

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INFORMÁTICA
SANTIAGO - CHILE



“SUPERRESOLUCIÓN Y ALINEAMIENTO DE IMÁGENES
DE EJE CORTO DEL CORAZÓN OBTENIDAS POR
RESONANCIA MAGNÉTICA CARDIOVASCULAR”

DANIEL ALEJANDRO MARTÍNEZ CASTRO

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL EN INFORMÁTICA

Profesor Guía: Julio Sotelo
Profesor Correferente: Carolina Saavedra

Junio - 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título; ☐ Tesis de Postgrado;

Título del trabajo: Superresolución y alineamiento de imágenes de eje corto del corazón obtenidas por resonancia magnética cardiovascular

Nombre del candidato(a): Daniel Alejandro Martínez Castro

Carrera / Grado: Ingeniería Civil Informática

Campus: Santiago San Joaquín ; **Departamento:** Departamento de Informática

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Julio Sotelo Parraguez, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

☒ El trabajo **NO contiene información que amerite confidencialidad** y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por:

☐ 6 meses; ☐ 12 meses; ☐ 2 años; ☐ 3 años; ☐ 5 años; ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 31/07/2025

; Firma:

Estudiante o Candidato(a):

Fecha: 30/07/2025

; Firma:

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

DEDICATORIA

A mi madre, Cecilia, quien me apoyó incondicionalmente durante estos años de carrera. A mi tío Domingo y a mi tía Patricia, por su constante cariño, palabras de aliento y apoyo en los momentos que más lo necesité. A mis abuelos, Domingo y Bladimira, por su amor y por cuidarme con dedicación durante mi infancia.

AGRADECIMIENTOS

A mi profesor guía, Julio Sotelo, gracias por el apoyo y la orientación brindada durante el desarrollo de esta memoria. A la profesora Claudia López, por proporcionar imágenes médicas de gran utilidad.

RESUMEN

Resumen— En este trabajo se propone un enfoque para mejorar la calidad de imágenes de resonancia magnética cardiovascular (CMR) de eje corto mediante dos soluciones principales. Primero, se desarrollan y comparan métodos de alineación basados en procesamiento de imágenes, con el objetivo de corregir la desalineación entre cortes transversales. Segundo, se implementa un modelo de superresolución basado en aprendizaje profundo, específicamente una red neuronal convolucional inspirada en U-Net, para generar cortes intermedios y aumentar la resolución volumétrica de las imágenes. La metodología fue evaluada utilizando el M&M *dataset* y un conjunto de datos adicional, obteniendo resultados que demuestran mejoras en la coherencia anatómica y la calidad visual de los volúmenes reconstruidos. Estas soluciones facilitan el análisis clínico y automatizado de estudios CMR, reduciendo la necesidad de correcciones manuales y mejorando la fidelidad estructural de las imágenes.

Palabras Clave— Procesamiento de imágenes, Aprendizaje profundo, Resonancia magnética cardiovascular, Enfermedades cardiovasculares, Alineación.

ABSTRACT

Abstract— This work proposes an approach to enhance the quality of short-axis cardiac magnetic resonance (CMR) images through two main solutions. First, several alignment methods based on image processing techniques are developed and compared to correct misalignment between transverse slices. Second, a deep learning-based super-resolution model, specifically a convolutional neural network inspired by U-Net, is implemented to generate intermediate slices and increase volumetric resolution. The methodology was evaluated using the M&M dataset and an additional dataset, showing improvements in anatomical coherence and visual quality of the reconstructed volumes. These solutions facilitate both clinical and automated CMR analysis by reducing the need for manual corrections and improving structural fidelity.

Keywords— Image processing, Deep learning, Cardiovascular magnetic resonance, Cardiovascular diseases, Alignment.

GLOSARIO

AHS: *Athlete's Heart Syndrome* / Síndrome de Corazón de Atleta.

ARV: *Arrhythmogenic Right Ventricular Cardiomyopathy* / Miocardiopatía Ventricular Derecha Arritmogénica.

bSSFP: *Balanced Steady-State Free Precession* / Precesión de Estado Estacionario Balanceado.

CMR: *Cardiovascular Magnetic Resonance* / Resonancia Magnética Cardiovascular.

CNN: *Convolutional Neural Network* / Red Neuronal Convolutacional.

CT: *Computed Tomography* / Tomografía Computarizada.

CVD: *Cardiovascular Disease* / Enfermedad Cardiovascular.

DCM: *Dilated Cardiomyopathy* / Miocardiopatía Dilatada.

DL: *Deep Learning* / Aprendizaje Profundo.

ED: *End Diastole* / Fin de la Diástole.

EDV: *End-Diastolic Volume* / Volumen Telediastólico.

EF: *Ejection Fraction* / Fracción de Eyección.

EIC: *Ischemic Heart Disease* / Enfermedad Isquémica del Corazón.

EKG: *Electrocardiogram* / Electrocardiograma.

ES: *End Systole* / Fin de la Sístole.

ESV: *End-Systolic Volume* / Volumen Telesistólico.

FCNN: *Fully Convolutional Neural Network* / Red Neuronal Totalmente Convolutacional.

GAN: *Generative Adversarial Network* / Red Generativa Adversaria.

gICP: *Generalized Iterative Closest Point* / Punto Más Cercano Iterativo Generalizado.

GRE: *Gradient-Echo* / Eco de Gradiente.

GPU: *Graphics Processing Unit* / Unidad de Procesamiento Gráfico.

HCM: *Hypertrophic Cardiomyopathy* / Miocardiopatía Hipertrófica.

HHD: *Hypertensive Heart Disease* / Enfermedad Cardíaca Hipertensiva.

LPIPS: *Learned Perceptual Image Patch Similarity* / Similitud de Parches de Imagen Perceptual Aprendida.

LGE: *Late Gadolinium Enhancement* / Realce Tardío con Gadolinio.

LV: *Left Ventricle* / Ventrículo Izquierdo.

LVNC: *Left Ventricular Noncompaction* / No Compactación del Ventrículo Izquierdo.

MAP: *Maximum A Posteriori* / Máxima a Posteriori.

MRI: *Magnetic Resonance Imaging* / Resonancia Magnética.

MSE: *Mean Squared Error* / Error Cuadrático Medio.

Myo: *Myocardium* / Miocardio.

NOR: *Normal* / Normal.

PSNR: *Peak Signal-to-Noise Ratio* / Relación Señal-Ruido de Pico.

RF: *Radiofrequency* / Radiofrecuencia.

RV: *Right Ventricle* / Ventrículo Derecho.

SA: *Short Axis* / Eje Corto.

SE: *Spin-Echo* / Eco de Espín.

SSFP: *Steady-State Free Precession* / Precesión de Estado Estacionario.

SSIM: *Structural Similarity Index Measure* / Medida de Índice de Similitud Estructural.

SV: *Stroke Volume* / Volumen Sistólico.

UTFSM: Universidad Técnica Federico Santa María.

WHO: *World Health Organization* / Organización Mundial de la Salud.

ÍNDICE DE CONTENIDOS

RESUMEN	IV
ABSTRACT	IV
GLOSARIO	V
ÍNDICE DE FIGURAS	IX
ÍNDICE DE TABLAS	X
INTRODUCCIÓN	1
CAPÍTULO 1: DEFINICIÓN DEL PROBLEMA	2
1.1 Contexto del Problema	2
1.2 Árbol del Problema	4
1.3 Objetivos de Solución	5
1.3.1 Objetivo General	5
1.3.2 Objetivos Específicos	5
CAPÍTULO 2: MARCO CONCEPTUAL	6
2.1 Enfermedades Cardiovasculares (CVD)	6
2.2 Resonancia Magnética (MRI)	6
2.3 Resonancia Magnética Cardiovascular (CMR)	7
2.3.1 Técnicas de obtención de imágenes	8
2.4 Aprendizaje profundo para la segmentación de imágenes médicas y cardíacas	9
2.4.1 Fully Connected Networks	9
2.4.2 U-Net	9
2.4.3 nnU-Net	11
2.5 Alineación para resonancias magnéticas cardiovasculares	14
2.6 Evaluación de Alineación	14
2.7 Superresolución para resonancias magnéticas cardiovasculares	15
2.8 Evaluación de Superresolución	15
2.8.1 MSE	15
2.8.2 PSNR	16
2.8.3 SSIM	16
2.8.4 Volumen del ventrículo izquierdo	17
CAPÍTULO 3: PROPUESTA DE SOLUCIÓN	18
3.1 M&Ms Challenge Dataset	18
3.2 Dataset de Soporte	20
3.2.1 Preprocesamiento	21
3.3 Alineación	22
3.3.1 Obtención de vistas	22

3.3.2	Centro de Masa del Ventrículo Izquierdo	24
3.3.3	Correlación Cruzada	24
3.4	Superresolución	25
3.5	Arquitectura de la red	25
3.6	Entrenamiento	28
3.6.1	Procesamiento del conjunto de datos	28
3.6.2	Función de Perdida	30
3.6.3	Optimizador	31
3.6.4	Aumentación de datos	32
3.7	Flujo de datos final	32
CAPÍTULO 4: VALIDACIÓN DE LA SOLUCIÓN		34
4.1	Alineación	34
4.1.1	M&M dataset	34
4.1.2	Dataset de Soporte	38
4.2	Superresolución	39
4.2.1	Resumen Cuantitativo	40
4.2.2	M&M dataset	42
4.2.3	M&M dataset superresolución (sin <i>downsample</i>)	48
4.2.4	Dataset de Soporte (Grosor de corte transversal 4 mm)	53
4.2.5	Dataset de Soporte (Grosor de corte transversal 8 mm)	56
4.2.6	M&M dataset Alineado	59
CAPÍTULO 5: CONCLUSIONES		64
5.1	Conclusiones Generales	64
5.2	Limitaciones	64
5.3	Cumplimiento de Objetivos	66
5.3.1	Objetivos	66
5.4	Trabajo Futuro	67
REFERENCIAS BIBLIOGRÁFICAS		68

ÍNDICE DE FIGURAS

1	Ejemplo de Dataset con sus anotaciones.	2
2	Alineación de MRI cardiovascular usando Ventrículo Izquierdo.	3
3	Ejemplo de imágenes de resonancia magnética (MRI) en eje corto.	3
4	Árbol del Problema.	4
5	Arquitectura U-net.	10
6	Pipeline de nnU-Net y sus parámetros inferidos.	13
7	Apariencia Visual de cortes centrales de CMR para los cuatro proveedores de equipo del M&Ms dataset.	18
8	Distribución demográfica y patológica de los pacientes en el M&M dataset.	20
9	Ejemplo de CMR cargado en ParaView junto con la proyección del eje corto.	21
10	Ejemplo de volumen generado tras procesar imágenes del Dataset de Soporte, obteniendo un volumen de eje corto.	22
11	Ejemplo de extracción de las vistas horizontal y vertical en un CMR de eje corto.	23
12	Ejemplo de extracción de las vistas de cuatro cámaras en un CMR de eje corto.	24
13	Bloque convolucional básico (Conv Block).	26
14	Bloque residual usado en la arquitectura de la ResUnet (Res Block).	27
15	Arquitectura Res-Unet.	28
16	(a y c) Imágenes de entrada para el modelo. (b) Imagen objetivo del modelo.	29
17	Cálculo de la función de pérdida <i>Learned Perceptual Image Patch Similarity</i> (LPIPS).	30
18	Comparación de similitud entre observadores humanos y varios modelos computacionales para LPIPS	31
19	Evolución de la tasa de aprendizaje durante en entrenamiento.	32
20	Ejemplo de aumentación de datos.	32
21	Flujo de procesamiento propuesto para imágenes CMR de eje corto del M&M dataset.	33
22	Comparación de métodos de alineamiento para un caso Philips del M&M dataset.	35
23	Comparación de métodos de alineamiento para un caso General Electric del M&M dataset.	36
24	Comparación de métodos de alineamiento para un caso Canon del M&M dataset.	37
25	Comparación de métodos de alineamiento para un caso Siemens del M&M dataset.	37
26	Comparación de métodos de alineamiento para un caso del Dataset de Soporte	38
27	Ejemplo de reducción de cortes transversales.	39
28	Gráfico de Bland-Altman para superresolución del M&M dataset con reducción de cortes (ES)	43
29	Caso con menor diferencia en el volumen del LV para la superresolución en el M&M dataset, utilizando reducción de cortes transversales (ES)	44
30	Caso con mayor diferencia en el volumen del LV para la superresolución en el M&M dataset, utilizando reducción de cortes transversales (ES)	44

31	Gráfico de Bland-Altman para superresolución del M&M <i>dataset</i> con reducción de cortes (ED)	45
32	Caso con menor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> , utilizando reducción de cortes transversales (ED)	47
33	Caso con mayor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> , utilizando reducción de cortes transversales (ED)	47
34	Gráfico de Bland-Altman para superresolución del M&M <i>dataset</i> (ES)	48
35	Caso con menor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> (ES)	49
36	Caso con mayor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> (ES)	50
37	Gráfico de Bland-Altman para superresolución del M&M <i>dataset</i> (ED)	50
38	Caso con menor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> (ED)	52
39	Caso con mayor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> (ED)	52
40	Gráfico de Bland-Altman para superresolución del <i>dataset</i> de soporte (4 mm) utilizando reducción de cortes	54
41	Caso con menor diferencia en el volumen del LV para la superresolución en el <i>Dataset</i> de Soporte (4mm)	55
42	Caso con mayor diferencia en el volumen del LV para la superresolución en el <i>Dataset</i> de Soporte (4mm)	55
43	Gráfico de Bland-Altman para superresolución del <i>dataset</i> de soporte (8 mm) utilizando reducción de cortes	57
44	Caso con menor diferencia en el volumen del LV para la superresolución en el <i>Dataset</i> de Soporte (8mm)	58
45	Caso con mayor diferencia en el volumen del LV para la superresolución en el <i>Dataset</i> de Soporte (8mm)	58
46	Gráfico de Bland-Altman para superresolución del M&M <i>dataset</i> alineado con reducción de cortes (ES)	59
47	Caso con menor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> alineado, utilizando reducción de cortes transversales (ES)	60
48	Caso con mayor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> alineado, utilizando reducción de cortes transversales (ES)	61
49	Gráfico de Bland-Altman para superresolución del M&M <i>dataset</i> alineado con reducción de cortes (ED)	61
50	Caso con menor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> alineado, utilizando reducción de cortes transversales (ED)	63
51	Caso con mayor diferencia en el volumen del LV para la superresolución en el M&M <i>dataset</i> alineado, utilizando reducción de cortes transversales (ED)	63

ÍNDICE DE TABLAS

1	Número de pacientes para cada subconjunto de entrenamiento con la distribución de centros y equipamiento.	19
2	Partición de datos para superresolución.	29
3	Métricas cuantitativas (MSE, SSIM, PSNR) para cada uno de los conjuntos de datos utilizados en la evaluación.	40
4	Diferencias de volumen (ml) entre el volumen original y el volumen reconstruido o aumentado para el LV.	41
5	Resultados de las métricas cuantitativas en el M&M <i>dataset</i> realizando reducción de cortes transversales.	42
6	Resultados de las métricas cuantitativas en el <i>dataset</i> de soporte con grosor de corte transversal de 4mm realizando reducción de cortes transversales.	53
7	Resultados de las métricas cuantitativas en el <i>Dataset</i> de soporte con grosor de corte transversal de 8mm realizando reducción de cortes transversales.	56
8	Resultados de las métricas cuantitativas en el M&M <i>dataset</i> alineado realizando reducción de cortes transversales.	59

INTRODUCCIÓN

La Resonancia Magnética Cardiovascular (CMR) es uno de los principales métodos utilizados para la evaluación de la función cardiovascular. Este procedimiento cuenta con múltiples secuencias de adquisición, entre las cuales se encuentra la del eje corto, que consiste en cortes del ventrículo izquierdo desde la base hasta el ápex. Esta secuencia es particularmente útil para evaluar métricas como la fracción de eyección, el volumen sistólico y diastólico, así como la masa ventricular¹.

Como la adquisición de imágenes se realiza durante ciertos puntos del ciclo cardíaco, estas pueden presentar cierta desalineación debido al movimiento del paciente u otras causas [Chandler *et al.*, 2008]. Por otro lado, dado que el ciclo cardíaco se divide en múltiples fases, se dispone de una cantidad limitada de imágenes por fase, lo cual reduce la precisión en el cálculo de métricas clave para evaluar la función ventricular [Bogaert *et al.*, 2012].

Tanto el alineamiento como la superresolución presentan desafíos técnicos importantes, especialmente en contextos donde no se dispone de datos perfectamente registrados o de alta calidad. Desarrollar soluciones robustas ante estas limitaciones resulta clave para ampliar el uso de CMR en entornos clínicos reales y para mejorar la reproducibilidad de los análisis cuantitativos.

Los objetivos principales de esta memoria son desarrollar una técnica de alineamiento de CMR de eje corto y un modelo de superresolución de CMR para aumentar la cantidad de cortes transversales. Estas técnicas serán evaluadas posteriormente mediante diferentes métricas cuantitativas, así como también a través de un análisis cualitativo, según corresponda a cada caso. Para alcanzar estos objetivos, se utilizará el M&M *dataset*, el cual cuenta con 375 CMR de eje corto, junto con un conjunto de datos de soporte que se detallará en capítulos posteriores.

Este documento se organizará en cinco capítulos. En el Capítulo 1 se presentará una breve introducción al contexto del problema, junto con los objetivos de este trabajo. El Capítulo 2 abordará el marco conceptual, donde se detallarán los principales conceptos relevantes para la solución propuesta, además de una revisión del estado del arte de métodos previos y métricas utilizadas. En el Capítulo 3 se presentará la propuesta de solución, describiendo en detalle todas las metodologías empleadas. El Capítulo 4 estará dedicado a la evaluación de los métodos desarrollados, tanto de forma cualitativa como cuantitativa. Finalmente, en el Capítulo 5 se concluirá este trabajo, incluyendo una discusión de los resultados y una propuesta de líneas de trabajo futuras.

¹<https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri>

CAPÍTULO 1

DEFINICIÓN DEL PROBLEMA

1.1. Contexto del Problema

Las enfermedades cardiovasculares (CVD) son la principal causa de muerte mundialmente, se estima que 17.9 millones de personas murieron en 2019 de CVD, lo cual representa un 32 % de todas las muertes globales. De estas muertes, la mayoría fueron por derrame cerebrovascular y ataque al corazón ².

La resonancia magnética (MRI) es una técnica de diagnóstico por imágenes que utiliza campos magnéticos y ondas de radio para generar imágenes detalladas del interior del cuerpo humano ³. Esta es la principal forma de diagnóstico para afecciones cardíacas, realizándose múltiples mediciones como volumen cardíaco, masa cardíaca, grosor del miocardio (MYO), flujo sanguíneo, entre otros. En la figura 1 se observan ejemplos des MRI cardiovasculares durante distintas fases del ciclo cardíaco y sus segmentaciones.




Figura 1: Ejemplo de Dataset con sus anotaciones.

Fuente: [León *et al.*, 2023], [Campello *et al.*, 2021].

En MRI es común que ocurran desalineamientos entre los cortes transversales debido a que la toma de imágenes es realizada una a la vez a través de ciclo cardíaco, generando una pila

²[https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))

³<https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri>

de imágenes que cubren por completo el corazón [Chandler *et al.*, 2008]. En la Figura 2 se puede apreciar este desalineamiento versus a cómo debería estar estas imágenes después de una corrección.




Figura 2: Alineación de MRI cardiovascular usando Ventrículo Izquierdo.

Fuente: [Dangi *et al.*, 2018].

Por otro lado, también se puede notar que la limitada cantidad de cortes transversales realizados al corazón las cuales son alrededor de 10 y 13 con un grosor de aproximadamente 10 milímetros dependiendo del proveedor del escáner y el modelo en específico, lo cual afecta directamente la calidad de las mediciones realizadas al corazón. En la Figura 3 se puede apreciar distintos cortes del corazón en un MRI de eje corto en una fase cardíaca.




Figura 3: Ejemplo de imágenes de resonancia magnética (MRI) en eje corto desde la base hasta el ápice cardíaco, capturadas en la fase de fin de diástole.

Fuente: Elaboración Propia.

Por todas estas razones, el procesamiento de imágenes procedentes de resonancias magnéticas cardiovasculares es un proceso que requiere una alta cantidad de tiempo (Entre 20 a 30 minutos en el caso de la segmentación [Grothues *et al.*, 2002]) y experiencia por parte del especialista médico. Además, es común que existan variaciones entre diferentes especialistas médicos.

1.2. Árbol del Problema

La Figura 4 presenta el árbol del problema, que incluye causas, el problema principal y sus efectos, así como el objetivo general y los objetivos específicos.




Figura 4: Árbol del Problema.
Fuente: Elaboración Propia.

1.3. Objetivos de Solución

1.3.1. Objetivo General

Implementar un algoritmo de alineamiento y superresolución de imágenes del corazón obtenidas con resonancia magnética cardiovascular, enfocado en imágenes de eje corto, con el propósito de mejorar la precisión diagnóstica en entornos clínicos.

1.3.2. Objetivos Específicos

1. Implementar uno o múltiples métodos para alinear imágenes de eje corto del corazón obtenidas en resonancias magnéticas cardiovasculares, permitiendo una mejor visualización de estructuras anatómicas y patológicas.
2. Implementar uno o múltiples algoritmos para aumentar la cantidad de imágenes transversales en resonancias magnéticas cardiovasculares.
3. Validar la precisión de los métodos de superresolución y alineamiento realizando pruebas experimentales para evaluar la precisión y la calidad de las imágenes generadas.

CAPÍTULO 2

MARCO CONCEPTUAL

A continuación, se introduce el marco teórico necesario para comprender el desarrollo de este trabajo. En primer lugar, se presentan las enfermedades cardiovasculares y su relevancia clínica. Luego, se describe el funcionamiento general de la resonancia magnética y su aplicación en el ámbito médico. Posteriormente, se profundiza en la resonancia magnética cardiovascular (CMR), destacando su utilidad en la evaluación anatómica y funcional del corazón, así como sus principales modalidades de adquisición. Seguidamente, se abordan los métodos de segmentación médica, con énfasis en la segmentación cardíaca, y se revisan los enfoques existentes para el alineamiento de volúmenes en resonancias magnéticas cardiovasculares. También se presentan las técnicas utilizadas para evaluar el desempeño de los métodos de alineación propuestos en este trabajo. Finalmente, se revisan los avances en superresolución aplicada a imágenes de resonancia magnética cardíaca, y se detallan las métricas empleadas para evaluar la calidad de las imágenes reconstruidas por el modelo desarrollado.

2.1. Enfermedades Cardiovasculares (CVD)

Las enfermedades cardiovasculares (CVD) son un grupo de enfermedades que afectan el corazón o los vasos sanguíneos, que incluyen condiciones como arteriopatía coronaria, accidente cerebrovascular, y enfermedad arterial periférica. De acuerdo a la Organización Mundial de la Salud (WHO), las CVD son la principal causa de muerte globalmente, responsable de un estimado de 17.9 millones de muertes en todo el mundo, lo que representa aproximadamente el 32 % del total de fallecidos⁴.

El desarrollo de CVD es influenciado por una amplia variedad de factores de riesgo, entre los que destacan la hipertensión arterial, colesterol elevado, diabetes, obesidad, e inactividad física. Además, factores como la edad, el historial familiar y la predisposición genética también pueden incrementar la probabilidad de padecer estas enfermedades⁵.

2.2. Resonancia Magnética (MRI)

La resonancia magnética es una tecnología no invasiva que permite obtener representaciones anatómicas tridimensionales de alta resolución del interior del cuerpo humano. Se utiliza comúnmente para la detección de enfermedades, diagnóstico y planificación de tratamientos. Se basa en una sofisticada tecnología que excita y mide cambios en la orientación del

⁴[https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))

⁵<https://www.nhs.uk/conditions/cardiovascular-disease/>

momento magnético de los protones de hidrógeno en el agua de los tejidos, inducidos por un campo magnético y pulsos de radiofrecuencia. Los MRI utilizan potentes imanes que producen un fuerte campo magnético que fuerza los protones del cuerpo a alinearse con ese campo. Cuando se aplica un pulso de radiofrecuencia (RF) a través del paciente, los protones son estimulados y pierden el equilibrio contra la atracción del campo magnético. Cuando el campo de radiofrecuencia se apaga, los sensores del MRI pueden detectar la energía liberada cuando los protones se realinean con el campo magnético. El tiempo que le toma al proton en realinearse con el campo magnético, así como la cantidad de energía liberada, cambia dependiendo del entorno y de la naturaleza química de las moléculas. Especialistas médicos son capaces de distinguir entre diferentes tipos de tejidos basados en estas propiedades magnéticas. ⁶

2.3. Resonancia Magnética Cardiovascular (CMR)

La Resonancia Magnética Cardiovascular (CMR) es una aplicación especializada del MRI diseñada para la evaluación del sistema cardiovascular. Aprovecha las ventajas del MRI como la no invasividad y la ausencia de radiación ionizante, haciéndolo particularmente adecuada para estudios clínicos. [Tseng *et al.*, 2016]

Los principales desafíos de la obtención de imágenes del sistema cardiovascular se derivan principalmente del movimiento cardíaco y respiratorio. Ya que a diferencia de otros órganos o estructuras, el corazón experimenta continuas relajaciones y contracciones. Para mitigar estos problemas, los CMR emplean diferentes técnicas:

- Gatillo Cardíaco (*Cardiac Gating*): Usando las señales de un electrocardiograma (EKG) se sincroniza la obtención de imágenes en fases específicas con el ciclo cardíaco ⁷.
- Contención de respiración (*breath-hold*): A los pacientes se le solicita que contengan la respiración durante la adquisición de las imágenes para así reducir la cantidad de artefactos generados por la respiración ⁸.
- Secuencias de Pulso (*Pulse Sequences*): Las secuencias de resonancia magnética adaptadas mejoran las imágenes de CMR. Las secuencias Spin-Echo (SE) son útiles para evaluar la morfología estática, mientras que las secuencias Gradient-Echo (GRE), particularmente la precesión en estado estacionario balanceado (bSSFP), se utilizan para imágenes dinámicas, incluyendo el cine MRI ⁹.

⁶<https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri>

⁷<https://radiopaedia.org/articles/cardiac-gating-mri>

⁸<https://health.ucdavis.edu/radiology/mymri/mymri.cardiac.html>

⁹<https://radiopaedia.org/articles/mri-pulse-sequences-1>

2.3.1. Técnicas de obtención de imágenes

1. **Imágenes de estructura cardiovascular:** Son fundamentales para delimitar los componentes estructurales del sistema cardiovascular, incluyendo el miocardio, los vasos sanguíneos y las cámaras cardíacas. Para lograr este propósito, es necesario suprimir las señales de la sangre y la grasa. Esto se realiza mediante la adición de un pulso de inversión RF, que permite suprimir la señal de la sangre o la grasa. Como resultado, se obtienen imágenes denominadas *dark blood* y *dark fat* respectivamente [Tseng et al., 2016].
2. **Imágenes de la función cardíaca:** Estas imágenes se centran en capturar el movimiento del corazón a lo largo del ciclo cardíaco, lo que permite una evaluación precisa de su función. La cine-RM, particularmente mediante el uso de secuencias de precesión en estado estacionario balanceado (SSFP), proporciona un alto contraste entre la sangre y el miocardio, facilitando la evaluación exacta de parámetros como el volumen sistólico, la fracción de eyección y el movimiento de las paredes ventriculares. Las vistas cine en eje corto se utilizan para calcular los volúmenes ventriculares durante el ciclo cardíaco, permitiendo la determinación de métricas clave como el volumen telediastólico (EDV), el volumen telesistólico (ESV), el volumen sistólico (SV) y la fracción de eyección (EF), esenciales para evaluar la función cardíaca global y regional [Leong et al., 2010].
3. **Caracterización del tejido miocárdico:** Permite identificar con detalle las anomalías del miocardio a nivel molecular. Una técnica ampliamente utilizada es el Realce Tardío con Gadolinio (LGE), donde el contraste basado en gadolinio resalta el miocardio anormal, como cicatrices o fibrosis, al retener el agente de contraste por más tiempo que el tejido sano, lo que resulta crucial para diferenciar las miocardiopatías isquémicas de las no isquémicas [Jackson et al., 2007]. Además, los mapeos T1 y T2 proporcionan tiempos de relajación cuantitativos, facilitando la detección de fibrosis miocárdica difusa (con el mapeo T1) [Iles et al., 2008] y de edema (con el mapeo T2). El mapeo T2* es particularmente valioso para evaluar la sobrecarga de hierro, como se observa en condiciones como la talasemia [Pennell, 2005].
4. **Imágenes de perfusión miocárdica:** Están diseñadas para evaluar el suministro de sangre al miocardio, proporcionando información crucial sobre la isquemia miocárdica y la función microvascular. Una técnica clave es la perfusión de primer paso, que implica una adquisición rápida de imágenes durante el tránsito inicial del contraste de gadolinio a través de la circulación coronaria. Al comparar la perfusión miocárdica en condiciones de estrés y en reposo, se puede calcular la reserva de perfusión, lo que ayuda en el diagnóstico de isquemia y en la identificación de áreas con función microvascular alterada [Jerosch-Herold, 2010].
5. **Imágenes de cuantificación de flujo:** Las imágenes por contraste de fase mide la velocidad y el volumen del flujo sanguíneo dentro de los vasos y a través de las válvulas cardíacas. Esta técnica es especialmente valiosa para cuantificar flujos de derivación

en enfermedades cardíacas congénitas y la velocidad de la onda de pulso aórtica como medida de la rigidez arterial [Yu et al., 2006].

2.4. Aprendizaje profundo para la segmentación de imágenes médicas y cardíacas

La segmentación de imágenes médicas es un aspecto crucial en la imagenología médica, permitiendo la identificación y delineación de estructuras anatómicas. Este proceso es esencial para diferentes aplicaciones incluyendo el diagnóstico, tratamiento y guía quirúrgica. La complejidad de la segmentación de estructuras anatómicas surge principalmente de la variabilidad en formas de órganos, tamaños y posiciones de los pacientes así como en la presencia de ruido o artefactos en los diferentes tipos de imagenología como lo pueden ser Tomografía Computarizada (CT) o Resonancia Magnética (RM).

Con los recientes avances en técnicas de *deep learning* se ha aumentado la eficiencia y precisión de la segmentación de órganos. Arquitecturas basadas en Redes Neuronales convolucionales (CNN) [Chen et al., 2020] se han convertido en la columna vertebral de muchos modelos de segmentación automática de estructuras anatómicas.

El contexto de la segmentación del corazón impone múltiples desafíos debido a su naturaleza dinámica y complejas estructuras anatómicas. Una segmentación precisa de regiones cardíacas es fundamental para evaluar la función cardíaca, detectar anomalías y planear intervenciones.

2.4.1. Fully Connected Networks

El estudio de Jang et al. [Jang et al., 2018] . presenta un enfoque completamente automático para la segmentación cardiovascular a partir de imágenes de resonancia magnética cardíaca. El método utiliza una red neuronal completamente convolucional (FCNN) para segmentar eficientemente el LV, RV y MYO. La red se entrena de principio a fin desde cero y alcanza una alta precisión, con puntuaciones promedio de Dice de 0.94, 0.89 y 0.88 para LV, RV y MYO, respectivamente, en el conjunto de datos ACDC ¹⁰.

2.4.2. U-Net

Una de las técnicas de *deep learning* más influyentes y ampliamente utilizadas para la segmentación de imágenes biomédicas es la red neuronal convolucional U-Net [Ronneberger et al., 2015]. U-Net es una arquitectura tipo *encoder-decoder* diseñada para

¹⁰<https://www.creatis.insa-lyon.fr/Challenge/acdc/databases.html>

la predicción eficiente píxel a píxel en imágenes. La red consiste en una ruta de contracción que captura el contexto y una ruta de expansión que permite una localización precisa. Es crucial destacar que U-Net incorpora conexiones residuales entre las capas del *encoder* y el *decoder*, lo que permite a la red propagar información espacial y aprender características locales. En la Figura 5 se muestra su arquitectura de forma detallada.




Figura 5: Arquitectura U-net (ejemplo para 32x32 píxeles en la resolución más baja). Cada cuadro azul corresponde a un mapa de características multicanal. El número de canales se indica en la parte superior del cuadro. El tamaño x-y se proporciona en el borde inferior izquierdo del cuadro. Los cuadros blancos representan mapas de características copiados. Las flechas indican las diferentes operaciones.

Fuente: [Ronneberger et al., 2015].

Usando U-Net y sus variantes se han desarrollado múltiples técnicas para segmentar estructuras cardíacas. Uno de estos enfoques es el *framework open-source* VENTSEG [León et al., 2023], diseñado para la segmentación de imágenes de CMR utilizando el conjunto de datos M&Ms. Además, se aplicaron procesos de preprocesamiento y postprocesamiento sobre las imágenes con el objetivo de mejorar las predicciones obtenidas. Con ello, se lograron resultados comparables a los de especialistas en segmentación cardíaca, alcanzando un aumento en la eficiencia de aproximadamente un 80 %.

2.4.3. nnU-Net

El *framework* nnU-Net (*no-new-UNet*) representa un avance significativo en la segmentación de imágenes médicas. A diferencia de las arquitecturas tradicionales de *deep learning*, que requieren un ajuste manual extenso y experiencia especializada, nnU-Net automatiza todo el proceso, desde el preprocesamiento hasta la selección de la arquitectura y la optimización de hiperparámetros. Basado en la arquitectura U-Net, nnU-Net mejora su versatilidad al adaptarse dinámicamente a una amplia gama de tareas. Alcanza un rendimiento de vanguardia gracias a un diseño autoconfigurable que ajusta sus configuraciones según las características del conjunto de datos, como la resolución de las imágenes, la intensidad y la modalidad. Este enfoque generalizable ha convertido a nnU-Net en un punto de referencia en el análisis de imágenes médicas, demostrando robustez en diversos conjuntos de datos y tareas, sin necesidad de intervención manual o modificaciones específicas.

En la Figura 8 se detalla el *pipeline* de nnU-Net, el cual se divide en tres componentes principales:

1. **Parámetros basados en reglas:** Configuran dinámicamente aspectos del modelo como el tamaño de *batch* o la topología de la red, basándose en las propiedades del conjunto de datos (*data fingerprint*).
2. **Parámetros empíricos:** Incluyen estrategias de postprocesamiento y selección de modelos que optimizan las predicciones en función del rendimiento observado durante la validación cruzada.
3. **Parámetros fijos:** Como función de pérdida y técnicas de aumentación de datos, que se mantienen constantes y son predefinidas por el *framework*.

Un componente crucial del *pipeline* de nnU-Net es la validación cruzada de cinco pliegues (*five-fold cross-validation*). Este enfoque divide el conjunto de datos en cinco particiones, de las cuales cuatro se emplean para el entrenamiento y una para la validación en cada iteración. Este procedimiento se repite de forma cíclica, asegurando que todas las particiones sirvan como conjunto de validación una vez. La validación cruzada no solo permite evaluar de manera objetiva el desempeño del modelo, sino que también facilita la identificación del conjunto óptimo de configuraciones al integrar información de múltiples particiones. Finalmente, el *framework* realiza una selección empírica del mejor modelo basado en los resultados obtenidos y aplica, si es necesario, un postprocesamiento adicional para refinar las predicciones.

La flexibilidad y adaptabilidad de nnU-Net lo han consolidado como un punto de referencia en la segmentación de imágenes médicas. Según diversos estudios, nnU-Net supera o iguala el rendimiento de otros métodos de segmentación en 33 de 53 conjuntos de datos biomédicos. Este enfoque generalizable permite abordar una amplia gama de tareas sin necesidad

de ajustes específicos, reduciendo significativamente el tiempo y el esfuerzo requeridos para implementar soluciones de segmentación automatizada.

En el contexto de la segmentación cardíaca, múltiples estudios han demostrado la efectividad de nnU-Net al alcanzar resultados *state-of-the-art*, incluso en estructuras complejas como los ventrículos y el miocardio [Full et al., 2021] [Zhang et al., 2021], realizando únicamente pequeños cambios en los rangos de aumentación de datos en comparación con la versión estándar de nnU-Net.




Figura 6: Configuración de método automatizado para la segmentación de imágenes bio-médicas basada en aprendizaje profundo. Dada una nueva tarea de segmentación, las propiedades del conjunto de datos se extraen en forma de una "huella digital del conjunto de datos"(rosa). Un conjunto de reglas heurísticas modela las interdependencias de los parámetros (mostradas como flechas delgadas) y opera sobre esta huella digital para inferir los "parámetros basados en reglas" dependientes de los datos (verde) de la secuencia de comandos. Estos se complementan con "parámetros fijos"(azul), que están predefinidos y no requieren adaptación. Se entrenan hasta tres configuraciones en una validación cruzada de cinco pasos. Finalmente, nnU-Net realiza automáticamente la selección empírica del conjunto óptimo de estos modelos y determina si se requiere postprocesamiento ("parámetros empíricos", amarillo). La tabla de la parte inferior muestra valores explícitos, así como formulaciones de reglas resumidas de todos los parámetros configurados.

Fuente: [Isensee et al., 2021].

2.5. Alineación para resonancias magnéticas cardiovasculares

[Nitta et al., 2013] presenta un método para el alineamiento automático de cortes transversales en CMR, utilizando técnicas de procesamiento de imágenes para detectar puntos de referencia clave en la anatomía cardíaca, como la válvula mitral, el ápice, el tracto de salida del ventrículo izquierdo, la válvula tricúspide, la esquina del ventrículo derecho y la pared anterior. Este enfoque permite la identificación precisa de los seis planos estándar utilizados en la evaluación cardíaca (eje corto, eje largo vertical, eje largo horizontal, y las vistas de cuatro, dos y tres cámaras) sin necesidad de una intervención manual significativa. Para lograrlo, el método implementa una combinación de reconstrucción de imágenes isotrópicas y algoritmos de clasificación basados en árboles de decisión extremadamente aleatorizados (Extremely Randomized Trees, ERT), lo que optimiza la detección de estructuras anatómicas y la planificación de cortes. Esta técnica destaca por su rapidez y precisión.

[Wan et al., 2016] propusieron un método geométrico para corregir distorsiones por movimiento en imágenes de resonancia magnética cardíaca, basado en el registro iterativo de contornos del ventrículo izquierdo delineados manualmente en planos de eje largo y corto. Estos contornos se proyectan en un sistema de coordenadas tridimensional del paciente y se alinean utilizando el algoritmo *generalized iterative closest point* (gICP), lo que permite una corrección precisa del desplazamiento entre cortes. Los contornos corregidos se utilizan posteriormente para reconstruir el volumen del ventrículo, permitiendo una validación cuantitativa de la mejora obtenida. Esta técnica ha demostrado incrementar significativamente la precisión en la modelación 3D del corazón.

[Villard et al., 2017] desarrollaron un algoritmo de registro basado en fase local para corregir la desalineación entre cortes en estudios de resonancia magnética cardíaca adquiridos con múltiples apneas. Su método emplea transformaciones rígidas y optimización iterativa para alinear imágenes de ejes corto y largo utilizando como criterio la correlación normalizada de las señales de fase local en las líneas de intersección entre cortes. Esta métrica es independiente del contraste, lo que la hace robusta frente a variaciones de intensidad propias de secuencias como *late gadolinium enhancement* (LGE). La estrategia optimiza los parámetros de un solo corte por iteración mientras mantiene fijos los demás, reduciendo la influencia de valores atípicos y minimizando la discrepancia espacial global. El resultado es una mejora sustancial en la coherencia tridimensional del volumen cardíaco reconstruido.

2.6. Evaluación de Alineación

Para evaluar el rendimiento de las técnicas de alineación empleadas, se realizará un análisis cualitativo comparando la imagen desalineada original con las imágenes obtenidas tras aplicar los métodos estudiados.

Además, se utilizará un conjunto de datos adicional que contiene imágenes alineadas de for-

ma precisa. A estas se les aplicará una desalineación artificial, para luego aplicar los métodos de alineación correspondientes. Esto permitirá realizar un análisis más profundo y controlado del desempeño de cada técnica bajo condiciones simuladas.

2.7. Superresolución para resonancias magnéticas cardiovasculares

[Ur Rahman y Wesarg, 2010] propusieron un método de reconstrucción por superresolución que combina imágenes de resonancia magnética cardíaca adquiridas en ejes corto (SA) y largo (LA), con el objetivo de generar volúmenes isotrópicos de alta resolución a partir de datos altamente anisotrópicos. Utilizan un enfoque de máxima a posteriori (MAP) que modela el proceso de adquisición mediante funciones de transformación geométrica, desenfoque, remuestreo y ruido, lo que permite estimar una imagen de alta resolución que reproduce con mayor fidelidad las observaciones originales. A diferencia de técnicas basadas en el promedio simple, el uso de registros deformables como paso previo mejora considerablemente la alineación entre los conjuntos de datos, permitiendo obtener imágenes más detalladas y adecuadas para tareas de segmentación y análisis clínico.

Las técnicas de superresolución aplicadas específicamente en el eje transversal (eje z) de las imágenes de resonancia magnética son aún escasas. La mayoría de los métodos existentes en el ámbito de la superresolución médica tienden a centrarse en mejorar la resolución espacial en los planos axiales, es decir, en los ejes x e y, donde la resolución ya es relativamente alta. Sin embargo, el eje transversal suele presentar una menor densidad de información debido al mayor espaciado entre cortes, lo que limita la calidad volumétrica de las reconstrucciones.

2.8. Evaluación de Superresolución

Las métricas empleadas para evaluar el rendimiento del método de superresolución son el Error Cuadrático Medio (MSE), la Relación de Señal a Ruido Máxima (PSNR) y el Índice de Similitud Estructural (SSIM). Además, se realizará un análisis cualitativo de las imágenes generadas.

2.8.1. MSE

El Error Cuadrático Medio (MSE) mide el promedio de las diferencias cuadradas entre la imagen estimada y la imagen de referencia:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

El MSE es una métrica simple que proporciona una medida cuantitativa clara del error. Sin embargo, presenta limitaciones, como su sensibilidad a valores atípicos (*outliers*) y su falta de correlación directa con la percepción visual. Por estas razones, se complementa con métricas como PSNR y SSIM, que permiten una evaluación más integral.

2.8.2. PSNR

El Pico de Relación Señal a Ruido (PSNR) mide la relación entre la intensidad máxima de la imagen y el ruido presente, reflejando la fidelidad de la imagen generada. Se define como:

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX^2}{MSE} \right) \quad (2)$$

El PSNR es útil para comparar la fidelidad de las imágenes generadas respecto a las originales, capturando diferencias en la calidad percibida. Es especialmente relevante en este contexto, donde la precisión de los píxeles es crítica para evaluar el rendimiento.

2.8.3. SSIM

El Índice de Similitud Estructural (SSIM) evalúa la similitud entre dos imágenes considerando tres factores principales: luminancia, contraste y estructura. Se define como:

$$SSIM = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3)$$

donde:

- μ_x y μ_y son las medias de las imágenes.
- σ_x^2 y σ_y^2 son las varianzas de las imágenes.
- σ_{xy} es la covarianza entre las imágenes.
- C_1 y C_2 son constantes para estabilizar la fórmula y evitar indeterminaciones.

El SSIM es una métrica que considera aspectos perceptuales al analizar características estructurales, de luminancia y contraste, en lugar de limitarse a medir diferencias pixel a pixel. Esto lo convierte en una herramienta más adecuada para evaluar la calidad visual desde la perspectiva humana.

2.8.4. Volumen del ventrículo izquierdo

Como última métrica se utilizará el volumen del ventrículo izquierdo, el cual se calculará utilizando la segmentación del mismo junto con el tamaño de voxel (*voxel size*) correspondiente a cada imagen. El volumen del ventrículo izquierdo es una métrica clínica clave, ya que permite evaluar la función cardíaca global y detectar alteraciones estructurales o funcionales asociadas a diversas patologías. Su inclusión en este trabajo permite complementar las evaluaciones cualitativa y cuantitativa, proporcionando un indicador fisiológico directo del impacto de la técnica superresolución sobre la calidad de las imágenes reconstruidas.

CAPÍTULO 3

PROPUESTA DE SOLUCIÓN

En las siguientes subsecciones se detallan los conjuntos de datos utilizados para el desarrollo de las soluciones propuestas, incluyendo un conjunto adicional. A continuación, se describen los cuatro tipos de métodos de alineación estudiados. Posteriormente, se explica el modelo de superresolución, abordando tanto su arquitectura como el proceso de entrenamiento. Finalmente, se presenta cómo todas estas soluciones se integran y funcionan de manera conjunta en el *dataset* M&M.

3.1. M&Ms Challenge Dataset

El conjunto de datos empleado en este trabajo es el *Multi-Centre, Multi-Vendor & Multi-Disease Cardiac Image Segmentation Challenge dataset*. Este conjunto de datos incluye imágenes de resonancia magnética cardíaca (CMR) obtenidas de cuatro proveedores de equipos de MRI (Siemens, Philips, General Electric y Canon) y recopiladas en seis centros de salud ubicados en España, Alemania y Canadá. En la Figura 7 se presentan ejemplos visuales correspondientes a cada uno de los proveedores de equipamiento incluidos en este conjunto de datos.




Figura 7: Apariencia Visual de cortes centrales de CMR para los cuatro proveedores de equipo del M&Ms *dataset*.

Fuente: [Campello et al., 2021].

El conjunto de datos está compuesto por un total de 375 pacientes, distribuidos en tres subconjuntos: un conjunto de entrenamiento con 175 pacientes, de los cuales 150 cuentan con

anotaciones; un conjunto de validación con 40 pacientes; y un conjunto de prueba con 160 pacientes. La distribución específica de los centros y proveedores en cada subconjunto se detalla en la Tabla 1.

Tabla 1: Número de pacientes para cada subconjunto de entrenamiento con la distribución de centros y equipamiento.

Fuente: [Campello et al., 2021].

	Siemens		Philips		GE	Canon	Total
Etiqueta	A		B		C	D	
Centro	1	6	2	3	4	5	
Entrenamiento	75	0	50	25	25	0	175
Validación	5	5	5	5	10	10	40
Prueba	16	24	19	21	40	40	160
Total	96	29	74	51	75	50	375

Para cada paciente anotado, se dispone de segmentaciones manuales a nivel de píxel correspondientes al ventrículo derecho (RV), ventrículo izquierdo (LV) y miocardio (MYO). Estas segmentaciones están disponibles exclusivamente para las fases cardíacas de fin de sístole (ES) y fin de diástole (ED) de la secuencia.

En la Figura 8 se puede apreciar un análisis del conjunto de datos, donde se incluyen 211 pacientes mujeres y solo 134 hombres. Además, se cuenta con un rango de edades amplio, con edades desde los 20 años hasta los 80 años.

Por otro lado, también se observa la distribución de las patologías de los pacientes, en las cuales se encuentran 8 patologías, las cuales son, en orden de frecuencia: Miocardiopatía Dilatada (DCM) con 97 pacientes, Normal (NOR) con 89 pacientes, Miocardiopatía Hipertrófica (HCM) con 85 pacientes, Otras (Other) con 25 pacientes, Enfermedad Cardíaca Hipertensiva (HHD) con 24 pacientes, Ventrículo Derecho Anómalo (ARV) con 15 pacientes, Enfermedad Isquémica del Corazón (EIC) con 5 pacientes, Síndrome de Corazón de Atleta (AHS) con 3 pacientes, y No Compactación del Ventrículo Izquierdo (LVNC) con 2 pacientes.

Esta variedad en cuanto a equipamiento, centro médico, patología, edad, y sexo permite que este conjunto de datos sea un punto de referencia sobresaliente para el estudio de enfermedades cardíacas, no solo en tareas de segmentación para las cuales fue creado originalmente, sino también en aplicaciones como la alineación y la superresolución, que son exploradas en este trabajo.




Figura 8: Distribución demográfica (arriba izquierda y arriba derecha) y patológica (abajo) de los pacientes en el M&M dataset.

Fuente: Elaboración propia.

3.2. Dataset de Soporte

Debido a que el M&M dataset carece de imágenes alineadas que puedan utilizarse como referencia, se empleará un conjunto de datos de soporte para realizar un análisis más profundo. Este conjunto de datos se compone de CMR adquiridos mediante una secuencia 3D multicontraste en un escáner de 0.55T. Contiene imágenes de contraste *bright-blood*, utilizadas para la visualización de estructuras cardiovasculares, y *black-blood*, empleadas para la caracterización del miocardio. Además, incluye mapas cuantitativos de los tiempos de relajación T1 y T2 obtenidos a nivel vóxel [Kokhanovsky et al., 2025].

3.2.1. Preprocesamiento

Dado que este dataset no cuenta con imágenes de eje corto, se realizó un preprocesamiento de cada CMR para obtener su proyección en dicho eje. Para ello, cada una de las imágenes *bright-blood* fue cargada en el software ParaView ¹¹, donde se seleccionó un origen en la base del corazón y una normal en dirección al ápice, como se muestra en la Figura ⁹.




Figura 9: Izquierda: Ejemplo de CMR cargado en ParaView. Derecha: Proyección del eje corto junto con su normal y un punto central del corazón que la intercepta.

Fuente: Elaboración propia.

Posteriormente, utilizando estos valores en el lenguaje de programación MATLAB ¹², se generaron cortes oblicuos con grosores de 4 mm (para la evaluación de superresolución) y 8 mm (para asemejar los del M&M dataset). Con este último, además, se generó un conjunto desalineado de forma artificial para evaluar los métodos de alineación, aplicando un desplazamiento aleatorio entre el 1 % y el 5 % del tamaño del corte transversal a un 60 % de los cortes del CMR. En la Figura ¹⁰ se aprecian los cortes de un paciente con un grosor de 8 mm, desde la base del corazón (corte 1) al ápex del corazón (corte 11).

Finalmente, a cada uno de los CMR se les aplicó un modelo de segmentación para poder utilizarlos en las diferentes técnicas de alineamiento.

¹¹<https://www.paraview.org/>

¹²<https://www.mathworks.com/products/matlab.html>




Figura 10: Ejemplo de volumen generado tras procesar imágenes del *Dataset* de Soporte, obteniendo un volumen de eje corto.

Fuente: Elaboración propia.

3.3. Alineación

Se implementaron 4 técnicas para mejorar la Alineación de CMR de eje corto:

- Centro de masa del Ventrículo Izquierdo (Vistas horizontal y vertical)
- Correlación cruzada (Vistas horizontal y vertical)
- Centro de masa del Ventrículo Izquierdo (Vistas 4 cámaras)
- Correlación cruzada (Vistas de 4 cámaras)

3.3.1. Obtención de vistas

En las cuatro técnicas mencionadas anteriormente, se puede observar que en realidad corresponden a dos técnicas principales, cada una con dos vistas diferentes. Por lo tanto, primero se introducirá el proceso de obtención de las vistas utilizadas.

La primera corresponde a las denominadas vistas horizontal y vertical. En esta, se calcula el centro de masa del ventrículo izquierdo utilizando el corte transversal central de la segmentación en una fase cardíaca. A partir de este punto, se extraen perfiles horizontales y

verticales para cada corte del volumen. Posteriormente, se apilaron estos perfiles, obteniendo así las proyecciones que se aprecian en la Figura 11.




Figura 11: Ejemplo de extracción de las vistas horizontal y vertical en un CMR de eje corto en una fase cardíaca seleccionada de forma arbitraria, mostrando tanto las imágenes anatómicas como sus segmentaciones correspondientes.

Fuente: Elaboración propia.

La segunda vista corresponde a la denominada vista de cuatro cámaras, en la cual se determina el centro de masa de los ventrículos izquierdo y derecho. A partir de estos puntos, se define una función lineal que intersecta ambos. Además, se establece una segunda función lineal perpendicular a la anterior, la cual cruza el centro de masa del ventrículo izquierdo.

De manera similar al método anterior, se extraen los perfiles siguiendo dichas funciones lineales para posteriormente apilarlos, como se muestra en la Figura 12.




Figura 12: Ejemplo de extracción de las vistas de cuatro cámaras en un CMR de eje corto en una fase cardíaca seleccionada de forma arbitraria, mostrando tanto las imágenes anatómicas como sus segmentaciones correspondientes.

Fuente: Elaboración propia.

3.3.2. Centro de Masa del Ventrículo Izquierdo

Usando las proyecciones, para cada uno de los perfiles de la segmentación, se recalculó el centro de masa del ventrículo izquierdo y del miocardio, en caso de que la segmentación del ventrículo izquierdo no esté disponible.

Manteniendo fijo el perfil del corte transversal central, se determinó el desplazamiento necesario en cada dirección para alinear los distintos cortes transversales del volumen y se aplicó a la imagen anatómica como a la segmentación, repitiendo el procedimiento en cada fase cardíaca del CMR.

3.3.3. Correlación Cruzada

Utilizando las proyecciones, primero se seleccionaron los perfiles del corte central como punto de referencia. Posteriormente, se aplicó una correlación cruzada entre cada par de perfiles adyacentes obtenidos a partir de las imágenes anatómicas.

$$c_k = \sum_n x_n \cdot a_{n+k} \quad (4)$$

Con lo cual se obtuvo el desplazamiento necesario para alinear los cortes transversales y, finalmente, se aplicaron las correcciones a cada corte transversal, repitiendo este procedimiento en cada fase cardíaca del CMR.

3.4. Superresolución

Para la superresolución de CMR se utilizó *Deep Learning*, empleando específicamente redes neuronales convolucionales. A continuación se detallan los principales aspectos relacionados con la arquitectura de la red neuronal, entrenamiento y experimentación.

La implementación de la red neuronal convolucional se realizó en Python¹³ utilizando la biblioteca PyTorch¹⁴. El código fuente de los modelos está disponible en <https://github.com/danieldamc/TBD>.

3.5. Arquitectura de la red

La arquitectura de red neuronal profunda usada para la superresolución de CMR es una basada en la U-net a la cual se le realizaron múltiples modificaciones en sus bloques. En la Figura 15 se muestra la arquitectura de la red final Res-Unet.

El primer bloque a definir corresponde al llamado *conv-block* este es el bloque básico de esta red neuronal y es una sucesión de una convolución con *kernel* de tamaño 3, seguido por una capa de *batch normalization* finalizando con una capa de activación ReLu. Este bloque se detalla en la Figura 13

¹³<https://www.python.org/>

¹⁴<https://pytorch.org/>




Figura 13: Bloque convolucional básico (Conv Block).
Fuente: Elaboración Propia.

En la Figura 14 se detalla la arquitectura del *res-block*, este bloque corresponde a tres *conv-block* secuenciales donde en el último *conv-block* se realiza una operación de identidad con la conexión residual previo a la función de activación [He et al., 2016]. Cabe destacar que a esta conexión residual se le aplica una convolución con tamaño de kernel 3 [Hu et al., 2023] para así poder igualar la cantidad de canales de la entrada y salida.




Figura 14: Bloque residual usado en la arquitectura de la ResUnet (Res Block).
Fuente: Elaboración Propia.

Finalmente, para la arquitectura ilustrada en la Figura 15 la cual al igual que la U-net consiste en un camino de contracción (izquierda) y un camino de expansión (derecha). Donde el camino de contracción consiste en la aplicación repetida de *res-block* y una operación de *max-pooling* con tamaño de *kernel* 2 y *stride* 2 para reducir la resolución, luego de cada reducción de resolución se duplica el número de canales en los mapas de características en la primera convolución en el *res-block*.




Figura 15: Arquitectura Res-Unet.
Fuente: Elaboración Propia.

3.6. Entrenamiento

La red neuronal convolucional fue entrenada durante 60 épocas utilizando el optimizador ADAM y la función de pérdida *Learned Perceptual Image Patch Similarity* (LPIPS). Además, se aplicó una estrategia de aumento de datos para incrementar la variabilidad del conjunto de entrenamiento. Todos los detalles del entrenamiento se detallan en las siguientes secciones.

El proceso de entrenamiento se llevó a cabo en una tarjeta gráfica (GPU) NVIDIA T4 con 15 GB de VRAM.

3.6.1. Procesamiento del conjunto de datos

Dado que M&M *dataset* está diseñado específicamente para una competencia de segmentación de estructuras cardíacas, la partición incluida en el mismo se encuentra optimizada para evaluar casos particulares. Sin embargo, esta configuración no es ideal para la tarea de superresolución. Por ello, se realizó una nueva partición, en la cual se mezclaron todos los

estudios de CMR del conjunto de datos y se dividieron en tres conjuntos: entrenamiento, validación y prueba, con una proporción de los datos del 70 %, 20 % y 10 %, respectivamente. Este procedimiento se llevó a cabo aplicando una estratificación basada en el centro de origen de los datos. En la Tabla 2 se detallan cada uno de los conjuntos junto con la cantidad de CMR y registros de cada uno.

Tabla 2: Partición de datos para superresolución.
Fuente: Elaboración Propia.

Partición	Cantidad de CMR	Cantidad de registros
Entrenamiento	241	60492
Validación	69	17672
Prueba	35	9540
Total	345	87704

Posteriormente, se adaptó cada estudio de CMR para que pudiera ser utilizado en una red neuronal convolucional. Para ello, se creó un nuevo conjunto de datos, en el cual cada registro se compone de tres imágenes de cortes transversales consecutivos correspondientes a una misma fase cardíaca. En este esquema, la primera y la tercera imagen actúan como entrada del modelo, mientras que la segunda imagen representa la salida, que se desea predecir. En la Figura 16 se muestra un ejemplo de un registro del *dataset*.




Figura 16: (a y c) Imágenes de entrada para el modelo. (b) Imagen objetivo del modelo.
Fuente: Elaboración Propia.

Dado que los estudios de CMR presentan variadas resoluciones y relaciones de aspecto, fue necesario realizar un preprocesamiento de las imágenes. En primer lugar, se llevó a cabo una normalización dividiendo el valor de cada píxel entre el valor máximo de los píxeles del estudio de CMR correspondiente, ajustando así los valores al rango [0, 1]. Posteriormente, las imágenes se adaptaron a una relación de aspecto 1:1 mediante la técnica de *padding*,

rellenando los espacios vacíos con ceros cuando fue necesario. Finalmente, las imágenes fueron redimensionadas a 224x224 píxeles.

3.6.2. Función de Perdida

Como los métricas clásicas de comparación pixel-a-pixel de imágenes como MSE o PSNR presentan limitaciones al capturar adecuadamente la percepción humana de la similitud visual. Para solucionar esto, se utilizó LPIPS (*Learned Perceptual Image Patch Similarity*) [Zhang et al., 2018] como función de pérdida al entrenar modelos.

Este método se basa en usar una red neuronal convolucional entrenada para clasificación, en este caso VGG [Simonyan, 2014] usando el conjunto de datos ImageNet [Russakovsky et al., 2015]. A la cual se le pasa las imágenes a comparar extrayendo *embeddings* en capas específicas para luego obtener la distancia entre estos y finalmente promediarlos. Detalles específicos de este procedimiento se detalla en la Figura 17.




Figura 17: Cálculo de la distancia desde una red. (Izquierda) Para calcular una distancia d_0 entre dos parches, x y x_0 , dada una red F , primero se calculan los *embeddings*, se normalizan las activaciones en la dimensión de canales, se escala cada canal por un vector w , y se calcula la distancia l_2 . Luego se promedia a través de la dimensión espacial y las capas. (Derecha) Una red pequeña G es entrenada para predecir la similitud h a partir del par de distancias (d_0, d_1) .

Fuente: [Zhang et al., 2018].

Como se muestra en la Figura 18, el uso de redes neuronales para la comparación de imágenes logra resultados que se alinean estrechamente con la percepción humana. Esto hace que LPIPS sea una herramienta particularmente eficaz para evaluar la similitud visual de manera más precisa que las métricas tradicionales. Además, su integración como función de pérdida permite optimizar modelos hacia una mejor representación de la calidad visual percibida, mejorando significativamente los resultados en tareas donde la percepción humana es un factor crítico.




Figura 18: Comparación de similitud entre observadores humanos y varios modelos computacionales, incluyendo métricas tradicionales y redes neuronales profundas. Cada conjunto de imágenes incluye una referencia (centro) y dos opciones (izquierda y derecha), donde se evalúa cuál es más similar al parche central según diferentes métodos.

Fuente: [Zhang et al., 2018].

3.6.3. Optimizador

Como optimizador se utilizó ADAM (*Adaptive Moment Estimation*) [Kingma, 2014] debido a su efectividad en la optimización de redes neuronales profundas y complejas. ADAM combina las ventajas del gradiente estocástico con momento (SGD Momentum) [Rumelhart et al., 1986] y la adaptación de la tasa de aprendizaje (RMSProp) [Hinton, 2012], con la adición de una corrección de sesgo en las estimaciones de momento.

Este mecanismo ajusta dinámicamente la tasa de aprendizaje para cada parámetro individual, proporcionando mayor estabilidad en el entrenamiento y mejorando la convergencia, incluso en modelos con grandes cantidades de parámetros. Su capacidad para adaptarse a las variaciones en los gradientes lo hace especialmente adecuado para tareas de aprendizaje profundo, siendo considerado un estándar en el campo.

La tasa de aprendizaje se ajustó dinámicamente a lo largo del entrenamiento. Inicialmente, se implementó una fase de *warmup* con un incremento lineal desde 0.001 hasta 0.01 durante las primeras 10 épocas. Posteriormente, la tasa de aprendizaje se mantuvo constante durante otras 10 épocas. Finalmente, se aplicó un esquema de *cosine annealing* durante 40 épocas, disminuyendo gradualmente hasta alcanzar un valor mínimo de 0.001. En la Figura 19 se muestra un gráfico evolución de la tasa de aprendizaje por época.




Figura 19: Evolución de la tasa de aprendizaje durante en entrenamiento.
Fuente: Elaboración Propia.

3.6.4. Aumentación de datos

Para enriquecer los datos y mejorar su diversidad, se implementó un proceso de aumentación de datos. Las transformaciones aplicadas incluyeron una rotación de las imágenes, con una probabilidad de 1, seleccionada aleatoriamente entre los ángulos $[0^\circ, 90^\circ, 180^\circ \text{ y } 270^\circ]$. Además, se realizaron un *flip* horizontal con una probabilidad de 0.5 y un *flip* vertical con la misma probabilidad. En la Figura 20, se ilustran estas transformaciones.




Figura 20: Ejemplo de aumentación de datos.
Fuente: Elaboración Propia.

3.7. Flujo de datos final

En las secciones anteriores de este capítulo se detallaron cada uno de los componentes de la propuesta de solución; solo falta explicar cómo estos funcionan en conjunto para procesar

un conjunto de CMR de eje corto.




Figura 21: Flujo de procesamiento propuesto para imágenes CMR de eje corto del M&M *dataset*. El esquema ilustra las etapas de segmentación, alineación, superresolución y segmentación final de los cortes generados.

Fuente: Elaboración Propia.

Como se aprecia en la Figura 21, se muestra un ejemplo del flujo de datos utilizando la propuesta de solución aplicada al M&M *dataset*. El primer paso consiste en segmentar el CMR, para luego aplicar uno de los métodos de alineación estudiados. Posteriormente, se aplica el modelo de superresolución con el objetivo de generar los cortes transversales intermedios entre cada par de cortes contiguos. Finalmente, los cortes transversales generados son segmentados, obteniendo así los dos volúmenes finales: uno correspondiente a las imágenes anatómicas y otro a las segmentaciones.

CAPÍTULO 4

VALIDACIÓN DE LA SOLUCIÓN

En esta sección se realizará la validación de las soluciones propuestas, comenzando con la evaluación de los métodos de alineamiento estudiados, para posteriormente analizar el desempeño del modelo de superresolución en distintos conjuntos de datos.

4.1. Alineación

Los métodos utilizados se validarán utilizando los dos conjuntos de datos expuestos en el capítulo anterior.

Para el M&M *dataset*, se seleccionaron cuatro pacientes, cada uno asociado a un equipamiento diferente (Siemens, Philips, GE y Canon). Estos pacientes poseen características similares en cuanto a edad, sexo y patología. Se realizará un análisis cualitativo con el objetivo de estudiar los efectos de cada uno de los métodos de alineamiento evaluados.

Por otro lado, también se utilizará el *Dataset* de Soporte para la evaluación. Dado que este conjunto incluye volúmenes alineados y desalineados artificialmente, será posible analizar con mayor profundidad los métodos de alineamiento mediante un análisis cualitativo.

4.1.1. M&M *dataset*

El primer conjunto de datos al cual se le realizará la evaluación de los métodos de alineación corresponde al M&M *dataset*, para lo cual se llevará a cabo un análisis cualitativo para cada uno de los fabricantes de equipamiento (Philips, GE, Canon, Siemens).




Figura 22: Imágenes anatómicas y segmentaciones en vistas horizontal y vertical para cada uno de los métodos de alineamiento, junto con la imagen original, correspondientes a un caso del proveedor de equipo Philips.

Fuente: Elaboración Propia.

En la Figura 22 se presenta un caso correspondiente a equipamiento Philips. Se muestran las vistas horizontal y vertical tanto del volumen original como de los volúmenes a los que se les aplicaron los distintos métodos de alineación. Se puede destacar que el método con mejor rendimiento para este caso es la correlación cruzada, utilizando las vistas horizontal y vertical, en las cuales la transición entre cortes transversales resulta más suave y el ventrículo izquierdo se visualiza de manera más coherente.




Figura 23: Imágenes anatómicas y segmentaciones en vistas horizontal y vertical para cada uno de los métodos de alineamiento, junto con la imagen original, correspondientes a un caso del proveedor de equipo General Electric.

Fuente: Elaboración Propia.

En la Figura 23 se presenta un caso correspondiente a equipamiento General Electric. Aquí se observa, en la imagen anatómica de la vista horizontal, cierta desalineación cerca del ápice del corazón. Los métodos que emplean tanto la vista horizontal como la vertical mostraron un buen rendimiento, especialmente aquel que utiliza el centro de masa. Por otro lado, los métodos basados en la vista de cuatro cámaras no lograron una alineación coherente con la anatomía cardíaca.

En la Figura 24 se presenta un caso correspondiente a un equipamiento Canon. Se observa que, en la vista horizontal anatómica, existe cierta desalineación. Los métodos que utilizan correlación cruzada no lograron mejorar la alineación, como se aprecia en las vistas horizontales. Por otro lado, los métodos que emplean el centro de masa se desempeñaron de buena manera, especialmente aquel que utiliza tanto la vista horizontal como la vertical.

Por último, en la Figura 25 se presenta un caso con equipamiento Siemens. En este caso, todos los métodos de alineación ofrecieron resultados favorables, siendo el método que utiliza el centro de masa en la vista de cuatro cámaras el que se desempeñó de la mejor manera.




Figura 24: Imágenes anatómicas y segmentaciones en vistas horizontal y vertical para cada uno de los métodos de alineamiento, junto con la imagen original, correspondientes a un caso del proveedor de equipo Canon.

Fuente: Elaboración Propia.




Figura 25: Imágenes anatómicas y segmentaciones en vistas horizontal y vertical para cada uno de los métodos de alineamiento, junto con la imagen original, correspondientes a un caso del proveedor de equipo Siemens.

Fuente: Elaboración Propia.

4.1.2. Dataset de Soporte

El segundo conjunto de datos al cual se le realizará la evaluación de los métodos de alineación estudiados corresponde al *Dataset* de Soporte. A este se le aplicó una desalineación artificial, la cual se muestra en la Figura 26. La magnitud de la desalineación corresponde a un rango entre 1 % y 5 %, elegido de forma aleatoria. En este caso, el método que logró los mejores resultados fue el que utiliza el centro de masa en la vista de cuatro cámaras. Por otro lado, los métodos que utilizan las vistas horizontal y vertical presentaron dificultades al alinear el CMR.




Figura 26: Imágenes anatómicas y segmentaciones en vistas horizontal y vertical para cada uno de los métodos de alineamiento, junto con la imagen original y la desalineada artificialmente, correspondientes a un caso del *Dataset* de Soporte.

Fuente: Elaboración Propia.

4.2. Superresolución

El modelo de superresolución se evaluará utilizando cinco conjuntos de datos con el objetivo de aumentar la robustez del análisis. En primer lugar, se evaluará sobre el conjunto de prueba del M&M *dataset*, especificado en el capítulo anterior.

En este conjunto se realizarán dos tipos de evaluación. En la primera, se aplicará una reducción de cortes transversales a los volúmenes en cada fase, eliminando todos los cortes transversales con índice impar, para luego predecir estos usando el modelo de superresolución. De esta forma, será posible realizar tanto un análisis cualitativo (Mejor y peor caso de volumen del ventrículo izquierdo en las fases cardíacas fin de sístole y fin de diástole) como cuantitativo (MSE, SSIM, PSNR) de los resultados. En la Figura 27 se muestra un ejemplo de la reducción de cortes transversales aplicado a un volumen, donde en la vista vertical se observa que la cantidad de cortes transversales disminuye de 13 a 7. Posteriormente, los cortes eliminados son reconstruidos mediante el modelo de superresolución.




Figura 27: Ejemplo de reducción de cortes transversales. Izquierda: corte vertical original en la fase cardíaca de fin de sístole. Derecha: corte vertical luego de aplicar la reducción de cortes transversales al volumen.

Fuente: Elaboración Propia.

Por otro lado, también se evaluará el modelo utilizando los datos originales sin aplicar *down-sampling*. En este caso, solo será posible llevar a cabo un análisis cualitativo.

En segundo lugar, se empleará el dataset de soporte especificado en el capítulo anterior. Dado que este conjunto permite definir libremente el grosor de los cortes transversales extraídos, se optó por utilizar dos grosores: 4 mm y 8 mm. A ambos conjuntos se les aplicó una reducción de cortes transversales, de manera que el modelo predijera sobre volúmenes con grosores efectivos de 8 mm y 16 mm, respectivamente. Esta estrategia permite evaluar la

efectividad del modelo ante distintos grosores de corte, y realizar tanto un análisis cualitativo como cuantitativo.

4.2.1. Resumen Cuantitativo

Antes de presentar los resultados, se realizará un resumen de las métricas cuantitativas con el fin de facilitar la comparación entre los distintos conjuntos de datos.

Tabla 3: Métricas cuantitativas (MSE, SSIM, PSNR) para cada uno de los conjuntos de datos utilizados en la evaluación.

Fuente: Elaboración Propia.

	MSE	SSIM	PSNR
M&M <i>dataset</i>	0.0036 ± 0.0023	0.66 ± 0.09	25.5 ± 3.1
Dataset de soporte (4mm)	0.0013 ± 0.0005	0.85 ± 0.03	29.5 ± 1.9
Dataset de soporte (8mm)	0.0025 ± 0.0009	0.80 ± 0.05	26.8 ± 1.9
M&M <i>dataset</i> Alineado	0.0042 ± 0.0026	0.65 ± 0.10	25.0 ± 3.20

En la Tabla 3 se presentan las métricas MSE, SSIM y PSNR para cada uno de los conjuntos de datos. Se puede apreciar que el conjunto de datos que obtuvo los mejores resultados corresponde al *Dataset de Soporte* con un grosor de corte de 4 mm, con un MSE de 0,0013, un SSIM de 0,85 y un PSNR de 29,5 dB. Por otro lado, en la versión de 8 mm de este dataset, estas métricas empeoran levemente a un MSE de 0,0025, un SSIM de 0,80 y un PSNR de 26,8 dB. Esto sugiere que, a medida que se disminuye el grosor de corte, la calidad de las imágenes generadas tiende a aumentar.

Para el conjunto de evaluación del M&M *dataset*, se obtiene un MSE de 0,0036, un SSIM de 0,66 y un PSNR de 25,5 dB, resultados que son coherentes con los obtenidos durante el entrenamiento del modelo. Al comparar las métricas entre el M&M *dataset* y el *Dataset de Soporte* en sus dos versiones, se aprecia un incremento en todas las métricas. Esto se atribuye principalmente a que, en el *Dataset de Soporte*, al ser una proyección oblicua de CMR, una proporción grande de la imagen tiene valor 0 en comparación con el M&M *dataset*.

Finalmente, también se evaluó el M&M *dataset* al cual se le aplicó el método de alineación basado en el centro de masa utilizando las vistas horizontal y vertical, antes de realizar la reducción de cortes transversales. Este conjunto obtuvo un MSE de 0,0042, un SSIM de 0,65 y un PSNR de 24,98 dB. Estas métricas son levemente inferiores a las del caso del M&M *dataset* sin alineación previa; sin embargo, la diferencia no es lo suficientemente significativa como para justificar el uso de la alineación en este contexto.

Tabla 4: Diferencias de volumen (ml) entre el volumen tridimensional original y el volumen tridimensional reconstruido o aumentado para el ventrículo izquierdo.

Fuente: Elaboración Propia.

	Diferencia volumen LV (ml)
M&M <i>dataset</i> (ES)	1.86 ± 7.03
M&M <i>dataset</i> (ED)	6.11 ± 11.17
M&M <i>dataset</i> Superresolución (ES)	-1.54 ± 5.29
M&M <i>dataset</i> Superresolución (ED)	-4.16 ± 4.44
Dataset de soporte (4 mm)	0.13 ± 6.18
Dataset de soporte (8 mm)	7.30 ± 11.57
M&M <i>dataset</i> Alineado (ES)	3.28 ± 8.33
M&M <i>dataset</i> Alineado (ED)	6.89 ± 10.44

En la Tabla 4 se muestra la diferencia de volumen entre el volumen tridimensional original y el volumen al cual se le aplicó la superresolución. Para el M&M *dataset*, se observa una diferencia de $1,86 \pm 7,03$ ml para la fase cardíaca de fin de sístole y de $6,11 \pm 11,17$ ml para la fase cardíaca fin de diástole. Por otro lado, para el caso del mismo *dataset* al cual se le aplicó superresolución sin realizar una reducción del número de cortes transversales, se obtuvieron diferencias de $-1,54 \pm 5,29$ ml para fin de sístole y $-4,16 \pm 4,44$ ml para fin de diástole. Al comparar estos dos conjuntos derivados del M&M *dataset*, se aprecia que, en el caso donde no se realizó una reducción del número de cortes, la diferencia de volumen es menor. Esto indica que una mayor cantidad de cortes transversales originales mejora la calidad de las imágenes reconstruidas y sus respectivas segmentaciones. Asimismo, se observa que en la fase de fin de diástole la diferencia de volúmenes es mayor, lo cual podría deberse a que en esta fase el volumen del ventrículo izquierdo alcanza su punto máximo. Para el *Dataset* de Soporte, se obtuvo una diferencia de $0,13 \pm 6,18$ ml para la versión con cortes de 4 mm y de $7,30 \pm 11,57$ ml para la versión de 8 mm, lo cual refuerza la observación de que una mayor cantidad de cortes transversales contribuye a mejorar la calidad de la segmentación del volumen tridimensional. Finalmente, para el M&M *dataset* al cual se le realizó alineación, se observó una diferencia de $3,28 \pm 8,33$ ml en la fase cardíaca de fin de sístole y de $6,89 \pm 10,44$ ml en la fase de fin de diástole. Estos valores, al igual que las métricas previamente expuestas, son levemente superiores, especialmente en la fase de fin de sístole, donde la diferencia incrementa aproximadamente al doble en comparación con el caso sin alineación.

A continuación, se realizará un análisis más detallado de las métricas cuantitativas, así como un análisis cualitativo para cada uno de los conjuntos de datos.

4.2.2. M&M dataset

El primer *dataset* al cual se le realizará la evaluación corresponde al M&M *dataset*, utilizando una reducción de cortes transversales (*downsampling*). En la Tabla 5 se presentan las métricas que describen el desempeño del modelo en este conjunto de datos. Los resultados obtenidos son: un MSE de $0,0036 \pm 0,0023$, un SSIM de $0,66 \pm 0,09$ y un PSNR de $25,59 \pm 3,17$ dB.

Tabla 5: Resultados de las métricas MSE, SSIM y PSNR en el M&M *dataset* realizando reducción de cortes transversales, incluyendo promedio, desviación estándar, valor mínimo y máximo.

Fuente: Elaboración Propia.

	Promedio	Desviación estándar	Mínimo	Máximo
MSE	0.0036	0.0023	0.0006	0.0108
SSIM	0.66	0.09	0.47	0.86
PSNR	25.59	3.17	20.20	32.34
Δ LV volumen ES	1.86	7.03	-14.46	15.86
Δ LV volumen ED	6.11	11.17	-16.59	36.87

En cuanto a las diferencias de volumen (ml) entre el volumen original y el volumen reconstruido tras la reconstrucción de cortes en la fase cardíaca de fin de sístole, se obtuvo un valor de $1,86 \pm 7,03$ ml. En la Figura 28 se presenta un gráfico de Bland-Altman que compara ambas muestras. Se observa que la mayoría de las diferencias se encuentran cercanas a cero, evidenciando una tendencia hacia valores positivos. Esto sugiere que los volúmenes predichos tienden a ser ligeramente inferiores a los volúmenes originales. Asimismo, se destaca que la mayoría de las diferencias se encuentran dentro de los límites de confianza del 95 % que se encuentran entre $-11,92$ ml y $15,65$ ml.




Figura 28: Gráfico de Bland-Altman entre el volumen original y el volumen obtenido mediante superresolución en el M&M dataset, utilizando una reducción de cortes transversales para la fase cardíaca de fin de sístole.

Fuente: Elaboración Propia.

En las Figuras 29 y 30 se presentan los casos con menor y mayor diferencia en el volumen ventricular izquierdo entre los respectivos volúmenes tridimensionales.

En el caso con menor diferencia, esta fue de 0,12 ml, indicando que el volumen ventricular original y el volumen predicho son extremadamente similares. Cabe destacar que este volumen tridimensional presenta únicamente cinco cortes transversales, lo cual implica que solo se generaron dos cortes nuevos mediante la superresolución, como se muestra en la Figura 29.

Por otro lado, en el caso con mayor diferencia, esta alcanzó los 15,86 ml, evidenciando que el volumen ventricular original es considerablemente mayor que el volumen predicho. Esta diferencia puede observarse en las segmentaciones de las vistas horizontal y vertical presentadas en la Figura 30, donde se aprecia que los cortes en los bordes del corazón no fueron correctamente segmentados por el modelo, lo que resultó en una reducción del volumen predicho en este caso.




Figura 29: Caso con menor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, utilizando reducción de cortes transversales en la fase cardíaca de fin de sístole. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 30: Caso con mayor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, utilizando reducción de cortes transversales en la fase cardíaca de fin de sístole. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 31: Gráfico de Bland-Altman entre el volumen original y el volumen obtenido mediante superresolución en el M&M dataset, utilizando una reducción de cortes transversales para la fase cardíaca de fin de diástole.

Fuente: Elaboración Propia.

En cuanto a las diferencias de volumen (ml) entre el volumen original y el volumen reconstruido tras la reconstrucción de cortes en la fase cardíaca de fin de diástole, se obtuvo un valor promedio de 6.11 ± 11.17 ml. En el gráfico de Bland-Altman mostrado en la Figura 31, se aprecia que la mayoría de las diferencias se encuentran próximas a cero. Sin embargo, la media de las diferencias es positiva, ya que existen múltiples casos en los cuales el volumen reconstruido es menor que el volumen original. La mayoría de las diferencias se encuentran dentro del intervalo de confianza del 95 %, comprendido entre -15.79 y 28.01 . Además, al comparar esta media con la correspondiente a la fase cardíaca de fin de sístole —fase en la cual los volúmenes ventriculares son menores debido a la contracción máxima del ventrículo izquierdo, se observa que la media de las diferencias en fin de diástole es mayor. Esto sugiere una posible relación entre el tamaño del volumen ventricular y la magnitud de las diferencias observadas.

En la Figura 32 se aprecia el caso con la menor diferencia de volumen entre el volumen tridimensional original y el reconstruido, siendo dicha diferencia de solo 0,23 ml. Tanto en las imágenes anatómicas como en las segmentaciones se observa una coincidencia muy alta, lográndose apreciar únicamente diferencias mínimas en la segmentación. Por otro lado, el

caso con la mayor diferencia de volumen, de 36,87 ml, se muestra en la Figura 33. En este caso, el volumen reconstruido es considerablemente menor que el original, lo cual puede apreciarse en el panel (b), donde múltiples cortes transversales carecen de segmentación. Al analizar las vistas con imágenes anatómicas, también se observan diferencias considerables, especialmente en los bordes de las estructuras cardiovasculares.




Figura 32: Caso con menor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, utilizando reducción de cortes transversales en la fase cardíaca de fin de diástole. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 33: Caso con mayor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, utilizando reducción de cortes transversales en la fase cardíaca de fin de diástole. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.

4.2.3. M&M dataset superresolución (sin downsample)




Figura 34: Gráfico de Bland-Altman entre el volumen original y el volumen obtenido mediante superresolución en el M&M dataset, para la fase cardíaca de fin de sístole.

Fuente: Elaboración Propia.

El segundo conjunto de datos corresponde al mismo M&M dataset evaluado anteriormente, pero en esta ocasión no se efectuó una reducción de cortes transversales, por lo que no se cuenta con un análisis cuantitativo de los resultados, a excepción del cálculo del volumen del ventrículo izquierdo. Para este, se obtuvo una diferencia de $-1,54 \pm 5,29$ ml en la fase cardíaca de fin de sístole y de $-4,16 \pm 4,44$ ml en la fase cardíaca de fin de diástole.

Primero se presentarán los resultados correspondientes a la fase cardíaca de fin de sístole. En la Figura 34 se muestra un gráfico de Bland-Altman con la diferencia en el volumen del ventrículo izquierdo entre el volumen tridimensional original y el volumen tridimensional al cual se le aplicó el modelo de superresolución. La diferencia media fue de $-1,54$ ml, indicando un sesgo sistemático leve en el cual el modelo tiende a sobreestimar ligeramente los volúmenes. Los límites de confianza se ubicaron entre $-11,94$ ml y $+8,82$ ml, mostrando una dispersión moderada. No se observa una tendencia clara de sesgo proporcional, lo que indica una buena concordancia general entre los volúmenes originales y los predichos.




Figura 35: Caso con menor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, en la fase cardíaca de fin de sístole. Se muestra el volumen de referencia antes de aplicar superresolución (a) y el volumen obtenido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.

En las Figuras 35 y 36 se presentan los casos con menor y mayor diferencia en el volumen del ventrículo izquierdo entre el volumen tridimensional original y el volumen predicho, respectivamente. En el caso con la menor diferencia, esta fue de $+0,03$ ml. Al observar las vistas horizontales y verticales de la segmentación, se aprecia que son prácticamente idénticas. Por otro lado, en las vistas horizontales y verticales anatómicas se observa una mejora en la calidad de imagen, logrando suavizar las estructuras cardiovasculares y aumentando su definición. Finalmente, en el caso con la mayor diferencia de volumen del ventrículo izquierdo, esta fue de $+13,45$ ml, lo que indica que el volumen tras la superresolución fue menor que el volumen original. Como se puede observar en las vistas horizontales y verticales de la segmentación, algunos cortes transversales en el centro del corazón no lograron ser segmentados completamente. No obstante, en las vistas anatómicas tanto horizontales como verticales se aprecia una alta similitud entre las estructuras reconstruidas.




Figura 36: Caso con mayor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, en la fase cardíaca de fin de sístole. Se muestra el volumen de referencia antes de aplicar superresolución (a) y el volumen obtenido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 37: Gráfico de Bland-Altman entre el volumen original y el volumen obtenido mediante superresolución en el M&M *dataset*, para la fase cardíaca de fin de diástole

Fuente: Elaboración Propia.

Continuando con la fase cardíaca de fin de diástole, en la Figura 37 se muestra un gráfico Bland-Altman con las diferencias de volumen del ventrículo izquierdo entre el volumen tridimensional original y el volumen tridimensional al cual se le aplicó la superresolución. En este caso, la media de las diferencias fue de $-4,16$ ml, indicando una ligera sobreestimación sistemática del volumen por parte del método de superresolución. Los límites de confianza del 95 % se encuentran entre $-12,87$ ml y $4,55$ ml. La mayoría de los puntos se distribuyen dentro de estos límites, lo que sugiere un buen nivel de concordancia entre ambas mediciones. Además, no se observa una tendencia de aumento o disminución de la diferencia en función del tamaño del volumen promedio, al igual que en la fase cardíaca de fin de sístole.

En la Figura 38 se presenta el caso con la menor diferencia en el volumen, la cual fue de $-0,30$ ml. En las vistas horizontales y verticales de la segmentación se aprecia una mejora en el nivel de detalle, lo cual también es evidente en las imágenes anatómicas. En la imagen frontal, únicamente se observan diferencias en estructuras pequeñas del corazón y en algunas estructuras fuera del mismo. Por otro lado, en la Figura 39 se presenta el caso con la mayor diferencia de volumen de este conjunto de datos, con una diferencia de $-18,27$ ml. Esto implica que el volumen predicho es mayor que el original. En las segmentaciones de las vistas horizontales y verticales en el panel (b), se observa que cortes en los costados fueron segmentados. Además, en las vistas anatómicas la calidad de la reconstrucción es buena, logrando capturar pequeños detalles; por lo tanto, el cambio en el volumen puede atribuirse principalmente a errores del modelo de segmentación.




Figura 38: Caso con menor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, en la fase cardíaca de fin de diástole. Se muestra el volumen de referencia antes de aplicar superresolución (a) y el volumen obtenido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 39: Caso con mayor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, en la fase cardíaca de fin de diástole. Se muestra el volumen de referencia antes de aplicar superresolución (a) y el volumen obtenido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.

4.2.4. Dataset de Soporte (Grosor de corte transversal 4 mm)

El tercer conjunto de datos evaluado corresponde al Dataset de Soporte con un grosor de corte transversal de 4 mm. Cabe destacar que, al igual que en el primer conjunto de datos evaluado, se realizó una reducción de cortes transversales con el objetivo de obtener métricas cuantitativas.

En la Tabla 6 se presentan los resultados de las métricas correspondientes para este conjunto de datos. Se obtuvo un MSE de $0,0013 \pm 0,0005$, un SSIM de $0,85 \pm 0,03$, un PSNR de $29,54 \pm 1,88$ dB, y, por último, una diferencia de volumen del ventrículo izquierdo de $0,13 \pm 6,18$ ml

Tabla 6: Resultados de las métricas MSE, SSIM, PSNR y diferencia de volumen del ventrículo izquierdo en el *dataset* de soporte con grosor de corte transversal de 4 milímetros realizando reducción de cortes transversales, incluyendo promedio, desviación estándar, valor mínimo y máximo.

Fuente: Elaboración Propia.

	Promedio	Desviación estándar	Mínimo	Máximo
MSE	0.0013	0.0005	0.0003	0.0029
SSIM	0.85	0.03	0.78	0.91
PSNR	29.54	1.88	25.71	34.90
Δ LV volumen	0.13	6.18	-18.28	15.98

En la Figura 40 se muestra un gráfico de Bland-Altman con las diferencias de volumen del ventrículo izquierdo entre el volumen tridimensional original y el reconstruido utilizando el modelo de superresolución. Como se mencionó previamente, la media de la diferencia es de $+0,13$ ml, lo cual indica un sesgo sistemático mínimo. Los límites de confianza del 95 % se encuentran entre $-11,79$ ml y $+12,05$ ml. La mayoría de las diferencias se ubican dentro de estos límites, lo que sugiere una buena concordancia entre las mediciones. No se observa una tendencia clara a lo largo del rango de promedios de volumen, indicando que los errores son homocedásticos.




Figura 40: Gráfico de Bland-Altman entre el volumen original y el volumen obtenido mediante superresolución en el *dataset* de soporte con grosor de corte transversal de 4 milímetros realizando reducción de cortes transversales.

Fuente: Elaboración Propia.

En la Figura 41 se muestra el caso con la menor diferencia entre los volúmenes del ventrículo izquierdo, correspondiente a $-0,04$ ml. Se puede observar que las segmentaciones entre el volumen original y el reconstruido son extremadamente similares, y en cuanto a las imágenes anatómicas, se aprecian leves diferencias en estructuras anatómicas pequeñas dentro del corazón.

Por otro lado, el caso con la mayor diferencia se muestra en la Figura 42, presentando una diferencia de $-18,28$ ml, lo cual indica que el volumen de la reconstrucción es mayor que el volumen original. Esto se puede observar en el panel (b), donde en la vista vertical se aprecian errores de segmentación en zonas cercanas al ápex del corazón, mientras que en la imagen horizontal se detecta la segmentación de un corte adicional. Al igual que en el caso con la menor diferencia, las discrepancias anatómicas son mínimas.




Figura 41: Caso con menor diferencia en el volumen del ventrículo izquierdo en el *Dataset* de soporte, utilizando cortes de 4 milímetros de grosor. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 42: Caso con mayor diferencia en el volumen del ventrículo izquierdo en el *Dataset* de soporte, utilizando cortes de 4 milímetros de grosor. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.

4.2.5. Dataset de Soporte (Grosor de corte transversal 8 mm)

El cuarto y último conjunto de datos a evaluar corresponde al *Dataset* de Soporte con un grosor de corte transversal de 8 mm. Al igual que en su versión de 4 mm, a este también se le realizó una reducción de cortes transversales para poder evaluar mediante métricas cuantitativas.

En la Tabla 7 se presentan las métricas obtenidas, donde se reportan los siguientes resultados: un MSE de $0,0025 \pm 0,0009$, un SSIM de $0,80 \pm 0,05$, un PSNR de $26,81 \pm 1,92$ dB, y una diferencia en el volumen del ventrículo izquierdo de $7,31 \pm 11,77$ ml.

Tabla 7: Resultados de las métricas MSE, SSIM y PSNR en el *Dataset* de soporte con grosor de corte transversal de 8 milímetros realizando reducción de cortes transversales, incluyendo promedio, desviación estándar, valor mínimo y máximo.

Fuente: Elaboración Propia.

	Promedio	Desviación estándar	Mínimo	Máximo
MSE	0.0025	0.0009	0.0006	0.0051
SSIM	0.80	0.05	0.66	0.90
PSNR	26.81	1.92	23.31	32.40
Δ LV volumen	7.31	11.77	-12.78	36.12

En la Figura 43 se presenta un gráfico de Bland-Altman con las diferencias de volumen del ventrículo izquierdo entre el volumen tridimensional original y el volumen tridimensional reconstruido utilizando el modelo de superresolución. La diferencia media fue de $+7,31$ ml, lo cual indica la presencia de un sesgo sistemático que tiende a subestimar los volúmenes. Los límites de confianza del 95 % se encuentran entre $-15,38$ ml y $30,00$ ml, mostrando una mayor dispersión en comparación con la versión de 4 mm de este conjunto de datos. Además, se observa una tendencia ascendente en las diferencias a medida que aumenta el volumen promedio, lo que sugiere la existencia de un sesgo proporcional.




Figura 43: Gráfico de Bland-Altman entre el volumen original y el volumen obtenido mediante superresolución en el *Dataset* de soporte con grosor de corte transversal de 8 milímetros realizando reducción de cortes transversales.

Fuente: Elaboración Propia.

En las Figuras 44 y 45 se muestran los casos con menor y mayor diferencia de volumen del ventrículo izquierdo, respectivamente. En el caso con la menor diferencia, esta es de $-0,94$ ml. Al comparar las segmentaciones en las vistas horizontales y verticales, tanto de la segmentación como de las imágenes anatómicas, en los paneles (a) y (b) de la Figura 44, se aprecia que son bastante similares; solo se visualizan diferencias en pequeños elementos dentro del corazón en las vistas anatómicas. El caso con la mayor diferencia corresponde a $+36,12$ ml, lo cual indica que el volumen reconstruido es menor que el original. Esto se puede notar claramente en el panel (b) de la Figura 45, donde tanto en la segmentación de las vistas horizontal y vertical se aprecian cortes sin segmentación en los costados del corazón, a pesar de que las imágenes anatómicas de estas vistas se reconstruyen con buena calidad.




Figura 44: Caso con menor diferencia en el volumen del ventrículo izquierdo en el *Dataset* de soporte, utilizando cortes de 8 milímetros de grosor. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 45: Caso con mayor diferencia en el volumen del ventrículo izquierdo en el *Dataset* de soporte, utilizando cortes de 8 milímetros de grosor. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.

4.2.6. M&M dataset Alineado

La quinta evaluación corresponde al M&M *dataset* al cual se le aplicó un método de alineación utilizando el centro de masa con vistas horizontales y verticales, seguido de una reducción de cortes transversales. En la Tabla 8 se presentan las métricas de rendimiento del modelo en este conjunto de datos. Los resultados obtenidos corresponden a un MSE de $0,042 \pm 0,0026$, un SSIM de $0,65 \pm 0,10$ y un PSNR de $24,98 \pm 3,20$ dB.

Tabla 8: Resultados de las métricas MSE, SSIM y PSNR en el M&M *dataset* alineado realizando reducción de cortes transversales, incluyendo promedio, desviación estándar, valor mínimo y máximo.

Fuente: Elaboración Propia.

	Promedio	Desviación estándar	Mínimo	Máximo
MSE	0.0042	0.0026	0.0007	0.0106
SSIM	0.65	0.10	0.46	0.86
PSNR	24.98	3.20	20.08	31.83
Δ LV volumen ES	3.28	8.33	-18.33	30.13
Δ LV volumen ED	6.89	10.44	-8.07	41.05




Figura 46: Gráfico de Bland-Altman entre el volumen original alineado y el volumen obtenido mediante superresolución en el M&M *dataset*, utilizando una reducción de cortes transversales para la fase cardíaca de fin de sístole.

Fuente: Elaboración Propia.

En cuanto a la diferencia de volumen del ventrículo izquierdo entre el volumen original y la reconstrucción para la fase cardíaca de fin de sístole, esta fue de $3,28 \pm 8,33$ ml. En la Figura 46 se muestra un gráfico de Bland-Altman, en el cual la media, como se mencionó previamente, presenta un leve sesgo positivo. Los límites de confianza del 95 % se encuentran entre $-12,80$ ml y $19,35$ ml, dentro de los cuales se ubica la mayoría de los datos. No se observa una tendencia clara en las diferencias en función del tamaño del volumen.

En las Figuras 47 y 48 se muestran los casos con menor y mayor diferencia de volumen (ml) en el ventrículo izquierdo para el M&M *dataset*, al cual no se le realizó un alineamiento previo a la reducción de cortes transversales.




Figura 47: Caso con menor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, obtenido previamente y al cual ahora se le aplicó alineación, utilizando reducción de cortes transversales en la fase cardíaca de fin de sístole. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.

El caso con menor diferencia presentó un valor de $1,38$ ml, lo que indica una alta similitud con el volumen original, al igual que en el caso sin alineamiento. Al observar las vistas anatómicas horizontal y vertical, se pueden apreciar diferencias muy ligeras, lo cual concuerda con la pequeña diferencia de volumen observada.

Por otro lado, el caso con mayor diferencia de volumen del ventrículo izquierdo entre el volumen original y el reconstruido se muestra en la Figura 48. Esta diferencia fue de $17,80$ ml, lo cual continúa la tendencia observada en la versión sin alineamiento, incrementándose en aproximadamente 2 ml. A pesar de esta diferencia, en las vistas anatómicas frontal, horizontal y vertical, las imágenes resultan bastante similares, observándose incluso un suavizado en los bordes entre el ventrículo izquierdo y el miocardio. Sin embargo, en la segmentación del volumen reconstruido no se logró identificar correctamente algunos cortes transversales en los extremos del corazón, lo cual explica la discrepancia observada en el volumen del ventrículo izquierdo.




Figura 48: Caso con mayor diferencia en el volumen del ventrículo izquierdo en el M&M *dataset*, obtenido previamente y al cual ahora se le aplicó alineación, utilizando reducción de cortes transversales en la fase cardíaca de fin de sístole. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 49: Gráfico de Bland-Altman entre el volumen original alineado y el volumen obtenido mediante superresolución en el M&M *dataset*, utilizando una reducción de cortes transversales para la fase cardíaca de fin de diástole.

Fuente: Elaboración Propia.

Para la fase cardíaca de fin de diástole se obtuvo una diferencia de volúmenes del ventrículo izquierdo de $6,89 \pm 10,44$ ml, lo cual se puede apreciar en el gráfico de Bland-Altman mostrado en la Figura 49. Esta diferencia indica un sesgo positivo más evidente en comparación con la fase cardíaca de fin de sístole, reflejando una tendencia a subestimar el volumen reconstruido. Los límites del 95 % de confianza se ubicaron entre $-13,26$ ml y $27,03$ ml, mostrando una dispersión considerable en las diferencias, especialmente para los volúmenes mayores. Aunque la mayoría de los puntos se encuentran dentro de estos límites, se observaron algunos valores atípicos con diferencias marcadas.

En las Figuras 50 y 51 se presentan los casos con menor y mayor diferencia de volumen del ventrículo izquierdo correspondientes a la versión del M&M dataset al cual no se le realizó alineamiento previo a la reducción de cortes transversales.

Para el caso con menor diferencia, esta fue de $0,03$ ml. Como se aprecia en las imágenes horizontales y verticales, tanto anatómicas como de segmentación, ambas versiones son prácticamente idénticas. En la vista frontal se pueden notar diferencias mínimas en estructuras externas al corazón, que no afectan significativamente la calidad de la reconstrucción.

Por otro lado, en el caso con mayor diferencia, esta fue de $23,01$ ml. Como se observa en la segmentación, al igual que en casos anteriores, los cortes cercanos a los bordes del corazón no lograron ser segmentados completamente, lo cual explica en gran parte esta diferencia. En las imágenes anatómicas horizontales y verticales se aprecia una buena similitud general, aunque también se observan discrepancias localizadas, especialmente en el miocardio. En la vista frontal se evidencian diferencias considerables tanto en estructuras extracardíacas como intracardíacas.




Figura 50: Caso con menor diferencia en el volumen del ventrículo izquierdo en el M&M dataset, obtenido previamente y al cual ahora se le aplicó alineación, utilizando reducción de cortes transversales en la fase cardíaca de fin de diástole. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.




Figura 51: Caso con mayor diferencia en el volumen del ventrículo izquierdo en el M&M dataset, obtenido previamente y al cual ahora se le aplicó alineación, utilizando reducción de cortes transversales en la fase cardíaca de fin de diástole. Se muestra el volumen de referencia antes de aplicar *downsampling* (a) y el volumen reconstruido tras aplicar el modelo de superresolución (b).

Fuente: Elaboración Propia.

CAPÍTULO 5

CONCLUSIONES

5.1. Conclusiones Generales

En este trabajo se abordó el problema de la baja calidad y la desalineación de imágenes de resonancias magnéticas cardiovasculares (CMR) de eje corto. Estas limitaciones implican una pérdida de tiempo, ya que los especialistas deben alinear manualmente los volúmenes, y además dificultan la realización de diagnósticos precisos y eficaces debido a la escasa calidad de las imágenes.

Como propuesta de solución, se estudiaron cuatro métodos de alineamiento: centro de masa con vistas horizontal y vertical, correlación cruzada con vistas horizontal y vertical, centro de masa con vistas de cuatro cámaras, y correlación cruzada con vista de cuatro cámaras. Adicionalmente, se implementó un algoritmo de inteligencia artificial, específicamente un modelo de *deep learning* inspirado en la arquitectura U-Net, para la generación de cortes transversales intermedios a partir de dos cortes contiguos. Este modelo fue entrenado utilizando un conjunto de datos derivado del M&M *dataset*.

Los resultados muestran una gran calidad tanto en la alineación como en la superresolución de los cortes transversales. En el caso de la alineación, se logró una mejor representación anatómica sin necesidad de intervención manual, mientras que el modelo de superresolución logró generar cortes coherentes y anatómicamente consistentes, incluso en regiones complejas del corazón. Las métricas cuantitativas y los análisis cualitativos evidenciaron que las soluciones propuestas pueden mejorar significativamente la calidad del volumen reconstruido, reduciendo errores y preservando características anatómicas clave para el diagnóstico.

Este trabajo contribuye al avance en el campo de la mejora de CMR de eje corto, logrando una mejora significativa en la calidad de las imágenes reconstruidas. Con la continua evolución de los modelos de *deep learning*, el aumento de la capacidad computacional y la disponibilidad de mayores volúmenes de datos, es posible perfeccionar las técnicas presentadas aquí y llevarlas eventualmente a aplicaciones clínicas reales.

5.2. Limitaciones

A pesar de la buena calidad de los resultados obtenidos, las soluciones propuestas presentan algunas limitaciones. En cuanto a la alineación, al depender de un modelo de segmentación previo para obtener los centros de masa del ventrículo izquierdo y del miocardio, esta se vuelve sensible al ruido o a errores en dicha segmentación. Esto puede provocar que el

cálculo de desplazamientos sea impreciso o incluso completamente erróneo, afectando negativamente la coherencia del volumen final. Por otro lado, el modelo de superresolución se basa únicamente en dos cortes transversales consecutivos para generar los cortes intermedios. Esta limitación implica una falta de contexto espacial más amplio, dificultando la preservación de la continuidad anatómica en regiones complejas. Además, el modelo no incorpora información de otras fases cardíacas, lo que podría aportar una representación más dinámica y coherente del movimiento cardíaco, especialmente útil en estudios funcionales.

5.3. Cumplimiento de Objetivos

En este trabajo se implementaron un algoritmo de alineación y un modelo de superresolución para resonancias magnéticas cardíacas de eje corto. Estas soluciones permiten abordar el problema de desalineación entre cortes transversales (Capítulo 3.3), logrando representar de forma más realista los volúmenes tridimensionales.

Las metodologías implementadas permiten abordar el problema principal desde sus causas fundamentales, cumpliendo tanto el objetivo general como los objetivos específicos propuestos.

5.3.1. Objetivos

1. **Implementar uno o múltiples métodos para alinear imágenes de eje corto del corazón obtenidas en resonancias magnéticas cardiovasculares, permitiendo una mejor visualización de estructuras anatómicas y patológicas:** Este objetivo fue alcanzado mediante la implementación de cuatro métodos de alineación (Capítulo 3.3). Estos permitieron corregir la desalineación entre cortes transversales, mejorando la coherencia anatómica del volumen. El método basado en el centro de masa con vista de horizontal y vertical destacó por su desempeño, validado tanto en el M&M *dataset* como en un conjunto de datos de soporte con desalineación artificial.
2. **Implementar uno o múltiples algoritmos para aumentar la cantidad de imágenes transversales en resonancias magnéticas cardiovasculares:** Este objetivo fue alcanzado mediante la implementación de un algoritmo de superresolución de imágenes utilizando redes neuronales convolucionales (Capítulo 3.5). Se llevó a cabo un análisis exhaustivo de arquitecturas de generación de imágenes, logrando desarrollar un modelo capaz de manejar la complejidad de las estructuras cardíacas, así como las variaciones asociadas al tipo de máquina de resonancia magnética o a las características del paciente.
3. **Validar la precisión de los métodos de superresolución y alineamiento realizando pruebas experimentales para evaluar la precisión y la calidad de las imágenes generadas:** Tanto la alineación como la superresolución fueron validadas utilizando como base el M&M *dataset*, que constituye el enfoque principal de este trabajo. Además, con el objetivo de aumentar la robustez del análisis, se evaluaron múltiples variaciones de este conjunto de datos. Por otro lado, se empleó un conjunto de datos adicional, denominado *Dataset de Soporte*, lo que permitió fortalecer aún más el análisis de los resultados (Capítulo 4).

Para validar el desempeño de los métodos de alineación se realizó un análisis cualitativo, mientras que el modelo de superresolución fue evaluado tanto cualitativa como cuantitativamente utilizando métricas estandarizadas como el MSE, SSIM y PSNR.

5.4. Trabajo Futuro

A partir del desarrollo realizado en este trabajo y los resultados alcanzados, se proponen las siguientes líneas de investigación futura con potencial de mejora.

- **Estudio de técnicas de alineamiento más complejas:** En este trabajo se utilizaron técnicas de alineamiento relativamente simples. Por lo tanto, podrían explorarse métodos más sofisticados, como algoritmos de registro de imágenes o enfoques basados en modelos de *deep learning*, que podrían mejorar la precisión del alineamiento.
- **Combinación de técnicas de alineamiento estudiadas:** Para aumentar la robustez de las técnicas empleadas, podría explorarse la combinación simultánea de múltiples vistas (horizontal, vertical y de cuatro cámaras), lo cual podría aportar información complementaria y mejorar los resultados de alineación.
- **Implementación de una red neuronal convolucional más compleja:** Debido a limitaciones computacionales, se optó por una arquitectura más ligera. Sin embargo, con acceso a recursos computacionales más avanzados, se podrían emplear arquitecturas más complejas como GANs (*Generative Adversarial Networks*), *Transformers* u otros modelos de última generación para mejorar la calidad de reconstrucción.
- **Extensión del modelo a tres dimensiones:** En este trabajo se abordó la superresolución de forma bidimensional. Una línea futura de investigación sería implementar un modelo de superresolución 3D que procese directamente los volúmenes completos, lo cual podría capturar mejor las relaciones espaciales entre cortes y mejorar la coherencia anatómica global.

REFERENCIAS BIBLIOGRÁFICAS

- [Bogaert et al., 2012] Bogaert, J., Dymarkowski, S., Taylor, A. M., y Muthurangu, V. (2012). *Clinical cardiac MRI*. Springer Science & Business Media.
- [Campello et al., 2021] Campello, V., Gkontra, P., Izquierdo, C., Martin-Isla, C., Sojoudi, A., Full, P., Maier-Hein, K., Zhang, Y., He, Z., Ma, J., Parreño Lara, M., Albiol, A., Kong, F., Shadden, S., Acero, J., Sundaresan, V., Saber, M., Elattar, M., Li, H., y Lekadir, K. (2021). Multi-centre, multi-vendor and multi-disease cardiac segmentation: The mms challenge. *IEEE Transactions on Medical Imaging*, PP:1–1.
- [Chandler et al., 2008] Chandler, A. G., Pinder, R. J., Netsch, T., Schnabel, J. A., Hawkes, D. J., Hill, D. L., y Razavi, R. (2008). Correction of misaligned slices in multi-slice cardiovascular magnetic resonance using slice-to-volume registration. *Journal of cardiovascular magnetic resonance*, 10(1):13.
- [Chen et al., 2020] Chen, C., Qin, C., Qiu, H., Tarroni, G., Duan, J., Bai, W., y Rueckert, D. (2020). Deep learning for cardiac image segmentation: a review. *Frontiers in cardiovascular medicine*, 7:25.
- [Dangi et al., 2018] Dangi, S., Yaniv, Z., y Linte, C. (2018). Cine cardiac mri slice misalignment correction towards full 3d left ventricle segmentation. *Proceedings of SPIE—the International Society for Optical Engineering*, 10576:6.
- [Full et al., 2021] Full, P. M., Isensee, F., Jäger, P. F., y Maier-Hein, K. (2021). Studying robustness of semantic segmentation under domain shift in cardiac mri. En *Statistical Atlases and Computational Models of the Heart. M&Ms and EMIDEC Challenges: 11th International Workshop, STACOM 2020, Held in Conjunction with MICCAI 2020, Lima, Peru, October 4, 2020, Revised Selected Papers 11*, pp. 238–249. Springer.
- [Grothues et al., 2002] Grothues, F., Smith, G., y Moon, J. (2002). Comparison of interstudy reproducibility of cardiovascular magnetic resonance with two-dimensional echocardiography in normal subjects and in patients with heart failure or left ventricular hypertrophy. *ACC Current Journal Review*, 11.
- [He et al., 2016] He, K., Zhang, X., Ren, S., y Sun, J. (2016). Deep residual learning for image recognition. En *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778.
- [Hinton, 2012] Hinton, G. (2012). Lecture 6e. Coursera: Neural Networks for Machine Learning. Retrieved from https://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf.
- [Hu et al., 2023] Hu, X., Sheng, G., Zhang, D., y Li, L. (2023). A novel residual block: replace conv1×1 with conv3×3 and stack more convolutions. *PeerJ Computer Science*, 9:e1302.

- [Iles *et al.*, 2008] Iles, L., Pfluger, H., Phrommintikul, A., Cherayath, J., Aksit, P., Gupta, S. N., Kaye, D. M., y Taylor, A. J. (2008). Evaluation of diffuse myocardial fibrosis in heart failure with cardiac magnetic resonance contrast-enhanced t1 mapping. *Journal of the American College of Cardiology*, 52(19):1574–1580.
- [Isensee *et al.*, 2021] Isensee, F., Jaeger, P. F., Kohl, S. A., Petersen, J., y Maier-Hein, K. H. (2021). nnu-net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature methods*, 18(2):203–211.
- [Jackson *et al.*, 2007] Jackson, E., Bellenger, N., Seddon, M., Harden, S., y Peebles, C. (2007). Ischaemic and non-ischaemic cardiomyopathies—cardiac mri appearances with delayed enhancement. *Clinical radiology*, 62(5):395–403.
- [Jang *et al.*, 2018] Jang, Y., Hong, Y., Ha, S., Kim, S., y Chang, H.-J. (2018). Automatic segmentation of lv and rv in cardiac mri. En *Statistical Atlases and Computational Models of the Heart. ACDC and MMWHS Challenges: 8th International Workshop, STACOM 2017, Held in Conjunction with MICCAI 2017, Quebec City, Canada, September 10-14, 2017, Revised Selected Papers 8*, pp. 161–169. Springer.
- [Jerosch-Herold, 2010] Jerosch-Herold, M. (2010). Quantification of myocardial perfusion by cardiovascular magnetic resonance. *Journal of Cardiovascular Magnetic Resonance*, 12(1):57.
- [Kingma, 2014] Kingma, D. P. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [Kokhanovskiy *et al.*, 2025] Kokhanovskiy, I., Passi, C. A. C., Crabb, M., Kunze, K. P., Karampinos, D., Makowski, M. R., Prieto, C., y Botnar, R. (2025). High-resolution anatomical bright-and black-blood whole-heart mri with joint t1/t2 myocardial tissue mapping at 0.55 t. *Journal of Cardiovascular Magnetic Resonance*, 27.
- [Leong *et al.*, 2010] Leong, D. P., De Pasquale, C. G., y Selvanayagam, J. B. (2010). Heart failure with normal ejection fraction: the complementary roles of echocardiography and cmr imaging. *JACC: Cardiovascular Imaging*, 3(4):409–420.
- [León *et al.*, 2023] León, M., Herrera, R., Urbina, J., Salas, R., Uribe, S., y Sotelo, J. (2023). Ventseg: efficient open source framework for ventricular segmentation. *International Symposium on Medical Information Processing and Analysis*, p. 30.
- [Nitta *et al.*, 2013] Nitta, S., Takeguchi, T., Matsumoto, N., Kuhara, S., Yokoyama, K., Ishimura, R., y Nitatori, T. (2013). Automatic slice alignment method for cardiac magnetic resonance imaging. *Magnetic Resonance Materials in Physics, Biology and Medicine*, 26:451–461.
- [Pennell, 2005] Pennell, D. J. (2005). T2* magnetic resonance and myocardial iron in thalassemia. *Annals of the New York Academy of Sciences*, 1054(1):373–378.

- [Ronneberger et al., 2015] Ronneberger, O., Fischer, P., y Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. En *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III* 18, pp. 234–241. Springer.
- [Rumelhart et al., 1986] Rumelhart, D. E., Hinton, G. E., y Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088):533–536.
- [Russakovsky et al., 2015] Russakovsky, Olga and Deng, Jia and Su, Hao and Krause, Jonathan and Satheesh, Sanjeev and Ma, Sean and Huang, Zhiheng and Karpathy, Andrej and Khosla, Aditya and Bernstein, Michael and others (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115:211–252.
- [Simonyan, 2014] Simonyan, K. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [Tseng et al., 2016] Tseng, W.-Y., Su, M.-Y., y Tseng, Y.-H. (2016). Introduction to cardiovascular magnetic resonance: Technical principles and clinical applications. *Acta Cardiologica Sinica*, 32:129–44.
- [Ur Rahman y Wesarg, 2010] Ur Rahman, S. y Wesarg, S. (2010). Combining short-axis and long-axis cardiac mr images by applying a super-resolution reconstruction algorithm. *Fraunhofer IGD*, 7623.
- [Villard et al., 2017] Villard, B., Zacur, E., Dall'Armellina, E., y Grau, V. (2017). Correction of slice misalignment in multi-breath-hold cardiac mri scans. En *Statistical Atlases and Computational Models of the Heart. Imaging and Modelling Challenges: 7th International Workshop, STACOM 2016, Held in Conjunction with MICCAI 2016, Athens, Greece, October 17, 2016, Revised Selected Papers* 7, pp. 30–38. Springer.
- [Wan et al., 2016] Wan, M., Huang, W., Zhang, J.-M., Zhao, X., Allen, J. C., Tan, R. S., Wan, X., y Zhong, L. (2016). Correcting motion in multiplanar cardiac magnetic resonance images. *Biomedical engineering online*, 15:1–16.
- [Yu et al., 2006] Yu, H.-Y., Peng, H.-H., Wang, J.-L., Wen, C.-Y., y Tseng, W.-Y. I. (2006). Quantification of the pulse wave velocity of the descending aorta using axial velocity profiles from phase-contrast magnetic resonance imaging. *Magnetic Resonance in Medicine: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 56(4):876–883.
- [Zhang et al., 2018] Zhang, R., Isola, P., Efros, A. A., Shechtman, E., y Wang, O. (2018). The unreasonable effectiveness of deep features as a perceptual metric. En *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 586–595.
- [Zhang et al., 2021] Zhang, Y., Yang, J., Hou, F., Liu, Y., Wang, Y., Tian, J., Zhong, C., Zhang, Y., y He, Z. (2021). Semi-supervised cardiac image segmentation via label propagation and style transfer. En *Statistical Atlases and Computational Models of the Heart. M&Ms and EMIDEC Challenges: 11th International Workshop, STACOM 2020, Held in Conjunction*

with MICCAI 2020, Lima, Peru, October 4, 2020, Revised Selected Papers 11, pp. 219–227.
Springer.