

Desarrollo de un Sistema Interactivo de Interconexión y Análisis de Imágenes DICOM con Retroalimentación Médica

Pablo Santos Blázquez, Francisco José García Peñalvo, and Andrea Vázquez Ingelmo

Universidad de Salamanca
Departamento de Informática y Automática
Facultad de Ciencias.
Plaza de los Caídos s/n
37008 Salamanca, España
{pablosbl,fgarcia,andreavazquez}@usal.es

Resumen La segmentación precisa de estructuras cardíacas en imágenes médicas es crucial para un diagnóstico y tratamiento efectivos. Este proyecto presenta el desarrollo de "dAIcom", una plataforma web interactiva para la visualización, anotación y análisis de imágenes DICOM (*Digital Imaging and Communication in Medicine*), mejorando la colaboración multidisciplinaria y la retroalimentación médica. Para ello, se ha integrado un modelo de inteligencia artificial basado en la arquitectura UNET, entrenado específicamente para segmentar estructuras cardíacas como el ventrículo izquierdo, la aurícula izquierda y el miocardio en imágenes obtenidas mediante el uso de ultrasonidos (ecocardiografías). Con el fin de evaluar el rendimiento y la adaptabilidad del modelo, se han realizado tres experimentos de reentrenamiento. Los resultados revelan que un mayor número de imágenes y anotaciones mejora significativamente la capacidad de generalización del modelo, reduciendo el sobreajuste. Además, se desarrolla un sistema PACS (*Picture Archiving and Communication System*) para gestionar y almacenar eficientemente las imágenes DICOM, asegurando la interoperabilidad y el almacenamiento seguro de los datos médicos. A lo largo del trabajo se han identificado diversos desafíos, incluyendo dificultades para obtener imágenes médicas debido a restricciones de confidencialidad y limitaciones computacionales. El trabajo futuro se centra en ampliar el conjunto de datos, optimizar los hiperparámetros y mejorar el proceso de anotación para incrementar la robustez y relevancia clínica del sistema. Estos esfuerzos buscan asegurar que la plataforma "dAIcom" no solo sea tecnológicamente avanzada, sino también clínicamente útil para mejorar la atención médica.

Keywords: Segmentación de imágenes, DICOM, U-NET, Inteligencia Artificial, Reentrenamiento, Dice Loss, Colaboración Médica

1. Introducción

El análisis y diagnóstico mediante imágenes médicas constituye un pilar fundamental en la medicina moderna. Técnicas como la tomografía computarizada (CT), la resonancia magnética (MRI), la tomografía por emisión de positrones (PET) y los ultrasonidos (US) proporcionan a los médicos información visual detallada del cuerpo humano, permitiendo la detección temprana de enfermedades, el seguimiento de tratamientos y la planificación de intervenciones quirúrgicas. Estas técnicas han transformado la manera en que se abordan muchas enfermedades, incrementando la precisión diagnóstica y mejorando significativamente los resultados de los pacientes.

El avance en las tecnologías de inteligencia artificial (IA) ha añadido una nueva dimensión a este campo, revolucionando la interpretación de imágenes médicas. Los algoritmos de aprendizaje automático, basados en redes neuronales profundas, son capaces de analizar vastas cantidades de datos de imágenes, identificar patrones complejos y ofrecer diagnósticos precisos y rápidos que a menudo superan las capacidades humanas. La integración de estos algoritmos en radiología ha permitido mejorar sustancialmente la detección de nódulos pulmonares, la identificación de tumores y el análisis de enfermedades retinianas [1, 2].

Este proyecto se basa en trabajos previos realizados mediante la plataforma CARTIER-IA [3], un programa enfocado en la investigación y desarrollo de tecnologías avanzadas de inteligencia artificial aplicadas a la salud. CARTIER-IA busca potenciar la colaboración entre instituciones académicas, hospitales y empresas tecnológicas para impulsar innovaciones que mejoren el diagnóstico y tratamiento de enfermedades mediante el uso de IA.

El objetivo principal de este trabajo es desarrollar «dAIcom», una plataforma web interactiva diseñada para asistir a los profesionales de la salud en la visualización, anotación y análisis de imágenes DICOM [4], mejorando así la colaboración multidisciplinaria y la retroalimentación médica. Los objetivos concretos de este proyecto incluyen (A) la creación una interfaz intuitiva que permita a los médicos acceder y analizar imágenes DICOM de manera eficiente; (B) implementar herramientas de anotación que faciliten la retroalimentación y colaboración entre los profesionales de la salud; (C) integrar un modelo de inteligencia artificial basado en la arquitectura UNET [5], específicamente entrenado para la segmentación de imágenes cardíacas, que permita identificar y segmentar de manera precisa estructuras anatómicas como el ventrículo izquierdo, la aurícula izquierda y el miocardio en imágenes de ultrasonidos cardíacos; y (D) desarrollar un sistema PACS que garantice la gestión y almacenamiento seguro de las imágenes DICOM.

Para evaluar el rendimiento del modelo UNET y su capacidad de adaptación a nuevas anotaciones, se llevaron a cabo tres experimentos distintos de reentrenamiento. Los resultados de estos experimentos demostraron que la inclusión de un mayor número de imágenes del dataset original junto con nuevas anotaciones mejora la capacidad de generalización del modelo, reduciendo significativamente el sobreajuste.

2. Estado de la Cuestión

Con el fin de identificar el estado actual de las técnicas y herramientas utilizadas en la segmentación de imágenes médicas y su integración en plataformas interactivas, se ha realizado un Mapeo Sistemático de la Literatura (MSL) siguiendo el marco de referencia «PRISMA 2020» [6] para asegurar una revisión exhaustiva y estructurada.

2.1 Mapeo Sistemático de la Literatura

El desarrollo del Mapeo Sistemático de la Literatura (MSL) ha seguido el método propuesto en [7]. La Fig. 1 muestra la estructura planteada para la realización del mismo, distinguiendo entre una primera etapa de planificación y una segunda etapa de revisión.

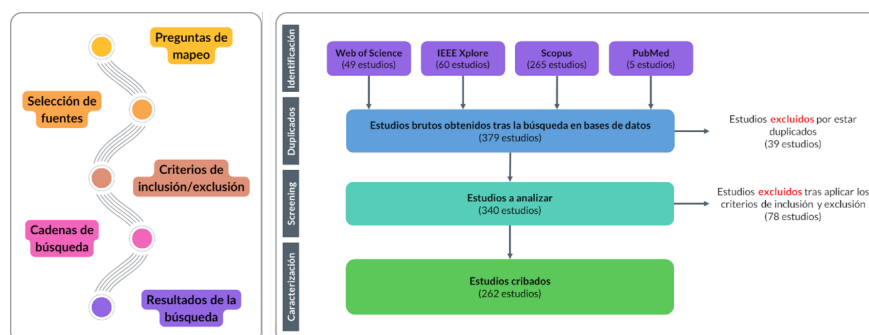


Figura 1: Estructura del Mapeo Sistemático de la Literatura

El proceso de mapeo comenzó con la definición de las preguntas de mapeo (MQs) enfocadas en la extracción de la información relevante para el estudio. Las preguntas fueron:

- **MQ1:** ¿Cuántos estudios que aborden esta cuestión han sido publicados en los últimos cinco años?
- **MQ2:** ¿Cuáles son los autores más activos en el campo de investigación?
- **MQ3:** ¿Qué técnicas de aprendizaje automático se han empleado para la segmentación y el análisis de imágenes DICOM en entornos clínicos hasta la fecha?
- **MQ4:** ¿Cuáles son las principales áreas médicas en las que se aplican técnicas de aprendizaje automático?

Estas preguntas de mapeo fueron planteadas para resolver la pregunta de investigación (RQ) principal:

¿Cuál es el estado actual en la aplicación de técnicas de aprendizaje automático para la segmentación y análisis de imágenes DICOM en entornos clínicos?

Para la búsqueda de estudios, se aplicaron criterios de inclusión y exclusión, y se definieron cadenas de búsqueda específicas para cada base de datos: «Web of Science» [8], «IEEE Xplore» [9], «Scopus» [10] y «PubMed» [11]. La revisión se llevó a cabo siguiendo las pautas «PRISMA 2020», y se recuperaron un total de 379 estudios, de los cuales 262 superaron los criterios de inclusión y exclusión y por lo tanto, fueron finalmente analizados.

2.2 Resultados del Mapeo

Los resultados del mapeo sistemático se pueden resumir en los siguientes puntos:

2.2.1 Cantidad de Estudios Publicados Entre 2019 y 2024, se observó un incremento significativo en el número de publicaciones, siendo el año 2022 el momento con más publicaciones, manteniéndose esta tendencia durante el año 2023.




Figura 2: Estudios publicados por año

2.2.2 Autores más Activos Se identificaron 31 autores que han publicado tres o más estudios en este campo, siendo los autores más activos Li J., Li Y. y Wang Y., entre otros.




Figura 3: Número de publicaciones por autor

2.2.3 Técnicas de Aprendizaje Automático Las técnicas identificadas como más recurrentes incluyen las Redes Neuronales Convolucionales (CNN), las Redes U-Net, y técnicas de Transfer Learning, como se muestra en la Fig. 4. Estas técnicas han demostrado ser efectivas para la segmentación precisa de imágenes médicas.




Figura 4: Técnicas de aprendizaje automático más utilizadas

2.2.4 Áreas Médicas Las principales áreas de aplicación incluyen especialidades como oncología, neumología, neurología y cardiología. Estas especialidades se benefician significativamente de las técnicas avanzadas de segmentación y análisis, mejorando tanto el diagnóstico como el tratamiento de enfermedades graves.

2.3 Conclusiones del Estado de la Cuestión

El Mapeo Sistemático de la Literatura ha revelado un interés creciente y un avance significativo en la aplicación de técnicas de aprendizaje automático para la segmentación y análisis de imágenes DICOM en entornos clínicos, siendo la oncología, la neumología, la neurología y la cardiología las áreas médicas más investigadas.

Puede consultarse la hoja de cálculo utilizada para llevar a cabo la revisión de la literatura a través del siguiente enlace:

<https://zenodo.org/records/11550753>

3. Metodología

La metodología se estructura en varias secciones que cubren desde la implementación de la interfaz web hasta los procedimientos de conexión con el servidor PACS y el entrenamiento y reentrenamiento de la red neuronal UNET.

3.1 Desarrollo Web

Para la implementación de la página web se ha utilizado un framework para el desarrollo de aplicaciones web en Python: *Django* [12]. Este framework de alto nivel facilita la creación de sitios web seguros y mantenibles mediante su arquitectura basada en el modelo-vista-controlador (MVC) [13]. Además, este proporciona una fácil compatibilidad con los algoritmos de Python, lo que permite integrar de manera efectiva los modelos de inteligencia artificial y las técnicas de procesamiento de imágenes utilizados en este proyecto.

La estructura de la aplicación web incluye varias vistas principales:

- **Vista de Acceso:** permite a los usuarios autenticarse en el sistema mediante un formulario de inicio de sesión seguro. La autenticación se maneja utilizando el sistema de autenticación de Django, que incluye funcionalidades para la gestión de usuarios y sesiones.
- **Vista de Consulta:** una vez autenticados, los médicos pueden acceder a esta vista para consultar el historial clínico de los pacientes. La búsqueda se puede realizar mediante el número de historial clínico, y se muestran también los pacientes citados para el día, ordenados por hora de consulta.
- **Vista de Detalle del Paciente:** al seleccionar un paciente, se redirige a esta vista donde se muestran todos los datos relevantes del paciente, incluyendo información acerca de la persona alternativa de contacto. También se listan todos los estudios DICOM asociados al paciente, ordenados por fecha y número de serie.
- **Vista de Estudios:** al seleccionar un estudio específico, se accede a esta vista donde se presentan los principales datos del paciente y del estudio en cuestión. En ella se muestran dos versiones de la imagen DICOM: la original y la procesada por la red UNET. La vista permite la anotación interactiva sobre ambas imágenes, facilitando así la tarea de segmentación por parte del médico. La interfaz también soporta la visualización y anotación de imágenes multidicom.

Además de estas vistas principales, se han desarrollado vistas básicas que se encuentran en cualquier plataforma web, como son el registro, recuperación de contraseña y modificación de datos personales, entre otras. También se ha añadido una ventana específica para la incorporación de nuevos algoritmos, permitiendo así la segmentación de otros tipos de imágenes o estudios, ampliando las capacidades y la flexibilidad del sistema.

Para la visualización y anotación de las imágenes DICOM se ha integrado el framework especializado en la visualización de imágenes médicas *Cornerstone* [14]. Este framework permite la visualización interactiva de imágenes DICOM, así como la anotación y manipulación de las mismas. No obstante, trabajar con este framework ha presentado grandes desafíos debido a la escasa y compleja documentación, así como a las incompatibilidades entre sus versiones.

La página web ha sido diseñada para ser intuitiva y fácil de utilizar, asegurando que los médicos puedan acceder rápidamente a la información relevante y realizar anotaciones de manera eficiente. La interfaz ha sido desarrollada utilizando HTML, CSS y JavaScript para asegurar una experiencia de usuario fluida y responsiva. El propio framework de *Django* es capaz de manejar el backend de la aplicación, gestionando las peticiones y sirviendo los datos necesarios para cada vista.

3.2 Procesamiento de Imágenes DICOM

Para incorporar el sistema desarrollado al sistema médico se ha desarrollado un PACS Server (*Picture Archiving and Communication System Server*) con el fin de gestionar y almacenar imágenes médicas de manera eficiente y segura. El PACS Server actúa como un receptor centralizado de imágenes DICOM, permitiendo su acceso y gestión desde diferentes estaciones de trabajo.

Para simular el entorno clínico real, se ha creado un script de envío que emula las señales generadas por los equipos médicos al realizar un estudio (captura de imágenes), ya que no ha sido posible tener acceso al entorno de despliegue real durante la etapa de desarrollo.

El flujo de comunicación DICOM desde que una máquina solicita guardar una imagen hasta que el PACS Server la recibe implica varios pasos esenciales, siendo este representado en la Fig. 5:

- **Establecimiento de la Asociación:** el dispositivo médico envía una solicitud de asociación (A-ASSOCIATE-RQ) al PACS Server, que responde con aceptación (A-ASSOCIATE-AC) si todo es compatible, o con rechazo (A-ASSOCIATE-RJ) si hay algún problema.
- **Transferencia de Datos:** con la asociación establecida, el dispositivo médico envía la imagen DICOM al PACS Server utilizando una solicitud de almacenamiento (C-STORE-RQ). El PACS Server recibe la solicitud, almacena la imagen y envía una respuesta de almacenamiento (C-STORE-RSP).
- **Verificación de Conectividad:** el dispositivo médico puede enviar una solicitud de verificación (C-ECHO-RQ) para asegurarse de la disponibilidad del PACS Server, que responde con (C-ECHO-RSP).
- **Finalización de la Asociación:** una vez completada la transferencia de imágenes, el dispositivo médico envía una solicitud para liberar la asociación (A-RELEASE-RQ) y el PACS Server responde confirmando la liberación (A-RELEASE-RP).




Figura 5: Flujo de comunicación del servidor PACS

Una vez recibida la señal de almacenamiento, se procesa la imagen, obteniendo así la segmentación predicha, como muestra la Fig. 6.

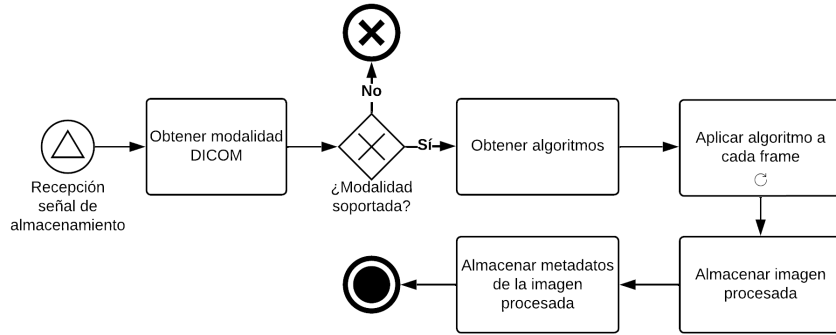


Figura 6: Flujo de procesamiento de imágenes DICOM

3.3 Configuración de la Red Neuronal

El objetivo principal de la red neuronal es segmentar el ventrículo izquierdo, la aurícula izquierda y el miocardio en ultrasonidos cardiorácicos de dos y cuatro cámaras (ecocardiografías). Para esta tarea, se ha elegido la arquitectura UNET debido a su capacidad comprobada para realizar segmentaciones precisas en imágenes biomédicas. La UNET es capaz de identificar patrones complejos como bordes, segmentos circulares y texturas, lo que la hace particularmente adecuada para la segmentación de estructuras anatómicas en imágenes médicas. La Fig. 7 muestra un ejemplo de arquitectura para este tipo de redes.




Figura 7: Ejemplo de arquitectura de una red neuronal U-NET [5]

El entrenamiento inicial de la red se realizó utilizando las imágenes de la base de datos CAMUS [15], la cual se centra en el uso de técnicas de aprendizaje profundo para la segmentación de ultrasonidos cardiotorácicos (ecocardiografías) en 2D.

Para cuantificar el ajuste de la predicción generada por la red a la segmentación dada como *ground truth*, se pueden utilizar varias métricas. Entre las más comunes están la precisión, el *recall*, la F1-score y el coeficiente de Dice. En este proyecto, se ha optado por utilizar el coeficiente de Dice como métrica principal, ya que es especialmente útil en problemas de segmentación de imágenes. Esta métrica cuantifica la superposición entre la segmentación predicha y la real, proporcionando una evaluación clara y directa de la calidad de la segmentación.

Además, para obtener el mejor funcionamiento de la red, es necesario seleccionar un algoritmo optimizador óptimo. Entre los algoritmos optimizadores más comunes se encuentran el Gradiente Descendente Estocástico (SGD), RMSprop y Adam, siendo este último el optimizador seleccionado para este proyecto debido a su robustez, eficiencia y adaptabilidad.

3.4 Reentrenamiento

El reentrenamiento de la red neuronal es una fase crucial en el desarrollo del sistema, ya que permite ajustar y mejorar el modelo en función de nuevas anotaciones realizadas por los médicos. La red debe ser capaz de aprender utilizando las imágenes y las anotaciones proporcionadas por los médicos como *ground truth*, como se muestra en la Fig. 8. Este proceso de aprendizaje continuo asegura que el modelo se mantenga actualizado y optimizado para las necesidades específicas del entorno clínico.

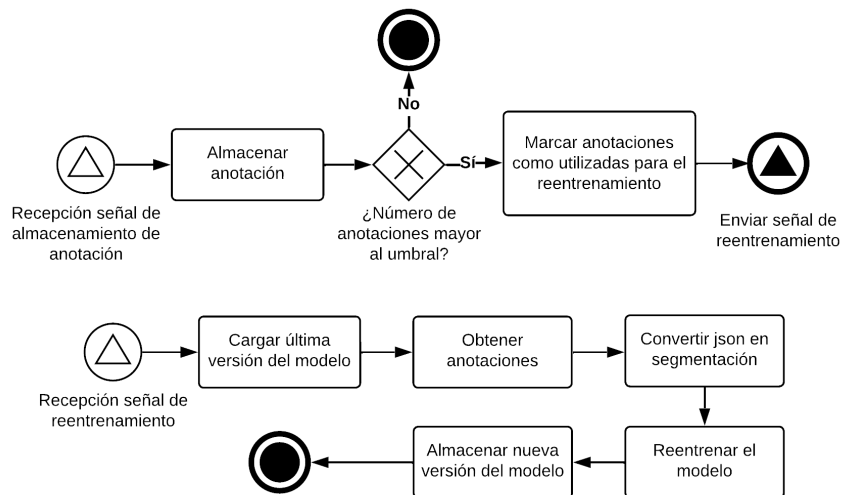


Figura 8: Flujo de ejecución del reentrenamiento

Para evaluar el rendimiento y la adaptabilidad del modelo UNET a nuevas anotaciones, se plantearon tres experimentos de reentrenamiento. Cada experimento utilizó diferentes proporciones de datos originales y nuevas anotaciones para mejorar la capacidad de generalización del modelo.

- **Primer experimento:** Consiste en reentrenar el modelo únicamente con 25 anotaciones realizadas sobre una misma imagen. El objetivo de este experimento es observar cómo el modelo se ajusta a un pequeño conjunto de datos altamente específicos y evaluar el riesgo de sobreajuste.
- **Segundo experimento:** En este experimento, se reentrena el modelo utilizando las 25 anotaciones mencionadas anteriormente junto con un número igual de imágenes del dataset original de entrenamiento. Esto pretende verificar si la inclusión de datos originales ayuda a mantener el conocimiento previo del modelo mientras se integra nueva información.
- **Tercer experimento:** Similar al segundo experimento, pero en este caso se utilizan el doble de anotaciones junto con las imágenes originales del dataset de entrenamiento. Este experimento busca evaluar si un mayor número de anotaciones mejora la precisión sin comprometer el conocimiento previo del modelo.

4. Resultados

Esta sección presenta los resultados obtenidos de la implementación del sistema, siguiendo la estructura de la metodología.

4.1 Desarrollo Web


La plataforma web realizada ha sido nombrada como «dAIcom », y su icono se muestra en la Fig. 9.



Figura 9: Icono de la aplicación web «dAIcom »

La implementación de la página web mediante Django resultó en una interfaz intuitiva y fácil de usar, permitiendo a los médicos acceder rápidamente a la información relevante y realizar anotaciones de manera eficiente. La vista de acceso permite la autenticación segura de los usuarios en el sistema (Fig. 10).

dAlcom Crea una cuenta


 dAlcom

User

Password

Entrar

[Crea una cuenta](#)
[¿Ovidaste tu contraseña?](#)

Figura 10: Interfaz de acceso

Una vez autenticados, los médicos pueden acceder a esta vista para consultar el historial clínico de los pacientes. La búsqueda se puede realizar de forma global introduciendo el número de historial clínico en la barra de búsqueda principal. En esta interfaz se muestran también los pacientes citados para el día, ordenados por hora de consulta, como se muestra en la Fig. 11.

dAlcom Área de Consulta Dr. Pablo Santos Blázquez

Buscador general:

Pacientes citados hoy para consulta:

Mostrar entradas Buscar

Fecha y hora	Número de historial clínico	Nombre	Especialidad	Descripción
23/06/2024 - 10:00	1666666	Anon Imo	Cardiología	Ultrasonido cardiorácico de cuatro cámaras
23/06/2024 - 10:30	1666667	Ann Onymous	Cardiología	Estudio por arritmia

Mostrando 1 a 2 de 2 entradas Anterior Siguiente

Figura 11: Interfaz de consulta

Al seleccionar un paciente, se redirige a esta vista donde, como muestra la Fig. 12, se describen todos los datos relevantes del paciente, incluyendo información acerca de la persona alternativa de contacto. También se listan todos los estudios DICOM asociados al paciente, ordenados por fecha y número de serie, permitiendo así el acceso a su visualización.

The screenshot displays the 'Historial Clínico del Paciente' interface. At the top, it shows the user 'Dr. Pablo Santos Blázquez'. The patient's clinical history number is '166666'. The patient's details include: Name 'Anon Ima', Date of Birth '05/06/1924', Sex 'Hombre', Birth Country 'España', Residence 'Salamanca', and Contact Phone '600000000'. The contact person is 'Anon Ima', Mother, with the same phone number. Below this, there is a section for 'Estudios DICOM del paciente' with a search bar and a table of studies.

Fecha y hora	Número de Serie	Número de instancia	Modalidad	Descripción
05/06/2024 - 18:16	1	1	US	Ultrasound Image
05/06/2024 - 18:16	1	43	US	Ultrasound Image
05/06/2024 - 18:16	1	49	US	Ultrasound Image

At the bottom of the table, it indicates 'Mostrando 1 a 3 de 3 entradas' and navigation buttons for 'Anterior' and 'Siguiente'.

Figura 12: Interfaz de detalle del paciente

Una vez seleccionado un estudio, se accede a esta vista, representada en la Fig. 13, donde se presentan los principales datos del paciente y del estudio en cuestión. Aquí se muestran dos versiones de la imagen DICOM: la original y la procesada por la red UNET. La vista permite la anotación interactiva sobre ambas imágenes, facilitando así la tarea de segmentación por parte del médico, permitiendo también la visualización y anotación de imágenes multidicom, recorriendo las distintas imágenes mediante el uso de un slider. En la parte derecha de la pantalla se muestran las anotaciones tomadas sobre dicha imagen.

Durante el proceso de anotación se permite al especialista médico interactuar mediante el uso de distintas herramientas:

- **Guardar anotación:** Este botón permite almacenar las modificaciones realizadas por el médico junto con una descripción de la misma.
- **Activar/desactivar brocha:** Este botón permite conmutar entre el estado activo e inactivo de la brocha. Por defecto, la brocha está en estado inactivo.
- **Tamaño de la brocha:** Este campo de numeración permite cambiar el tamaño de la brocha desde un tamaño mínimo de 1 píxel hasta un máximo de 150.
- **Selector de segmentación:** Este desplegable muestra las distintas capas de segmentación y sus colores correspondientes. Permite seleccionar la capa de segmentación sobre la que se trabaja.




Figura 13: Vista de los estudios DICOM

- **Ver/ocultar la segmentación:** Este botón permite conmutar entre el estado visible y oculto de la segmentación. Por defecto, la segmentación está en estado visible.
- **Volver al estado inicial:** Este botón permite volver a cargar el estado de segmentación inicial, descartando todas las modificaciones realizadas.

4.2 Procesamiento de Imágenes DICOM

El desarrollo del PACS Server permitió la gestión y almacenamiento eficiente de las imágenes médicas. El flujo de comunicación DICOM se implementó de manera efectiva, asegurando que las imágenes fueran transferidas y almacenadas correctamente.

El PACS Server se probó con éxito mediante un script de envío que emulaba las señales generadas por los equipos médicos.

4.3 Configuración de la Red Neuronal

A continuación, se expone la configuración de la red neuronal utilizada en el proyecto, describiendo tanto la métrica de evaluación seleccionada como la estructura específica de la red UNET implementada. Además, se justifica la elección de la «Generalized Dice Loss (GDL)» como función de pérdida para este modelo.

4.3.1 Función de Evaluación: Dice Coefficient El coeficiente de Dice es una métrica utilizada para evaluar la similitud entre dos conjuntos. Es particularmente útil en problemas de segmentación de imágenes, donde se compara el conjunto que forma la máscara de la segmentación predicha con el conjunto de la máscara de la segmentación real (ground truth). La fórmula del coeficiente de Dice es la siguiente:

$$\text{Dice} = \frac{2 \times |X \cap Y|}{|X| + |Y|}$$

donde X es el conjunto de píxeles predichos e Y es el conjunto de píxeles correspondientes a la segmentación realizada por los especialistas médicos (ground truth). El valor del coeficiente de Dice varía entre 0 y 1, donde 1 indica una concordancia perfecta.

4.3.2 Arquitectura de la Red: UNET A continuación, se describe la estructura de la UNET utilizada en este proyecto:

- **Entrada:** La red acepta imágenes de tamaño 384x384 píxeles. Antes de ser ingresadas a la red, las imágenes deben ser redimensionadas a este tamaño.
- **Capas de contracción (encoder):** La fase de contracción consta de varias capas convolucionales seguidas de operaciones de pooling. Estas capas extraen características importantes y reducen la dimensionalidad espacial de las imágenes.
 - **Capa 1:** Conv2D(10 filtros, 3x3) seguida de Conv2D (10 filtros, 3x3) y BatchNormalization.
 - **Capa 2:** MaxPooling2D seguida de Conv2D (20 filtros, 3x3) y Conv2D (20 filtros, 3x3) y BatchNormalization.
 - **Capa 3:** MaxPooling2D seguida de Conv2D (40 filtros, 3x3) y Conv2D (40 filtros, 3x3) y BatchNormalization.
 - **Capa 4:** MaxPooling2D seguida de Conv2D (80 filtros, 3x3) y Conv2D (80 filtros, 3x3) y BatchNormalization.
 - **Capa 5:** MaxPooling2D seguida de Conv2D(160 filtros, 3x3) y Conv2D (160 filtros, 3x3) y BatchNormalization.
 - **Capa 6:** MaxPooling2D seguida de Conv2D(320 filtros, 3x3) y Conv2D (320 filtros, 3x3) y BatchNormalization.
- **Capas de expansión (decoder):** La fase de expansión consiste en capas de upsampling seguidas de convoluciones. Estas capas aumentan la dimensionalidad espacial y combinan la información de características extraídas en la fase de contracción.
 - **Capa 1:** UpSampling2D seguida de Concatenate, Conv2D(160 filtros, 3x3), Conv2D(160 filtros, 3x3) y BatchNormalization.
 - **Capa 2:** UpSampling2D seguida de Concatenate, Conv2D(80 filtros, 3x3), Conv2D(80 filtros, 3x3) y BatchNormalization.
 - **Capa 3:** UpSampling2D seguida de Concatenate, Conv2D(40 filtros, 3x3), Conv2D(40 filtros, 3x3) y BatchNormalization.
 - **Capa 4:** UpSampling2D seguida de Concatenate, Conv2D(20 filtros, 3x3), Conv2D(20 filtros, 3x3) y BatchNormalization.
 - **Capa 5:** UpSampling2D seguida de Concatenate, Conv2D(10 filtros, 3x3), Conv2D(10 filtros, 3x3) y BatchNormalization.
- **Conexiones de Skip:** Las conexiones de skip entre las capas de contracción y expansión permiten la transferencia de características de alta resolución, mejorando la precisión de la segmentación.
- **Salida:** La capa de salida aplica una convolución final para mapear las características aprendidas a la máscara de segmentación deseada. Conv2D(4 filtros, 1x1).

4.3.3 Preprocesamiento de las Imágenes Para que las imágenes puedan ser segmentadas correctamente por la red UNET, deben ser preprocesadas de la siguiente manera:

- **Redimensionado:** para encajar con la estructura requerida por la entrada de la red neuronal, las imágenes de entrada deben ser redimensionadas a 384x384 píxeles.
- **Normalización:** los valores de los píxeles deben ser normalizados para mejorar la convergencia del entrenamiento.

4.3.4 Pérdida de Dice Generalizada La función de pérdida utilizada en este proyecto es la Generalized Dice Loss en lugar de la tradicional Dice Loss. La elección de la Generalized Dice Loss se debe a que la función argmax, utilizada en la segmentación, no es continua y, por lo tanto, no es adecuada para el entrenamiento con retropropagación. La Generalized Dice Loss es una versión diferenciable del coeficiente de Dice, lo que permite su uso en el entrenamiento de redes neuronales.

$$\text{GDL} = 1 - \frac{2 \sum w_c \sum x_c y_c}{\sum w_c (\sum x_c + \sum y_c)}$$

donde x_c y y_c son las predicciones y las etiquetas para la clase c , y w_c es un peso que ajusta la contribución de cada clase en función del tamaño relativo de la clase.

4.4 Reentrenamiento

Cada una de las Figuras de los experimentos representan una imagen DICOM distinta, catalogadas como 'E', 'F' y 'G'. Estas imágenes son mostradas en formato original y con la segmentación predicha por la versión del modelo original en la Fig. 14.




Figura 14: Predicciones del modelo original

El lote de 25 anotaciones con el cual se han realizado los experimentos se corresponde a la imagen DICOM 'G', por lo que las imágenes 'E' y 'F' nunca han sido utilizadas

para el entrenamiento o reentrenamiento, es por esto que conforman el set de validación. La Fig. 15 muestra la anotación con la que se han realizado los diferentes experimentos:




Figura 15: Anotación con la que se han realizado los diferentes experimentos

Como se puede observar en la Fig. 15, se ha modificado la segmentación para que el ventrículo izquierdo (segmento rojo) sea ligeramente más grande, la aurícula derecha (segmento morado) sea también más grande y se ajuste a la forma real de la misma, haciendo que su forma sea menos circular y para que el miocardio (segmento verde) sea notablemente más estrecho. Estas anotaciones se almacenan en formato json, formato que posteriormente se adapta para coincidir con la entrada de las herramientas de Cornerstone que generan la segmentación.

Para cada uno de los experimentos se han obtenido tres figuras (como las mostradas en las Figs. 16, 17 y 18, correspondientes al experimento 2), cada una correspondiente a una de las imágenes. Estas figuras representan cuatro segmentaciones independientes que muestran las predicciones realizadas por el sistema tras realizar el reentrenamiento con distintos valores de «batch size» y «epochs». Cada una de las imágenes segmentadas obtenidas con cada configuración muestra el valor final de reentrenamiento caracterizado por la métrica «multiclass_dice».

Los experimentos de reentrenamiento realizados demostraron la efectividad de incluir nuevas anotaciones para mejorar la capacidad de generalización del modelo UNET:

- **Experimento 1:** Utilizó un conjunto de datos limitado, revelando problemas de sobreajuste. Las predicciones para las imágenes 'E', 'F' y 'G' mostraron discrepancias significativas respecto a las segmentaciones reales.
- **Experimento 2:** Incorporó un mayor número de imágenes del conjunto de datos original junto con nuevas anotaciones, mejorando la generalización del modelo. Las predicciones para las imágenes 'E', 'F' y 'G' fueron más precisas.
- **Experimento 3:** Con una proporción de 2:1 de imágenes del conjunto de datos original respecto a las anotaciones, se logró una adaptación equilibrada, reduciendo significativamente el sobreajuste. Las predicciones para las imágenes 'E', 'F' y 'G' mostraron una alta concordancia con las segmentaciones reales.




Figura 16: Predicciones obtenidas para la imagen 'E' en el experimento 2




Figura 17: Predicciones obtenidas para la imagen 'F' en el experimento 2




Figura 18: Predicciones obtenidas para la imagen 'G' en el experimento 2

5. Discusión

La arquitectura UNET ha demostrado ser muy efectiva en tareas de segmentación de imágenes médicas debido a su capacidad para capturar tanto características locales como globales de las imágenes. En este estudio, los resultados han mostrado una alta precisión en la segmentación de estructuras cardíacas específicas, con valores del coeficiente Dice cercanos a 1.0 en muchos casos. Más de ochenta estudios previos identificados durante la etapa de mapeo también han utilizado la arquitectura UNET y sus variantes para la segmentación de imágenes de resonancia magnética y tomografía computarizada, logrando resultados similares en términos de precisión y capacidad de generalización. Nuestros resultados son consistentes con estos estudios y confirman la robustez de la arquitectura UNET para la segmentación de imágenes de ultrasonido cardíaco.

Los tres experimentos realizados en este estudio han sido fundamentales para entender la influencia de diferentes configuraciones de datos de entrenamiento y parámetros en la precisión del modelo. El experimento 1 ha mostrado una precisión excesivamente alta y un claro caso de sobreajuste. El experimento 2 mejoró la capacidad de generalización del modelo y mostró valores de precisión más realistas. El experimento 3 logró una adaptación equilibrada, reduciendo significativamente el sobreajuste. Estos experimentos demostraron que la adición de imágenes del dataset original permite una mejor adaptación del modelo a nuevas anotaciones.

El reentrenamiento del modelo con diferentes configuraciones de batch size y epochs mostró que estos hiperparámetros tienen una influencia significativa en la precisión de la segmentación. Un batch size más grande permite al modelo aprender patrones más robustos y estabilizar el proceso de entrenamiento, aunque también incrementa el riesgo de sobreajuste si no se maneja adecuadamente. Un mayor número de epochs permite al modelo ajustarse mejor a los datos de entrenamiento, pero también introduce el riesgo de sobreajuste. Los resultados obtenidos demuestran que el reentrenamiento de la red UNET con anotaciones adicionales y un mayor número de imágenes del dataset original mejora significativamente la precisión de la segmentación.

Estos hallazgos subrayan la importancia de utilizar conjuntos de datos variados y configuraciones de entrenamiento adecuadas para desarrollar modelos de segmentación robustos y precisos. La elección de la forma de reentrenamiento deberá decidirse cuando el proyecto entre en fase de producción, dependiendo de la valoración de los especialistas médicos sobre la segmentación inicial. Si la segmentación inicial es poco precisa, se requerirá un entrenamiento más rápido y se implementará la estrategia del experimento 2; si es bastante precisa, se implementará la estrategia del experimento 3.

6. Conclusiones

El proyecto "dAIcom" ha demostrado ser exitoso en el desarrollo de una plataforma web interactiva para la visualización, anotación y análisis de imágenes DICOM, mejorando la colaboración multidisciplinaria y la retroalimentación médica. La implementación de la interfaz web utilizando el framework *Django* ha proporcionado una herramienta intuitiva y eficiente para los profesionales de la salud, permitiéndoles acceder rápidamente a la información relevante y realizar anotaciones precisas.

La integración del modelo UNET específicamente entrenado para la segmentación de imágenes cardíacas ha sido un componente clave del proyecto. Los resultados obtenidos mostraron una alta precisión en la segmentación del ventrículo izquierdo, la aurícula izquierda y el miocardio, lo cual es crucial para el diagnóstico y tratamiento de enfermedades cardíacas. Los experimentos de reentrenamiento realizados confirmaron que la inclusión de nuevas anotaciones junto con un mayor número de imágenes del dataset original mejora la capacidad de generalización del modelo, reduciendo significativamente el sobreajuste.

El desarrollo del PACS Server permitió la gestión y almacenamiento eficiente de imágenes médicas, asegurando la integridad y disponibilidad de los datos DICOM. La implementación del flujo de comunicación DICOM fue efectiva, garantizando que las imágenes fueran transferidas y almacenadas correctamente desde los dispositivos médicos hasta el servidor PACS.

En términos de limitaciones, se identificaron varios desafíos. La falta de acceso a un entorno clínico real para probar la plataforma limitó la capacidad de evaluar su rendimiento en condiciones reales. Además, trabajar con *Cornerstone* fue extremadamente complicado, debido a su documentación limitada y problemas de compatibilidad entre versiones. Futuras versiones del proyecto deberían considerar la integración de otros frameworks de visualización y una validación más exhaustiva en entornos clínicos.

En cuanto a las líneas futuras, se sugiere explorar la integración de otros modelos de inteligencia artificial y frameworks de visualización que puedan complementar y mejorar las capacidades actuales de la plataforma. Además, una validación más exhaustiva en entornos clínicos reales será fundamental para asegurar que "dAIcom" pueda cumplir con los requisitos y expectativas de los profesionales de la salud en la práctica diaria.

Continuar mejorando la precisión y robustez del modelo mediante el uso de conjuntos de datos más variados y técnicas avanzadas de reentrenamiento será esencial para el éxito continuo del proyecto.

Para futuras investigaciones, es esencial ampliar el dataset con datos más variados, estudiar configuraciones de hiperparámetros y desarrollar métodos automáticos para su ajuste óptimo. Las líneas más prometedoras sugieren la implementación de una funcionalidad capaz de realizar comparaciones entre las distintas versiones almacenadas del modelo y la obtención de métricas adicionales como el volumen de la aurícula y el ventrículo. Otras posibles líneas podrían integrar herramientas de análisis estadístico mejorará aún más el sistema o funcionalidades de personalización y un sistema de notificaciones y alertas para mantener a los médicos informados y comprometidos con la mejora continua del sistema.

Referencias

1. R. Najjar, "Redefining radiology: A review of artificial intelligence integration in medical imaging," *Diagnostics*, vol. 13, no. 17, p. 2760, 2023.
2. L. Pinto-Coelho, "How artificial intelligence is shaping medical imaging technology: A survey of innovations and applications," *Bioengineering*, vol. 10, no. 12, p. 1435, 2023.
3. F. J. García-Peñalvo, A. Vázquez-Ingelmo, A. García-Holgado, J. Sampedro Gómez, A. Sánchez-Puente, V. Vicente-Palacios, P. I. Dorado-Díaz, and P. L. Sánchez, "Cartier-ia: An overview of ai research applied to health," *International Journal of Interactive Multimedia and Artificial Intelligence*, vol. 6, no. 7, pp. 112–119, 2021.
4. P. Mildenerger, M. Eichelberg, and E. Martin, "Introduction to the dicom standard," *European Radiology*, vol. 12, no. 4, pp. 920–927, 2002.
5. O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, pp. 234–241, Springer, 2015.
6. M. J. Page, J. E. McKenzie, P. M. Bossuyt, I. Boutron, T. C. Hoffmann, C. D. Mulrow, and D. Moher, "The prisma 2020 statement: an updated guideline for reporting systematic reviews," *BMJ*, vol. 372, p. n71, 2021.
7. F. J. García-Peñalvo, "Desarrollo de estados de la cuestión robustos: Revisiones sistemáticas de literatura," *Education in the knowledge society*, vol. 23, 2022.
8. W. of Science, "Web of science." <https://www.webofscience.com/>. Accessed: 08-06-2024.
9. I. Xplore, "Ieee xplore." <https://ieeexplore.ieee.org/Xplore/>. Accessed: 08-06-2024.
10. Scopus, "Scopus." <https://www.scopus.com/>. Accessed: 08-06-2024.
11. PubMed, "Pubmed." <https://pubmed.ncbi.nlm.nih.gov/>. Accessed: 08-06-2024.
12. Django Software Foundation, "Django: The web framework for perfectionists with deadlines," 2021.
13. T. Reenskaug, "Model-view-controller (mvc) design pattern," 2020.
14. Cornerstone Project, "Cornerstone: Open source web-based dicom viewer," 2016.
15. S. Leclerc, E. Smistad, J. Pedrosa, A. Østvik, F. Cervenansky, F. Espinosa, R. Larrabal, *et al.*, "The camus dataset: cardiac acquired ultrasound from the medical university of south carolina," *Data in brief*, vol. 20, pp. 384–388, 2018.