultados. Esto, debido a la flexibilidad y accesibilidad de estas herramientas, permite futuras mejoras o adaptaciones del protocolo.
- En este desarrollo, el protocolo semiautomático demostró una buena precisión en la segmentación precisa de estructuras cardíacas como la aorta y los ventrículos. Los radiólogos y cardiólogos podrán trabajar con un entendimiento anatómico más claro y preciso con este avance, lo que afectará la forma en que se planean las intervenciones quirúrgicas o quirúrgicas.
- El protocolo semiautomático propuesto, que combina algoritmos de aprendizaje profundo y segmentación manual, ha logrado reducir el tiempo que normalmente se requeriría para una segmentación completamente manual. Esto mejora la eficiencia en el manejo de grandes cantidades de datos, lo cual responde bien a la necesidad de reducir tiempos de procesamiento de las imágenes en ambiente clínico donde el tiempo es un factor crítico.
- A pesar de que el protocolo ha demostrado ser efectivo, es necesario continuar mejorando su precisión, especialmente en estructuras cardíacas complejas que varían más entre pacientes con diferentes cardiopatías congénitas. El entrenamiento del modelo también podría beneficiarse de bases de datos más amplias, lo que aumentaría su capacidad de generalización.

X. RECOMENDACIONES

En cuanto al trabajo futuro, es posible la implementación de técnicas de visualización avanzadas para los resultados de segmentación. Esto podría incluir la representación 3D interactiva de las estructuras segmentadas o la superposición dinámica de resultados en diferentes modalidades de imagen. La integración de herramientas de análisis cuantitativo post-segmentación también representaría una adición de gran valor para personal médico o investigativo. Esto permitiría al personal médico extraer métricas relevantes directamente de las segmentaciones, facilitando la cuantificación de volúmenes, formas y otros parámetros de interés clínico o de investigación.

Es importante resaltar que, también es necesario hacer la exploración de técnicas de optimización de rendimiento, como la inferencia acelerada por GPU de manera escalable mediante las diferentes instancias de los servicios EC2 de AWS o la paralelización de procesos, podría mejorar aún más la eficiencia del módulo, especialmente en el procesamiento de grandes conjuntos de datos o en aplicaciones en tiempo real.

De manera similar, la exploración del módulo de realidad virtual '*Slicer Virtual Reality*' desarrollado por KitWare para 3D Slicer también brindaría un avance mayor al aumentar las capacidades del módulo desarrollado durante este proyecto, para la integración de la salida del modelo con una compresión más inmersiva de la anatomía obtenida de la segmentación.

Adicionalmente, es importante explorar las capacidades del modelo para expandir su uso hacia otras cardiopatías congénitas que el personal médico especialista lo requiera, considerando que el tipo de paciente que conforman normalmente la base de datos tienden a ser pacientes que tienen múltiples diagnósticos y que hacen necesaria que la capacidad del modelo vaya más allá de la generalización de estructuras morfológicamente sanas, y que es más poco probable dada la complejidad de las cardiopatías, que el diagnóstico esté limitado a un único dictamen.

Finalmente, hacer un análisis prospectivo del uso de la herramienta con los especialistas brindaría un panorama más específico para conocer estadísticamente como mejora el uso de la

herramienta en tiempos de procedimiento, así como hacer una retroalimentación activa del flujo de trabajo para futuras mejoras haciendo depuración de errores en la segmentación obtenida y cómo mejorarla con nuevos datos de entrada.

REFERENCIAS

- [1] "Cardiac Computed Tomography: Techniques and Applications." *Radiographics*, vol. 31, no. 5, 2011, pp. 1225-1246.
- [2] "Three-Dimensional Visualization of Cardiac Anatomy Using Computed Tomography." *Journal of Cardiovascular Computed Tomography*, vol. 3, no. 2, 2009, pp. 126-134.
- [3] "Diagnostic Accuracy of Cardiac Computed Tomography Angiography for Coronary Artery Disease: A Meta-Analysis." *JAMA*, vol. 309, no. 11, 2013, pp. 1147-1156.
- [4] "Improving Cardiac Tomography Reconstructions with Adaptive Preprocessing Techniques." *Proceedings of the IEEE International Symposium on Biomedical Imaging*, 2018, pp. 1234-1238.
- [5] "Augmented Reality in Cardiology: A Review." *Journal of Medical Systems*, vol. 42, no. 10, 2018, pp. 1-11.
- [6] "Interdisciplinary Approaches to Advancing Cardiac Imaging and Diagnosis." *Journal of Healthcare Engineering*, vol. 2019, 2019, pp. 1-12.
- [7] C. Baladrón, J. Gómez, and I. J. Amat-Santos, "Big data y nuevas tecnologías de la información: qué necesita saber el cardiólogo," *Revista española de cardiología/Revista española de cardiología*, vol. 74, no. 1, pp. 81–89, Jan. 2021, doi: <https://doi.org/10.1016/j.recesp.2020.06.017>.
- [8] Vera, Miguel, *Automatic segmentation of the ascending aorta and aortic valve in computed tomography images*, *Revista Latinoamericana de Hipertensión*, vol. 12, no. 2, 2017, pp.70-78. Redalyc, <https://www.redalyc.org/articulo.oa?id=170252186005>
- [9] Y. Huérfano et al., "Métodos de segmentación de imágenes cardíacas: Fundamentos y alcance," *Revista Latinoamericana de Hipertensión*, vol. 10, 2015, Available: https://www.revhipertension.com/rlh_10_3_2015/metodos%20de%20segmentacion.pdf
- [10] M. Vera, V. Molina, K. Huerfano, and José ChacónMgSc, "Segmentación automática tridimensional de estructuras ventriculares cerebrales en imágenes de resonancia..." ResearchGate, 2016. https://www.researchgate.net/publication/315759501_Segmentacion_automatica_tridimensional_de_estructuras_ventriculares_cerebrales_en_imagenes_de_resonancia_magnetica.
- [11] M. Vera et al., "Automatic segmentation of the left atrium in cardiac computed tomography" *Revista Latinoamericana de Hipertensión*, Vol. 11 - N° 3, 2016, Available: https://www.revhipertension.com/rlh_11_3_2016/segmentacion%20automatica%20de%20la%20auricula%20izq.pdf
- [12] Vera, Miguel, y Huérfano, Yoleidy, y Contreras-Velásquez, Julio, y Del Mar, Atilio, y Rodríguez, Johel, y Bautista, Nahid, y Wilches-Durán, Sandra, y Graterol-Rivas, Modesto, y Riaño-Wilches, Daniela, y Rojas, Joselyn, y Bermúdez Valmore. "Segmentación automática de la arteria aorta ascendente y la válvula aórtica en imágenes de tomografía computarizada cardíaca." *Revista Latinoamericana de Hipertensión*, vol. 12, no. 2, 2017,

- pp.70-78. Redalyc, <https://www.redalyc.org/articulo.oa?id=170252186005>
- [13] Vera, Miguel, y Huérfano, Yoleidy, “Medical Imaging Segmentation Methods: Foundations and Scope” *Revista Latinoamericana de Hipertensión*, Vol. 10 - Nº 3, 2015, Available:https://www.revhipertension.com/rlh_10_3_2015/metodos%20de%20segmentacion.pdf
- [14] R. Cano-Zarate, E. K. Hernández-Barajas, H. H. Hernández-Barajas, Aloha Meave-González, and N. Espinola-Zavaleta, “Efectos de la impresión 3D en la planificación quirúrgica de las cardiopatías congénitas,” *Archivos de cardiología de México*, vol. 91, no. 1, May 2021, doi: <https://doi.org/10.24875/acm.20000395>.
- [15] A. RSNA, “Procedimientos de tomografía axial computarizada (TC o TAC),” *Radiologyinfo.org*, 2024. Available: <https://www.radiologyinfo.org/es/ctscan>.
- [16] M. A. Mafraji, “Tomografía computarizada (TC),” *Manuale Merck versión para el público general*, Nov. 2023. Available: <https://www.merckmanuals.com/es-us/hogar/temas-especiales/pruebas-de-diagn%C3%B3stico-por-la-imagen-habituales/tomograf%C3%ADa-computarizada-tc>.
- [17] “Radiografías, tomografías computarizadas (TC) e imágenes por resonancia magnética (IRM) (X-rays, CT Scans, and MRIs) - OrthoInfo - AAOS,” *Aaos.org*, 2019. Available: <https://orthoinfo.aaos.org/es/treatment/radiografias-tomografias-computarizadas-tc-e-imagenes-por-resonancia-magnetica-irm-x-rays-ct-scans-and-mris/>.
- [18] “Tomografía computarizada: MedlinePlus enciclopedia médica,” *Medlineplus.gov*, 2023. Available: <https://medlineplus.gov/spanish/ency/article/003330.htm>.
- [19] A. Elena, “Segmentación y procesamiento de imágenes médicas,” *REVISTA SAYWA*, vol. 3, no. 4, pp. 13–21, 2021, Accessed: Apr. 18, 2024. [Online]. Available: <https://revistas.uan.edu.co/index.php/saywa/article/view/1454>
- [20] “MONAI - Home,” *Monai.io*, 2023. <https://monai.io/>
- [21] A. Diaz-Pinto et al., “MONAI Label: A framework for AI-assisted interactive labeling of 3D medical images,” *Medical Image Analysis*, vol. 95, p. 103207, Jul. 2024, doi: <https://doi.org/10.1016/j.media.2024.103207>.
- [22] “MONAI Label - Product Page,” *Monai.io*, 2024. <https://monai.io/label.html>
- [23] N. Roulet, “Segmentación automática multi-tarea de imágenes médicas utilizando redes neuronales profundas.” Available: https://sinc.unl.edu.ar/sinc-publications/2018/RFF18/sinc_RFF18.pdf
- [24] “Automated ischemic stroke lesion segmentation from 3D MRI,” 2022. [Online]. Available: <https://doi.org/10.5281/zenodo.5083813>
- [25] EITCA Academy, “¿Cómo facilitan las conexiones residuales en las arquitecturas ResNet el entrenamiento de redes neuronales muy profundas y qué impacto tuvo esto en el rendimiento de los modelos de reconocimiento de imágenes? - Academia EITCA,” *EITCA Academy*, May 21, 2024.

- [26] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137–1149, Jun. 2017, doi: <https://doi.org/10.1109/tpami.2016.2577031>.
- [27] K. Sakamoto et al., "Automated evaluation of masseter muscle volume: deep learning prognostic approach in oral cancer," *BMC cancer*, vol. 24, no. 1, Jan. 2024, doi: <https://doi.org/10.1186/s12885-024-11873-y>.
- [28] S. Arshad, T. Amjad, A. Hussain, I. Qureshi, and Q. Abbas, "Dermo-Seg: ResNet-UNet Architecture and Hybrid Loss Function for Detection of Differential Patterns to Diagnose Pigmented Skin Lesions," *Diagnostics*, vol. 13, no. 18, pp. 2924–2924, Sep. 2023, doi: <https://doi.org/10.3390/diagnostics13182924>.
- [29] yerramvarun, "Understanding DICE COEFFICIENT," *Kaggle.com*, Dec. 26, 2020. <https://www.kaggle.com/code/yerramvarun/understanding-dice-coefficient> (accessed Aug. 23, 2024).
- [30] K. H. Zou et al., "Statistical validation of image segmentation quality based on a spatial overlap index1," *Academic Radiology*, vol. 11, no. 2, pp. 178–189, Feb. 2004, doi: [https://doi.org/10.1016/s1076-6332\(03\)00671-8](https://doi.org/10.1016/s1076-6332(03)00671-8).
- [31] "Clasificación: Exactitud, recuperación, precisión y métricas relacionadas," *Google for Developers*, 2024. <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=es-419> (accessed Aug. 23, 2024).
- [32] A. Jain, "A Comprehensive Guide to Performance Metrics in Machine Learning," *Medium*, Feb. 06, 2024. <https://medium.com/@abhishekjainindore24/a-comprehensive-guide-to-performance-metrics-in-machine-learning-4ae5bd8208ce> (accessed Aug. 23, 2024).
- [33] Rajiah, P. (2018). Cardiac CT angiography: current status and continuing challenges. *The British Journal of Radiology*, 91(1089), 20180049.
- [34] Peng, P., Lekadir, K., Gooya, A., Shao, L., Petersen, S. E., & Frangi, A. F. (2016). A review of heart chamber segmentation for structural and functional analysis using cardiac magnetic resonance imaging. *Magnetic Resonance Materials in Physics, Biology and Medicine*, 29(2), 155-195.
- [35] Ecabert, O., Peters, J., Schramm, H., Lorenz, C., von Berg, J., Walker, M. J., ... & Weese, J. (2008). Automatic model-based segmentation of the heart in CT images. *IEEE Transactions on Medical Imaging*, 27(9), 1189-1201.
- [36] Tan, L. K., & Jaspal, J. (2017). Modern techniques of cardiovascular CT and MRI in congenital heart disease. *The British Journal of Radiology*, 90(1079), 20170399.
- [37] Rizvi, A., Mao, S., & Su, Y. (2019). Cardiac computed tomography for planning structural heart interventions. *Interventional Cardiology Review*, 14(1), 37.
- [38] J. Solis, M. Sitges, R. A. Levine, and J. Hung, "Three-dimensional echocardiography. New possibilities in mitral valve assessment," *Revista española de cardiología*, vol. 62, no. 2,

- pp. 188–98, 2009, Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2822664/>.
- [39] A. Bravo et al., “Análisis de imágenes cardíacas tridimensionales.” Available: https://www.revhipertension.com/rlh_11_4_2016/analisis_de_imagenes_cardiacas.pdf.
- [40] S. Park and M. Chung, “Cardiac segmentation on CT Images through shape-aware contour attentions,” *Computers in Biology and Medicine*, vol. 147, p. 105782, Aug. 2022, doi: <https://doi.org/10.1016/j.combiomed.2022.105782>
- [41] R. A. Peña-Juarez, C. A. Corona-Villalobos, M. A. Medina-Andrade, L. Garrido-García, C. Gutierrez-Torpey, and Moisés Mier-Martínez, “Presentación y manejo de las cardiopatías congénitas en el primer año de edad,” *Archivos de cardiología de México (En línea)*, vol. 91, no. 3, Aug. 2021, doi: <https://doi.org/10.24875/acm.20000113>. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8351658/>.
- [42] “Enfermedades del corazón más comunes en niños,” *Shaio.org*, 2023. Available: <https://www.shaio.org/causas-diganostico-y-tratamiento-de-cardiopatias-congenitas>.
- [43] “Diagnóstico,” *www.bostonscientific.com*, Aug. 19, 2020. Available: <https://www.bostonscientific.com/es-co/condiciones-de-salud/cardiopatia-congenita/diagnostico.html>.
- [44] H. Gómez et al., “Conducto arterioso persistente en adulto,” *Acta médica Grupo Ángeles*, vol. 17, no. 2, pp. 181–184, 2019, Available: https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1870-7203201900020018.
- [45] E. Elizabeth, N. Acurio, M. Mónica, and D. Ríos, “UNIVERSIDAD POLITÉCNICA SALESIANA SEDE GUAYAQUIL TRABAJO DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE: INGENIERO DE SISTEMAS CARRERA: INGENIERÍA DE SISTEMAS TEMA: ‘DESAFÍOS Y OPORTUNIDADES DEL EMPLEO DE LA REALIDAD AUMENTADA EN LA SALUD, REVISIÓN SISTEMÁTICA’ AUTOR,” 2021. Available: <https://dspace.ups.edu.ec/bitstream/123456789/20930/1/UPS-GT003371.pdf>
- [46] E. Aguilar, A. Vivas, and J. Sabater, “Una aproximación a la realidad aumentada y sus aplicaciones quirúrgicas,” *Entre ciencia e ingeniería*, vol. 12, no. 24, pp. 15–24, Dec. 2018, doi: <https://doi.org/10.31908/19098367.3811>.
- [47] N. Aslani, A. Behmanesh, A. Garavand, M. Maleki, F. Davoodi, and R. Shams, “The Virtual Reality Technology Effects and Features in Cardiology Interventions Training: A Scoping Review,” *Medical journal of the Islamic Republic of Iran*, Jun. 2022, doi: <https://doi.org/10.47176/mjiri.36.77>. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9448494/>.
- [48] “embodi3D.com,” *embodi3D.com*, 2019. <https://www.embodi3d.com/>.
- [49] “InVesalius,” *Github.io*, 2024. <https://invesalius.github.io/>.
- [50] “what-is-cloud-computing,” *Amazon Web Services, Inc.*, 2024. <https://aws.amazon.com/es/what-is-cloud-computing/>.
- [51] “AWS | Elastic compute cloud (EC2) de capacidad modificable en la nube,” *Amazon Web*

- Services, Inc., 2023. <https://aws.amazon.com/es/ec2/>.
- [52] “Vue PACS Client.” Accessed: Aug. 29, 2024. [Online]. Available: https://pacshub.rimarad.com/help/en_US/webHelp/8G7607_OLH_CARESTREAM_Vue_PACS_Client_en.pdf
- [53] “Nuevas instancias G5 de Amazon EC2 (1:20),” Amazon Web Services, Inc., 2024. <https://aws.amazon.com/es/ec2/instance-types/g5/>.
- [54] “¿Qué es SSH? Definición y detalles,” Paessler.com, 2018. <https://www.paessler.com/es/it-explained/ssh> (accessed Jul. 04, 2024).
- [55] “Introducing WinSCP :: WinSCP,” Winscp.net, Mar. 24, 2024. <https://winscp.net/eng/docs/introduction> (accessed Jul. 04, 2024).
- [56] “tutorials/auto3dseg at main · Project-MONAI/tutorials,” GitHub, 2024. <https://github.com/Project-MONAI/tutorials/tree/main/auto3dseg>
- [57] “monailabel.tasks.train.basic_train — MONAI Label 0.8.3 Documentation,” Monai.io, 2024. https://docs.monai.io/projects/label/en/latest/_modules/monailabel/tasks/train/basic_train.html.
- [58] L. Baskaran, S. J. Al’Aref, G. Maliakal, and L. J. Shaw, “Automatic segmentation of multiple cardiovascular structures from cardiac computed tomography angiography...,” ResearchGate, May 06, 2020. https://www.researchgate.net/publication/341198676_Automatic_segmentation_of_multiple_cardiovascular_structures_from_cardiac_computed_tomography_angiography_images_using_deep_learning.
- [59] “¿Qué es el sobreajuste? - Explicación del sobreajuste en machine learning - AWS,” Amazon Web Services, Inc., 2022. <https://aws.amazon.com/es/what-is/overfitting/>.
- [60] “Validación cruzada - Amazon Machine Learning,” Amazon.com, 2024. https://docs.aws.amazon.com/es_es/machine-learning/latest/dg/cross-validation.html#:~:text=La%20validaci%C3%B3n%20cruzada%20es%20una,subconjunto%20complementario%20de%20los%20datos.
- [61] “¿Qué es el aprendizaje supervisado? | IBM,” Ibm.com, May 14, 2024. <https://www.ibm.com/mx-es/topics/supervised-learning>.
- [62] “¿Qué es TensorFlow y para qué sirve?,” ¿Qué es TensorFlow y para qué sirve?, 2022. <https://www.incentro.com/es-ES/blog/que-es-tensorflow>.
- [63] Itop, “Tensorflow,” Itop.es, 2023. <https://www.itop.es/soluciones-tecnologicas/business-analytics-business-intelligence/tensorflow.html>.
- [64] “Extension Wizard — 3D Slicer documentation,” Readthedocs.io, 2024. https://slicer.readthedocs.io/en/latest/user_guide/modules/extensionwizard.html.
- [65] “NITRC: MRICron: Tool/Resource Info,” Nitrc.org, 2019. <https://www.nitrc.org/projects/mricron>.

-
- [66] “Gradient Anisotropic Diffusion — 3D Slicer documentation,” Readthedocs.io, 2024. https://slicer.readthedocs.io/en/latest/user_guide/modules/gradientanisotropicdiffusion.html.
- [67] “Modules:MedianFilter-Documentation-3.6 - Slicer Wiki,” Slicer.org, 2024. <https://www.slicer.org/wiki/Modules:MedianFilter-Documentation-3.6>.
- [68] “lassoan/SlicerMONAIAuto3DSEg: Extension for 3D Slicer for running MONAI Auto3DSEg models,” GitHub, Apr. 22, 2024. <https://github.com/lassoan/SlicerMONAIAuto3DSEg>.
- [69] Ultralytics, “TensorBoard,” Ultralytics.com, 2024. <https://docs.ultralytics.com/es/integrations/tensorboard/#tensorboard>.
- [70] EITCA Academy, “¿Cómo ayuda TensorBoard a visualizar y comparar el rendimiento de diferentes modelos? - Academia EITCA,” EITCA Academy, Aug. 13, 2023. <https://es.eitca.org/artificial-intelligence/eitc-ai-dlptfk-deep-learning-with-python-tensorflow-and-keras/tensorboard/optimizing-with-tensorboard/examination-review-optimizing-with-tensorboard/how-does-tensorboard-help-in-visualizing-and-comparing-the-performance-of-different-models/>.
- [71] “MONAILabel/plugins/slicer at main · Project-MONAI/MONAILabel,” GitHub, 2024. <https://github.com/Project-MONAI/MONAILabel/tree/main/plugins/slicer>.
- [72] “Slicer/Base/Python/slicer/ScriptedLoadableModule.py at main · Slicer/Slicer,” GitHub, 2024. <https://github.com/Slicer/Slicer/blob/main/Base/Python/slicer/ScriptedLoadableModule.py>.
- [73] “Developer Guide — 3D Slicer documentation,” Readthedocs.io, 2024. https://slicer.readthedocs.io/en/latest/developer_guide/index.html.

ANEXOS

El siguiente anexo corresponde al repositorio de GitHub que contiene archivos relacionados con el protocolo desarrollado dentro de este proyecto para pacientes pediátricos con enfermedades congénitas. Incluye scripts para la segmentación de tomografías computarizadas utilizando MONAI Label, así como flujos de trabajo configurados para 3D Slicer. También se proporciona información sobre los parámetros del dataset necesario y archivos necesarios para reproducir el proceso de segmentación mediante inferencia. El objetivo general como se planteó inicialmente, es mejorar la visualización anatómica y facilitar la planificación quirúrgica en procedimientos de cardiología intervencionista.

En el enlace proporcionado, se encuentran los scripts y las guías de uso de lo siguiente:

- Extensión de 3D Slicer '*SimplifiedMONAILabel*'
- Guías de AWS y configuración de la instancia EC2 con las librerías necesarias.
- Interfaz gráfica de usuario (GUI) para iniciar la instancia EC2.
- Archivos del modelo y su desempeño.
- Licencia y explicación del proyecto en un archivo README.

Enlace al repositorio: <https://github.com/doviedob/CardioAR3D>