



INAOE

Clasificación de imágenes de flujo sanguíneo en aorta con CFD y redes neuronales convolucionales.

Por:

Lic. Edgar Omar Martínez Jiménez

Tesis sometida como requisito
para obtener el grado de:

MAESTRO EN CIENCIAS Y TECNOLOGÍAS BIOMÉDICAS

en el

**Instituto Nacional de Astrofísica,
Óptica y Electrónica**

Agosto, 2025

Tonantzintla, Puebla

Dirigida por:

Dra. Raquel Díaz Hernández

©INAOE 2025

Derechos Reservados

El autor otorga al INAOE el permiso de reproducir
y distribuir copia de esta tesis en su totalidad o en
partes mencionando la fuente



Índice general

1. Introducción	1
1.1. Planteamiento del problema	2
1.2. Objetivos	3
1.2.1. Objetivo general	3
1.2.2. Objetivos específicos	3
1.3. Aportación	3
1.4. Organización de la tesis	4
2. Marco teórico	6
2.1. Anatomía de la aorta	6
2.1.1. Coartación de la aorta	8
2.1.2. Síndrome de Marfan	9
2.2. Dinámica de fluidos computacional (CFD)	10

2.3. Visualización	12
2.4. Redes neuronales convolucionales	13
2.5. Clasificación de imágenes	14
2.6. Matriz de confusión	15
2.6.1. Métricas de evaluación	16
3. Trabajo relacionado	18
3.1. Simulación de flujo en aorta	18
3.1.1. Discusión	22
3.2. Simulación de flujo en otras anatomías	22
3.2.1. Discusión	25
4. Método propuesto	28
4.1. Esquema general	28
4.2. Simulación	29
4.2.1. Base de datos (modelos)	29
4.2.2. Ajuste de parámetros de simulación	30
4.2.3. Resultados numéricos	33
4.3. Visualización	33
5. Experimentos y Resultados	37
5.1. Base de datos (imágenes)	37

5.2. Experimentos	38
5.3. Resultados	40
5.3.1. Red Compact	41
5.3.2. Red Enhanced	41
5.3.3. Red ResNet-50	42
5.3.4. Red ResNet-18	43
5.3.5. Red MobileNetV2	44
5.3.6. Red AlexNet	45
5.3.7. Matriz de confusión	46
5.4. Discusión de resultados	50
6. Conclusiones y Trabajo futuro	51
6.1. Conclusiones	51
6.2. Trabajo futuro	52
Referencias	52
A. Artículos publicados	58

Lista de Figuras

2.1. Divisiones anatómicas de la aorta: raíz aórtica aorta ascendente, arco aórtico y aorta torácica descendente. Fuente de la imagen: Pellón (2020).	7
2.2. Imagen obtenida mediante resonancia magnética que muestra una coartación de la aorta. Fuente: Wilson et al. (2013).	8
2.3. Imagen obtenida mediante resonancia magnética que muestra una dilatación de aorta de un paciente con síndrome de Marfan. Fuente: Wilson et al. (2013).	10
4.1. Esquema general del método propuesto. El esquema gráfico de la CNN corresponde a la arquitectura ResNet-18 utilizada en este experimento. Ramzan et al. (2020)	29
4.2. A) Ejemplo de un instante de flujo simulado del modelo "0008_H_AO_H". B) Visualización con una rotación de 90°. C) Visualización con una rotación de 180°. D) Visualización con una rotación de 270°.	34
4.3. A) Ejemplo de un instante de flujo simulado del modelo "0013_H_AO_COA". B) Visualización con una rotación de 90°. C) Visualización con una rotación de 180°. D) Visualización con una rotación de 270°.	35

4.4.	A) Ejemplo de un instante de flujo simulado del modelo "0021_H_AO_MFS". B) Visualización con una rotación de 90°. C) Visualización con una rotación de 180°. D) Visualización con una rotación de 270°.	36
5.1.	Matriz de confusión de la arquitectura Compact del entrenamiento uno.	47
5.2.	Matriz de confusión de la arquitectura ResNet-50 del entrenamiento uno.	49

Lista de Tablas

3.1. Comparación de trabajos relacionados con la presente tesis	26
4.1. Datos de los modelos utilizados	30
4.2. Parámetros de configuración de la simulación para modelos sanos, CoA y MFS	32
5.1. Cantidad de imágenes por modelo y resolución	38
5.2. Resultados Red Compact	41
5.3. Resultados Red Enhanced	42
5.4. Resultados Red ResNet-50	43
5.5. Resultados Red ResNet-18	44
5.6. Resultados Red MobileNetV2	45
5.7. Resultados Red AlexNet	46

Agradecimientos

En primer lugar, deseo expresar mi más sincero agradecimiento a mi asesora, la Dra. Raquel Díaz Hernández, por su guía, paciencia y dedicación a lo largo de este trabajo. Su compromiso académico, sus valiosas observaciones y su constante apoyo fueron fundamentales para el desarrollo de esta tesis. Gracias por motivarme a superar mis límites y por enseñarme con su ejemplo el valor del esfuerzo y la disciplina en la investigación.

A mi pareja Miriam, por estar siempre a mi lado, por su paciencia infinita, por creer en mí cuando yo dudaba y por recordarme que cada esfuerzo tiene un propósito. Su amor y compañía fueron mi mayor impulso para no rendirme.

A mi madre Lorena, cuyo cariño y dedicación han sido el pilar de mi vida. Gracias por enseñarme con tu ejemplo a ser perseverante, a mantener la fe en los momentos difíciles y a valorar cada logro con humildad.

A mi padre Santiago, por transmitirme la importancia del esfuerzo, el trabajo honesto y la disciplina. Sus palabras y consejos fueron guía y motivación constante en este proceso.

A mi hermana Yurilia, por su apoyo lleno de cariño y complicidad, que me recordó que nunca estuve solo y que cada paso dado es también un motivo de orgullo

compartido en la familia.

A mi amigo Fernando, por su compañía, consejos y apoyo en los momentos clave, demostrando que la verdadera amistad es también un motor para alcanzar metas.

A mis amigos, quienes con sus palabras de aliento, su compañía y los momentos compartidos, me ayudaron a sobrellevar las dificultades y me hicieron recordar la importancia de disfrutar cada etapa del camino.

A todos ustedes, gracias por ser mi fuerza, mi inspiración y mi razón para seguir adelante. Este logro es tanto mío como suyo.

Resumen

Ante la necesidad de contar con herramientas diagnósticas complementarias, no invasivas y con potencial de aplicación en tiempo real, esta tesis propone una metodología basada en simulaciones de dinámica de fluidos computacional (CFD) y redes neuronales convolucionales (CNN) para la clasificación automática de imágenes de flujo aórtico. El diagnóstico temprano de enfermedades aórticas como la coartación de la aorta y el síndrome de Marfan es esencial para prevenir complicaciones cardiovasculares graves. Si bien las técnicas de imagen médicas permiten evaluar la anatomía vascular, presentan limitaciones al analizar la dinámica del flujo sanguíneo. En esta investigación se simularon 12 modelos anatómicos tridimensionales contruidos a partir de tomografía computarizada y resonancia magnética, representando condiciones sanas y patológicas. A partir de estas simulaciones se generaron 2160 imágenes, las cuales fueron clasificadas en tres categorías (aorta sana, coartación de la aorta y síndrome de Marfan) mediante distintas arquitecturas de CNN. Los resultados demostraron una precisión destacable, alcanzando un *F1-score* del 98.47% con la red Compact. Además, esta arquitectura destacó por su rápida capacidad de inferencia, con un tiempo promedio de 3.45 ms por imagen. Estos resultados respaldan firmemente el uso de esta metodología como una alternativa automatizable, reproducible y potencialmente aplicable en entornos clínicos en tiempo real.

Abstract

Given the need for complementary, non-invasive diagnostic tools with potential for real-time application, this thesis proposes a methodology based on computational fluid dynamics (CFD) simulations and convolutional neural networks (CNN) for automatic classification of aortic flow images. Early diagnosis of aortic diseases, such as coarctation of the aorta and Marfan syndrome, is essential to prevent severe cardiovascular complications. While medical imaging techniques enable the assessment of vascular anatomy, they have limitations in analyzing blood flow dynamics. In this research, 12 three-dimensional anatomical models were simulated, constructed from computed tomography and magnetic resonance imaging, representing healthy and pathological conditions. From these simulations, a total of 2,160 images were generated and classified into three categories (healthy aorta, aortic coarctation, and Marfan syndrome) using different CNN architectures. The results demonstrated remarkable accuracy, achieving an F1-score of 98.47% with the Compact network. Moreover, this architecture stood out for its rapid inference capability, with an average inference time of 3.45 ms per image. These results strongly support the use of this methodology as an automatable, reproducible, and potentially real-time applicable alternative in clinical settings.

INTRODUCCIÓN

El diagnóstico temprano de patologías aórticas como la coartación de la aorta y el síndrome de Marfan resulta decisivo para reducir la morbilidad y la mortalidad asociadas a complicaciones cardiovasculares graves. Las técnicas de imagen médicas convencionales, entre ellas la tomografía computarizada (TC) y la resonancia magnética (RM), permiten caracterizar con precisión la geometría vascular; sin embargo, presentan limitaciones para describir de manera detallada la dinámica del flujo sanguíneo, indispensable para entender la evolución hemodinámica de dichas enfermedades [Song et al. \(2023\)](#). En este contexto, la dinámica de fluidos computacional (CFD) ha emergido como una herramienta no invasiva capaz de reproducir virtualmente el comportamiento del flujo dentro de modelos anatómicos obtenidos a partir de imágenes clínicas, aportando información cuantitativa sobre parámetros como la distribución de presiones, los esfuerzos de cizalla y la formación de remolinos.

Si bien la interpretación visual de los campos de velocidad y vorticidad generados por CFD puede ofrecer indicios valiosos al clínico, dicho análisis suele ser subjetivo y demandante en tiempo. La incorporación de técnicas de aprendizaje profundo, especialmente las redes neuronales convolucionales (CNN), abre la posibilidad de automatizar la identificación de patrones hemodinámicos y, con ello,

asistir de forma objetiva al especialista. Las CNN han demostrado un rendimiento sobresaliente en la clasificación de imágenes médicas gracias a su capacidad para aprender representaciones jerárquicas directamente a partir de los datos, evitando la extracción manual de características [Litjens et al. \(2017\)](#). Sin embargo, su aplicación al estudio de flujos aórticos generados por simulaciones CFD sigue siendo escasa y fragmentaria.

El presente trabajo propone un método basado en CNN para clasificar imágenes de flujo aórtico derivadas de simulaciones CFD construidas a partir de modelos anatómicos obtenidos de TC. Concretamente, se aborda la diferenciación automática entre modelos sanos, casos con coartación de la aorta y casos pertenecientes al síndrome de Marfan. Para ello se genera un conjunto de datos sintéticos que cubre un rango representativo de condiciones hemodinámicas, se entrena y optimiza una arquitectura convolucional adecuada, y se evalúa el desempeño mediante métricas.

1.1. Planteamiento del problema

El diagnóstico temprano de patologías aórticas como el síndrome de Marfan y la coartación de la aorta es fundamental para evitar complicaciones cardiovasculares graves. Aunque las técnicas de imagen médica como la tomografía computarizada (CT) o la resonancia magnética (MR) permiten detectar anomalías anatómicas, presentan limitaciones para evaluar de forma detallada la dinámica del flujo sanguíneo. La simulación por dinámica de fluidos computacional (CFD) ha demostrado ser una herramienta útil para modelar y analizar estos flujos, y su integración con redes neuronales profundas ha abierto nuevas posibilidades para la clasificación automática de patrones patológicos en imágenes generadas por estas simulaciones.

1.2. Objetivos

1.2.1. Objetivo general

Desarrollar una metodología que permita diferenciar imágenes de flujo sanguíneo aórtico generadas a partir de modelos tridimensionales construidos mediante tomografía computarizada y resonancia magnética, utilizando redes neuronales convolucionales para clasificar entre aortas sanas, con coartación y con síndrome de Marfan.

1.2.2. Objetivos específicos

Los objetivos específicos se listan a continuación:

- Simular modelos 3D de aorta con patologías y sanas con CFD basados en imágenes de TC y RM.
- Realizar un procesamiento de imágenes generadas tras la simulación.
- Clasificar imágenes con diferentes arquitecturas de redes neuronales convolucionales.
- Evaluar el desempeño del sistema propuesto mediante métricas cuantitativas.

1.3. Aportación

Esta tesis presenta como principal aportación una metodología que combine la simulación de flujo sanguíneo mediante dinámica de fluidos computacional (CFD) con la clasificación de imágenes utilizando redes neuronales convolucionales (CNN). La originalidad del trabajo radica en demostrar que, mediante el uso de simulaciones numéricas y técnicas de aprendizaje profundo como lo son las CNN, es posible

identificar de manera mediante el uso de simulaciones numéricas y técnicas de aprendizaje profundo como lo son las CNN, es posible identificar de manera precisa patrones patológicos precisa patrones patológicos sin necesidad de recurrir a imágenes clínicas directas, abriendo así nuevas perspectivas para el análisis no invasivo y la planificación personalizada en cardiología computacional.

1.4. Organización de la tesis

Los capítulos que conforman la tesis se estructuran de la siguiente manera:

- **Capítulo 2. Marco teórico:** En este capítulo se abordan los fundamentos sobre la anatomía de la aorta y sus patologías (coartación y síndrome de Marfan), los principios de la dinámica de fluidos computacional (CFD), las redes neuronales convolucionales (CNN), la clasificación de imágenes médicas y las métricas de evaluación.
- **Capítulo 3. Trabajo relacionado:** En este capítulo se hace una revisión crítica de investigaciones previas relevantes en el campo de la clasificación de imágenes médicas y simulaciones CFD.
- **Capítulo 4. Método propuesto:** En este capítulo se detalla la metodología desarrollada, incluyendo la generación de modelos 3D, la simulación del flujo con CFD, el procesamiento de imágenes, la visualización y el entrenamiento de las redes CNN.
- **Capítulo 5. Experimentos y resultados:** En este capítulo se presentan los resultados obtenidos mediante distintas arquitecturas de redes neuronales aplicadas a la tarea de clasificación de imágenes de flujo aórtico, así como un análisis cuantitativo y cualitativo de su desempeño.

- **Capítulo 6. Conclusiones y trabajo futuro:** En este capítulo se resumen las conclusiones más relevantes del estudio y se discuten posibles líneas de investigación a seguir.

MARCO TEÓRICO

Este capítulo estará relacionado con los fundamentos teóricos para la comprensión de CFD y su relación con el uso biomédico; a su vez, el uso de redes neuronales convolucionales para la clasificación de imágenes. La estructura de este marco teórico está dada por (6) secciones principales: (1) una introducción a la anatomía de la aorta y las patologías; coartación de la aorta y síndrome de Marfan, (2) continuando con una introducción acerca de la simulación por dinámica de fluidos computacional (CFD, por sus siglas en inglés), (3) posteriormente se abordarán como se visualizan el flujo de las simulaciones en imágenes, (4) luego se dará una breve explicación teórica acerca de las redes neuronales convolucionales (CNN), (5) posteriormente se dará una introducción a la clasificación de imágenes y su uso biomédico y (6) por último se darán bases teóricas de la matriz de confusión y las métricas de evaluación para la clasificación de imágenes.

2.1. Anatomía de la aorta

La aorta es el principal vaso sanguíneo del sistema circulatorio, encargado de transportar sangre rica en oxígeno desde el ventrículo izquierdo del corazón hacia el resto del cuerpo. Anatómicamente, la aorta se divide en varias secciones principales,

cada una con características morfológicas y funcionales específicas que influyen en la dinámica del flujo sanguíneo [Thubrikar \(1990\)](#); [Nichols and O'Rourke \(2011\)](#).

La aorta inicia en el corazón con la raíz aórtica, donde se encuentran las válvulas semilunares (válvulas aórticas) que controlan la salida de sangre. Inmediatamente después se ubica la aorta ascendente, que emerge del ventrículo izquierdo y da origen a las arterias coronarias. Posteriormente, la aorta forma un arco conocido como el arco aórtico, del cual surgen las principales ramas que irrigan la cabeza, el cuello y los miembros superiores: el tronco braquiocefálico, la arteria carótida común izquierda y la arteria subclavia izquierda [Hall \(2020\)](#).

Tras el arco, la arteria continúa como aorta torácica descendente, recorriendo el tórax por delante de la columna vertebral como se observa en la figura 2.1.




Figura 2.1: Divisiones anatómicas de la aorta: raíz aórtica aorta ascendente, arco aórtico y aorta torácica descendente. Fuente de la imagen: [Pellón \(2020\)](#).

En condiciones normales, la aorta presenta un diámetro que varía entre 2.5 y 3.5 cm en la porción torácica, y entre 1.5 y 2.5 cm en la porción abdominal [Thubrikar \(1990\)](#). Su pared está constituida por tres capas: la íntima (capa interna de endotelio), la *media* (compuesta de músculo liso y fibras elásticas) y la adventicia (capa externa de tejido conectivo) [Nichols and O'Rourke \(2011\)](#). Esta estructura proporciona a la aorta tanto resistencia como elasticidad, propiedades esenciales

para amortiguar las variaciones de presión generadas durante el ciclo cardíaco.

2.1.1. Coartación de la aorta

La coartación de la aorta (CoA) es una malformación congénita del sistema cardiovascular que se caracteriza por un estrechamiento localizado del lumen aórtico como se observa en la figura 2.2. Esta condición provoca una obstrucción parcial del flujo sanguíneo, lo que se traduce en hipertensión en la parte superior del cuerpo, disminución del flujo en las extremidades inferiores y sobrecarga de presión en el ventrículo izquierdo [Brown et al. \(2013\)](#).




Figura 2.2: Imagen obtenida mediante resonancia magnética que muestra una coartación de la aorta. Fuente: [Wilson et al. \(2013\)](#).

Las técnicas de diagnóstico han evolucionado significativamente, y actualmente se dispone de herramientas no invasivas altamente efectivas. La ecocardiografía

Doppler es el método de elección en neonatos y niños, ya que permite estimar el gradiente de presión a través de la estenosis. Sin embargo, en adultos o en pacientes con mala ventana acústica, esta técnica puede ser insuficiente.

La resonancia magnética cardiovascular (CMR) ha ganado relevancia como técnica de referencia en adolescentes y adultos, ya que permite una caracterización anatómica detallada y cuantificación precisa del flujo mediante secuencias codificadas en velocidad (phase-contrast MRI), sin exposición a radiación ionizante [Raza et al. \(2023\)](#); [Kilner et al. \(2007\)](#).

En casos seleccionados, el cateterismo cardíaco sigue teniendo un papel diagnóstico, especialmente cuando se planean intervenciones terapéuticas. Este procedimiento permite la medición directa del gradiente de presión transcoartación y la evaluación invasiva de la anatomía, aunque su uso diagnóstico ha disminuido con el avance de las técnicas por imagen no invasiva [Raza et al. \(2023\)](#).

En conjunto, la coartación de la aorta representa una patología estructural relevante, cuyo diagnóstico temprano y seguimiento a largo plazo son fundamentales, ya que incluso tras una corrección quirúrgica o por catéter, los pacientes pueden desarrollar reestenosis, hipertensión persistente o complicaciones asociadas. Las imágenes médicas y las técnicas de simulación como CFD ofrecen un complemento valioso en la caracterización hemodinámica individual de estos casos.

2.1.2. Síndrome de Marfan

El síndrome de Marfan (MFS) es un trastorno del tejido conectivo con herencia autosómica dominante, causado por mutaciones en el gen FBN1, lo que contribuye de forma activa al desarrollo de patologías vasculares como la dilatación y disección de la aorta torácica ver figura [2.3 Gillis et al. \(2013\)](#).



Figura 2.3: Imagen obtenida mediante resonancia magnética que muestra una dilatación de aorta de un paciente con síndrome de Marfan. Fuente: [Wilson et al. \(2013\)](#).

Por tanto, la distinción entre MFS y otros síndromes aórticos hereditarios requiere no solo una evaluación fenotípica cuidadosa, sino también el soporte del análisis molecular.

En conjunto, el síndrome de Marfan representa un ejemplo paradigmático de enfermedad genética con manifestaciones cardiovasculares potencialmente letales. La comprensión de sus mecanismos moleculares ha permitido avanzar no solo en el diagnóstico diferencial, sino también en el desarrollo de terapias dirigidas, lo cual es particularmente relevante en el contexto de la medicina personalizada.

2.2. Dinámica de fluidos computacional (CFD)

La dinámica de fluidos computacional (CFD) se define como el uso de métodos numéricos para resolver las ecuaciones que gobiernan la conservación de masa, cantidad de movimiento y energía en un fluido. Desde sus inicios en las décadas de 1950-60, cuando las primeras computadoras permitieron discretizar las ecuaciones

de Navier-Stokes (2.1)(2.2), la disciplina se ha consolidado como un “tercer pilar” de la investigación en mecánica de fluidos que complementa la teoría analítica y la experimentación física Ferziger et al. (2020) estas ecuaciones se muestran a continuación.

$$\rho \left(\frac{\partial \mathbf{v}}{\partial t} + \mathbf{v} \cdot \nabla \mathbf{v} \right) = -\nabla p + \mu \nabla^2 \mathbf{v} + \mathbf{f} \quad (2.1)$$

donde:

- ρ es la densidad del fluido.
- $\mathbf{v}$ es el campo de velocidad del fluido.
- p es la presión.
- μ es la viscosidad dinámica del fluido.
- $\nabla^2 \mathbf{v}$ es el término de difusión viscoso.
- $\mathbf{f}$ son las fuerzas externas.

La ecuación de continuidad, que asegura la conservación de la masa en un fluido incomprensible, es:

$$\nabla \cdot \mathbf{v} = 0 \quad (2.2)$$

Una simulación típica sigue tres fases: (i) preprocesado, donde se genera la geometría, la malla y las condiciones de contorno; (ii) solución numérica, que integra las ecuaciones en el tiempo o hasta estado estacionario empleando algoritmos implícitos o explícitos y aceleradores como multigrid; y (iii) posprocesado, en el que se visualizan campos de presión, velocidad y vorticidad, y se extraen magnitudes de

interés (coeficientes de arrastre, fuerzas hemodinámicas, etc.) antes de realizar los estudios de verificación y validación correspondientes [Ferziger et al. \(2020\)](#).

En los últimos años, CFD ha alcanzado un lugar destacado en las ciencias biomédicas. Revisiones recientes muestran cómo la simulación del flujo sanguíneo con geometrías obtenidas de imágenes médicas permite cuantificar esfuerzos cortantes en aneurismas, evaluar la progresión de la aterosclerosis y planificar tratamientos personalizados en modelos de arterias estenosadas o válvulas cardíacas [Taebi \(2024\)](#). Estos avances, impulsados por el aumento de la potencia de cómputo y la disponibilidad de mallas de alta fidelidad, han situado a CFD como una herramienta no invasiva de enorme valor clínico [Nitesh Kumar and B \(2023\)](#).

2.3. Visualización

La visualización de resultados CFD sigue un flujo estructurado: primero, los datos de simulación se exportan en formatos como VTK o VTU, los cuales contienen tanto la geometría (nodos, conectividad de elementos) como los campos escalares y vectoriales (presión, velocidad, vorticidad). Se cargan estos datos en una estructura de datos jerárquica y se procesan mediante un pipeline de filtros, donde se puede aplicar transformaciones como isosuperficies, líneas de flujo, cortes, interpolaciones o cálculos de derivadas espaciales. Este pipeline, basado en el modelo de flujo de datos de VTK, permite crear representaciones visuales eficientes mediante un modelo de demanda ("demand-driven execution") optimizado para flujos de trabajo interactivos o en modo batch [Ahrens et al. \(2005\)](#).

2.4. Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN) son una clase de arquitectura de aprendizaje profundo diseñadas específicamente para procesar datos, como las imágenes en dos dimensiones. Introducidas formalmente por Yann LeCun en la década de 1990 y popularizadas con el trabajo de [Krizhevsky et al. \(2017\)](#) en la competencia ImageNet, las CNN se han convertido en el estándar para tareas de visión por computadora, incluyendo clasificación de imágenes, detección de objetos, segmentación semántica y análisis de imágenes médicas [Litjens et al. \(2017\)](#).

A diferencia de las redes neuronales densamente conectadas, las CNN se basan en el uso de filtros convolucionales que extraen características locales de una imagen de entrada, preservando su estructura espacial. Estas redes están compuestas por capas de convolución, activación no lineal (como ReLU), normalización y submuestreo (pooling). A medida que los datos atraviesan múltiples capas, se extraen representaciones jerárquicas, desde bordes y texturas en las primeras capas hasta formas complejas y semánticas en las últimas. Esta capacidad de aprendizaje jerárquico de características permite que las CNN superen ampliamente a los métodos tradicionales de visión artificial en múltiples dominios.

En el campo de la imagenología médica, las CNN han demostrado resultados sobresalientes en tareas como la detección de tumores en resonancia magnética, el análisis automático de retinografías, la segmentación de órganos en tomografías, y más recientemente, en la clasificación de patrones de flujo simulados mediante dinámica de fluidos computacional (CFD). Estas aplicaciones aprovechan no solo la precisión de las CNN, sino también su capacidad para aprender directamente de los datos sin necesidad de ingeniería manual de características [Shen et al. \(2017\)](#); [Lundervold and Lundervold \(2019\)](#).

Arquitecturas como AlexNet, VGG, ResNet, DenseNet y EfficientNet han sido

adaptadas con éxito al entorno médico, ya sea entrenadas desde cero o mediante técnicas de transfer learning, en las cuales se reutilizan pesos preentrenados en grandes conjuntos de datos generales (como ImageNet) y se ajustan a tareas clínicas específicas. Estas estrategias permiten trabajar incluso con bases de datos pequeñas, una limitación común en el ámbito biomédico.

A pesar de sus ventajas, el uso de CNN en contextos médicos también plantea desafíos importantes, como la necesidad de interpretabilidad, la validación clínica, y la mitigación de sesgos derivados de datos desequilibrados. Por ello, se están desarrollando técnicas de visualización como Grad-CAM y saliency maps, que permiten destacar qué regiones de la imagen influyen más en las decisiones del modelo, aumentando la transparencia en entornos clínicos.

2.5. Clasificación de imágenes

La clasificación de imágenes, en términos generales, consiste en asignar etiquetas según sus características visuales; para ello es necesario extraer y analizar dichas características. Las más comunes se basan en densidad, color, textura, forma y posición [Hassan et al. \(2022\)](#). Aquí entran en juego las redes neuronales convolucionales, un subconjunto del aprendizaje profundo (DL, por sus siglas en inglés). Este enfoque permite clasificar, agrupar y predecir grandes conjuntos de datos y, gracias a ello, las CNN posibilitan una clasificación eficaz de imágenes.

En el ámbito médico, la clasificación de imágenes es una herramienta útil porque facilita la detección de anomalías o patologías en imágenes médicas. Tradicionalmente, estas tareas las realiza un profesional médico basándose en su experiencia; contar con modelos de DL como apoyo adicional contribuye a mejorar el diagnóstico.

El tamaño de imagen influye directamente en la resolución de los patrones

espaciales que la red puede aprender; imágenes demasiado pequeñas pueden perder detalles relevantes, mientras que imágenes excesivamente grandes aumentan el costo computacional sin necesariamente mejorar el rendimiento del modelo. Por su parte, el *batch size* regula cuántas muestras son procesadas simultáneamente durante cada actualización de los pesos, lo cual afecta tanto la estabilidad del entrenamiento como la eficiencia del uso de memoria de la GPU.

El número de épocas e iteraciones determina cuántas veces la red es expuesta al conjunto de datos. Un número insuficiente puede producir un modelo subentrenado, mientras que un número excesivo podría inducir sobreajuste. El learning rate o tasa de aprendizaje es otro parámetro crítico: controla el tamaño de los pasos que da el optimizador al ajustar los pesos de la red. Un valor demasiado alto puede hacer que el modelo no converja o sea inestable, mientras que un valor demasiado bajo puede ralentizar el aprendizaje o hacer que el modelo se estanque en mínimos locales.

En conjunto, estos parámetros forman la base sobre la cual se construye la eficiencia, estabilidad y confiabilidad del sistema de clasificación. Su correcta selección y ajuste, respaldados por validación cruzada y experimentación sistemática, resultan esenciales para obtener un modelo robusto, preciso y aplicable en contextos clínicos reales.

2.6. Matriz de confusión

La matriz de confusión es una herramienta fundamental en la evaluación de modelos de clasificación supervisada. Permite analizar de forma detallada las predicciones realizadas por un clasificador, comparándolas con las clases reales. Es especialmente útil cuando se desea comprender el comportamiento del modelo en cada clase individual, más allá de una métrica global como la exactitud (*accuracy*).

En su forma más básica, la matriz de confusión está compuesta por cuatro

elementos:

donde:

- TP: Verdaderos positivos
- TN: Verdaderos negativos
- FP: Falsos positivos
- FN: Falsos negativos

A partir de estos elementos se derivan múltiples métricas de evaluación.

2.6.1. Métricas de evaluación

La evaluación del desempeño de modelos de clasificación de imágenes requiere el uso de métricas cuantitativas que permitan medir qué tan bien el modelo asigna etiquetas correctas a las muestras del conjunto de prueba. Estas métricas se derivan principalmente de la matriz de confusión, que compara las clases predichas por el modelo con las clases reales.

Entre las métricas más fundamentales se encuentra la exactitud (accuracy) [2.3](#), que representa la proporción de predicciones correctas con respecto al total de muestras. Si bien es ampliamente utilizada, su utilidad puede ser limitada en conjuntos de datos desequilibrados, donde una clase es significativamente más frecuente que las demás.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.3)$$

Para abordar este problema, se utilizan métricas basadas en el rendimiento por clase, como la precisión [2.4](#) (precision), el *recall* [2.5](#) (sensibilidad o TPR) y la

F1-score 2.6. La precisión mide qué proporción de las predicciones positivas fue realmente correcta, mientras que el recall mide qué proporción de las muestras positivas fue identificada correctamente. La F1-score (F1) combina ambas métricas mediante su media armónica, lo que proporciona una medida robusta en contextos donde el balance entre falsos positivos y falsos negativos es crítico [Sokolova and Lapalme \(2009\)](#).

$$Precision = \frac{TP}{TP + FP} \quad (2.4)$$

$$Recall = \frac{TP}{TP + FN} \quad (2.5)$$

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (2.6)$$

En tareas multiclase, estas métricas pueden calcularse mediante distintos esquemas de agregación: macro-promedio (promedio simple entre clases), micro-promedio (acumulando verdaderos positivos y negativos globalmente), y ponderado (pesando por la frecuencia de cada clase). Estos esquemas permiten una evaluación más justa cuando las clases tienen diferentes distribuciones, como suele ocurrir en problemas reales de clasificación de imágenes médicas o flujos físicos simulados.

TRABAJO RELACIONADO

3.1. Simulación de flujo en aorta

El estudio realizado por [LaDisa et al. \(2011\)](#) aborda el análisis detallado de patrones hemodinámicos en pacientes con coartación de la aorta, específicamente tratados mediante cirugía de resección con anastomosis extremo a extremo. Los autores utilizaron simulaciones numéricas basadas en dinámica de fluidos computacional, apoyadas en datos reales de resonancia magnética y presiones arteriales clínicas, para evaluar cómo la intervención quirúrgica modifica los patrones del esfuerzo cortante (WSS) y el índice oscilatorio del esfuerzo cortante (OSI) en la aorta torácica.

Los resultados obtenidos mostraron diferencias significativas en la distribución espacial y temporal del WSS y OSI entre pacientes tratados y sujetos sanos. Se observó que los pacientes con CoA presentaron valores elevados de WSS en la región cercana a la reparación quirúrgica, así como un aumento del OSI en regiones distales. Estas áreas identificadas podrían ser más susceptibles al desarrollo de complicaciones clínicas futuras, como formación de placas ateroscleróticas.

Este trabajo comparte varias similitudes metodológicas con la presente investigación, incluyendo el uso de modelos anatómicos derivados de imágenes

médicas y la aplicación de CFD para evaluar patrones hemodinámicos complejos.

El estudio presentado por [An et al. \(2024\)](#) analiza las características del flujo sanguíneo en pacientes con válvula aórtica bicúspide (BAV) que presentan dilatación de la aorta ascendente, antes y después de someterse a un procedimiento de reemplazo valvular aórtico transcatéter (TAVR). Utilizando (CFD), los autores evaluaron los patrones de flujo sanguíneo, la presencia de vórtices, flujo helicoidal y el esfuerzo cortante sobre la pared (WSS) en la aorta ascendente de tres pacientes específicos.

Los resultados obtenidos mostraron que, antes del procedimiento, los pacientes presentaban patrones de flujo anormales caracterizados por vórtices y flujos helicoidales, con altos valores de WSS regionales (hasta 16.7 Pa). Después del procedimiento de TAVR, estos patrones de flujo anormal se normalizaron significativamente y los valores máximos de WSS disminuyeron considerablemente (alcanzando valores tan bajos como 1.1 Pa en un paciente). Los autores sugieren que esta normalización de los patrones de flujo podría tener importantes implicaciones clínicas a largo plazo, reduciendo potencialmente el riesgo de eventos adversos como el crecimiento de la aorta o la disección aórtica.

El artículo presentado por [Morris et al. \(2016\)](#) aborda una revisión integral sobre el uso de la CFD en diversas aplicaciones dentro de la medicina cardiovascular.

Entre las principales aplicaciones resaltadas están la evaluación de dispositivos médicos como prótesis valvulares y stents, simulaciones en aneurismas y disecciones aórticas, así como la predicción del comportamiento hemodinámico en enfermedades coronarias. Los autores subrayan cómo estas simulaciones facilitan la obtención de parámetros imposibles o difíciles de medir clínicamente, como el esfuerzo cortante sobre las paredes arteriales (WSS), y permiten realizar análisis detallados del impacto de diferentes tratamientos o intervenciones médicas antes de implementarlas en pacientes reales.

El estudio realizado por [Capellini et al. \(2025\)](#) utiliza CFD para evaluar

comparativamente dos estrategias diferentes de tratamiento endovascular en pacientes con úlcera penetrante aórtica (PAU). Las dos estrategias consideradas fueron la reparación endovascular de la aorta torácica (TEVAR) con un injerto aórtico ramificado específico para la arteria subclavia izquierda (SBSG), y un enfoque híbrido que incluye el procedimiento TEVAR junto con un bypass carotídeo-subclavio (LCCA-LSA).

Utilizando modelos anatómicos reconstruidos a partir de imágenes médicas de tomografía computarizada (CT), los autores realizaron simulaciones CFD para comparar detalladamente la morfología y hemodinámica de la aorta torácica antes y después del tratamiento. Los resultados revelaron que la técnica SBSG mantiene mejor el flujo sanguíneo en la arteria subclavia izquierda (LSA), mostrando una reducción mínima en la tasa de flujo sanguíneo y una menor caída de presión en comparación con el método híbrido, el cual presentó disminuciones más significativas en la perfusión arterial y mayores pérdidas de presión debido a cambios geométricos más drásticos.

Además, el estudio evaluó parámetros hemodinámicos clave como el esfuerzo cortante sobre la pared (WSS), identificando regiones con bajo WSS y alto índice de esfuerzo cortante oscilatorio (OSI), que podrían estar asociadas a un mayor riesgo aterogénico a largo plazo. Se concluyó que el enfoque SBSG tiene un menor impacto sobre estos parámetros críticos, sugiriendo una ventaja hemodinámica sobre el enfoque híbrido.

El estudio de [Tango et al. \(2025\)](#) analiza los cambios hemodinámicos generados por los procedimientos de reemplazo valvular aórtico quirúrgico (SAVR) y transcáteter (TAVR) mediante simulaciones numéricas avanzadas de interacción fluido-estructura (FSI). El objetivo principal es evaluar el impacto que estos procedimientos tienen sobre la dinámica del flujo sanguíneo en comparación con una válvula aórtica nativa idealizada y saludable. Las simulaciones se

realizaron utilizando geometrías idealizadas y parámetros fisiológicos obtenidos experimentalmente, utilizando software comercial especializado en problemas dinámicos no lineales (LS-DYNA).

Los resultados muestran que, aunque ambos tratamientos son efectivos desde el punto de vista clínico, generan patrones de flujo significativamente diferentes respecto a las condiciones fisiológicas ideales. En particular, las válvulas quirúrgicas presentan una menor área efectiva de orificio, mayores gradientes de presión transvalvular y tiempos prolongados de apertura y cierre respecto a las transcáteter, lo cual puede incrementar el riesgo de complicaciones hemodinámicas a largo plazo. Las válvulas transcáteter logran resultados más cercanos a la válvula nativa en términos de rendimiento sistólico, aunque introducen perturbaciones en los senos de Valsalva, incrementando el riesgo potencial de estancamiento sanguíneo y daño celular debido a la presencia de regiones con bajo esfuerzo cortante sobre la pared (WSS).

El trabajo escrito por [Keshmiri and Andrews \(2015\)](#) presenta detalladamente la metodología general requerida para llevar a cabo simulaciones CFD en aplicaciones médicas, incluyendo la identificación y definición de problemas, preprocesamiento (generación de geometría y malla), solución numérica y postprocesamiento de resultados.

El trabajo resalta que la CFD permite realizar "experimentos numéricos" donde modelos anatómicos derivados de imágenes médicas (TC, RM, ultrasonido 3D) se combinan con técnicas numéricas avanzadas para simular condiciones hemodinámicas que serían difíciles, costosas o incluso imposibles de reproducir experimentalmente. Destacan la importancia y las ventajas de usar simulaciones numéricas para evaluar parámetros cruciales como el esfuerzo cortante sobre la pared (WSS), el índice oscilatorio del esfuerzo cortante (OSI), y el tiempo de residencia relativo (RRT), entre otros, los cuales están directamente relacionados

con enfermedades como la aterosclerosis y aneurismas arteriales.

3.1.1. Discusión

Los estudios revisados comparten una base metodológica común con esta tesis, especialmente en el uso de simulaciones CFD aplicadas a modelos anatómicos derivados de imágenes médicas. Sin embargo, la mayoría de estas investigaciones se centran en casos clínicos específicos o revisiones metodológicas sin incorporar automatización diagnóstica.

La principal aportación de esta tesis radica en la integración de redes neuronales convolucionales con simulaciones CFD para la clasificación automática de flujo sanguíneo en diferentes condiciones aórticas. Esta combinación permite automatizar la interpretación de patrones hemodinámicos, reduciendo la subjetividad del análisis clínico y ofreciendo una herramienta escalable y reproducible para el diagnóstico asistido.

En conjunto, la presente investigación no solo valida y extiende enfoques previos en CFD aplicada a medicina, sino que introduce un marco novedoso de análisis automatizado con potencial de aplicación clínica en el diagnóstico cardiovascular no invasivo.

3.2. Simulación de flujo en otras anatomías

El artículo presentado por [Schena et al. \(2024\)](#) propone evaluar diferentes alternativas quirúrgicas en aneurismas cerebrales complejos. Este marco tiene como objetivo proporcionar información cuantitativa y reproducible sobre parámetros hemodinámicos claves, tales como presión, velocidad del flujo sanguíneo y esfuerzo cortante sobre la pared (WSS), permitiendo así una evaluación objetiva y detallada

de cada opción quirúrgica antes de llevar a cabo intervenciones clínicas reales.

El estudio enfatiza particularmente la importancia de contar con simulaciones específicas para cada paciente, utilizando geometrías derivadas directamente de imágenes médicas como la angiografía por tomografía computarizada (CTA). Dentro del marco propuesto, los autores realizan simulaciones CFD sobre las diferentes alternativas quirúrgicas (por ejemplo, posiciones de clip y estrategias de derivación o bypass), comparando resultados cuantitativos que facilitan a los neurocirujanos una toma de decisiones más informada y precisa.

El artículo de [Lee \(2011\)](#) presenta una revisión integral sobre la aplicación de la CFD en enfermedades cardiovasculares.

Se describe detalladamente los componentes esenciales de la CFD: el preprocesamiento, la solución numérica y el posprocesamiento. Se subraya que la precisión en la generación de geometrías, definición de propiedades físicas del fluido (por ejemplo, modelos de viscosidad sanguínea) y condiciones de frontera basadas en datos clínicos (presión, flujo y velocidad) son fundamentales para obtener resultados confiables. Se enfatiza la importancia de la visualización avanzada para interpretar adecuadamente los resultados numéricos, como el esfuerzo cortante en la pared arterial (WSS), índices oscilatorios (OSI) y perfiles de velocidad y presión.

Entre las aplicaciones clínicas discutidas destacan estudios sobre enfermedades arteriales coronarias (aterosclerosis), cardiopatías congénitas como la circulación Fontan, análisis hemodinámico en aneurismas aórticos y enfermedades cerebrovasculares. Resalta cómo la CFD permite entender la fisiopatología cardiovascular, optimizar intervenciones clínicas y desarrollar dispositivos médicos más eficaces mediante simulaciones personalizadas.

El artículo de [Sun and Xu \(2014\)](#) ofrece una revisión exhaustiva sobre las aplicaciones de la CFD en el estudio y diagnóstico de la enfermedad arterial coronaria.

Los autores explican cómo mediante reconstrucciones tridimensionales de la anatomía arterial obtenidas de imágenes médicas (como la tomografía computarizada o angiografía coronaria), se puede calcular el esfuerzo cortante en la pared arterial (WSS), un parámetro hemodinámico central en el desarrollo de la aterosclerosis. La CFD permite correlacionar valores bajos de WSS con zonas propensas a la formación de placas, mientras que valores elevados se asocian con mayor riesgo de ruptura de placas vulnerables.

El artículo también aborda la integración de simulaciones de interacción fluido-estructura (FSI) y el uso del índice de reserva fraccional de flujo (FFR) derivado por CFD como alternativa no invasiva para la evaluación funcional de estenosis coronarias. Se presentan resultados de estudios clínicos que validan la precisión del FFR computado frente a métodos invasivos, destacando su potencial para reducir procedimientos diagnósticos innecesarios.

El trabajo de [Pellón \(2020\)](#) propone el uso de técnicas ópticas, en particular la imagen hiperespectral (HSI), como una herramienta de diagnóstico no invasiva para identificar y caracterizar patologías en la aorta, específicamente el aneurisma. El autor parte del hecho de que las técnicas convencionales de imagen médica como la tomografía computarizada o la resonancia magnética, aunque efectivas, presentan limitaciones en entornos intraoperatorios y conllevan altos costos o exposición a radiación ionizante.

La metodología propuesta consiste en el uso de imágenes hiperespectrales para obtener un análisis espectral completo del tejido aórtico, permitiendo detectar anomalías estructurales y químicas a través de la interacción de la luz con los cromóforos del tejido (principalmente colágeno y elastina). Se emplearon técnicas de detección de anomalías como el algoritmo RX y métodos de descomposición lineal basados en el modelo de Kubelka-Munk para cuantificar los cromóforos y evaluar el grado de degradación del tejido aórtico.

El estudio incluye el análisis comparativo entre muestras sanas y patológicas, identificando diferencias espectrales significativas que permiten segmentar regiones con alteraciones estructurales. Se destaca que la técnica es inocua, de bajo costo, no invasiva y adecuada para entornos quirúrgicos, presentando una alternativa prometedora a las técnicas tradicionales de diagnóstico.

3.2.1. Discusión

Diversos estudios revisados comparten con esta tesis el uso riguroso de simulaciones mediante dinámica de fluidos computacional para el análisis hemodinámico en distintas patologías cardiovasculares. Investigaciones como las de Lavín Pellón, Lee, Schena et al. y Sun y Xu exploran enfoques que, aunque variados en su aplicación (óptica espectral, aneurismas cerebrales o arterias coronarias), coinciden en la utilidad de modelos derivados de imágenes médicas para estudiar el comportamiento vascular.

Sin embargo, la propuesta de esta tesis se diferencia al incorporar redes neuronales convolucionales para la clasificación automática de patrones de flujo sanguíneo simulados. Esta integración permite automatizar el análisis y ampliar el potencial diagnóstico de las simulaciones CFD, ofreciendo un enfoque más eficiente, reproducible y escalable para el estudio de patologías aórticas como la coartación y el síndrome de Marfan.

En conjunto, los enfoques revisados respaldan la metodología adoptada, mientras que esta tesis aporta una innovación al extender el uso de CFD mediante herramientas de inteligencia artificial, posicionándose como una contribución relevante dentro del diagnóstico cardiovascular asistido por computadora.

A continuación se presenta una comparación resumida entre los trabajos relacionados y la propuesta desarrollada en esta tesis (véase la Tabla [3.1](#)).

Tabla 3.1: Comparación de trabajos relacionados con la presente tesis

Autor(es)	Descripción del trabajo	Comparación con esta tesis
(Keshmiri and Andrews, 2015)	Uso de CFD en aplicaciones vasculares, destacando el proceso desde la segmentación.	Coincide con el uso de CFD, pero la tesis incorpora CNN para clasificación automática.
(Tango et al., 2025)	Simulación FSI para evaluar diferencias hemodinámicas entre válvulas quirúrgicas y transcáteter.	Enfoque valvular específico; la tesis amplía el análisis a distintas patologías aórticas e integra clasificación automática con CNN.
(Capellini et al., 2025)	CFD para comparar dos estrategias endovasculares en úlceras aórticas.	Evaluación post-intervención específica; la tesis se enfoca en diagnóstico automatizado multiclase en flujo aórtico.
(Morris et al., 2016)	Revisión general de aplicaciones de CFD en medicina cardiovascular.	Coincide en el uso de CFD, pero la tesis añade inteligencia artificial para automatizar el diagnóstico aórtico.
(An et al., 2024)	CFD aplicado a evaluar TAVR en pacientes con válvula bicúspide.	Análisis centrado en el impacto post-procedimiento; la tesis aborda distintas patologías y aplica clasificación automática.
(LaDisa et al., 2011)	Evaluación hemodinámica postquirúrgica en CoA con simulaciones CFD.	Se enfoca en un solo tratamiento y condición; la tesis cubre múltiples patologías y propone automatización diagnóstica.

Tabla 3.1 (continuación). Comparación de trabajos relacionados con la presente tesis

Autor(es)	Descripción del trabajo	Comparación con esta tesis
(Pellón, 2020)	Diagnóstico de aneurismas con imagen hiperespectral y análisis óptico.	Enfoque óptico-espectral; la tesis se basa en simulaciones hemodinámicas y CNN para clasificación.
(Schena et al., 2024)	Marco CFD para comparar alternativas quirúrgicas en aneurismas cerebrales.	Aplicación quirúrgica específica; la tesis automatiza el análisis en flujo aórtico bajo múltiples patologías.
(Sun and Xu, 2014)	CFD en arterias coronarias para evaluar formación y riesgo de placas ateroscleróticas.	Enfoque en coronarias; la tesis aplica CFD + CNN en aorta para clasificación diagnóstica automatizada.

MÉTODO PROPUESTO

El método propuesto en este trabajo tiene como objetivo desarrollar una metodología capaz de diferenciar imágenes de flujo sanguíneo aórtico que representan condiciones de aorta sana, coartación de la aorta y síndrome de Marfan, partiendo de modelos 3D contruidos a partir de imágenes médicas reales. Mediante el uso de redes neuronales convolucionales, utilizando datos generados por simulaciones de dinámica de fluidos computacional.

4.1. Esquema general

La metodología se divide en varias etapas fundamentales ver figura 4.1. En primer lugar, se realiza la reconstrucción de modelos 3D anatómicos a partir de imágenes médicas obtenidas mediante tomografía computarizada y resonancia ver tabla 4.1. A partir de estos modelos, se realiza una simulación del flujo sanguíneo utilizando técnicas de CFD, lo que permite generar imágenes sintéticas con información hemodinámica detallada.

Posteriormente se lleva a cabo el procesamiento de las imágenes generadas. En esta fase se extraen cortes bidimensionales representativos del flujo, los cuales son rotulados y organizados por clase. Las imágenes se someten a un proceso




Figura 4.1: Esquema general del método propuesto. El esquema gráfico de la CNN corresponde a la arquitectura ResNet-18 utilizada en este experimento. [Ramzan et al. \(2020\)](#)

de estandarización en cuanto a tamaño, resolución y formato, con el objetivo de garantizar su compatibilidad y correcto procesamiento por parte de los modelos de redes neuronales. El conjunto resultante se divide en subconjuntos de entrenamiento y prueba de forma balanceada.

4.2. Simulación

4.2.1. Base de datos (modelos)

La base de datos utilizada consta de 12 modelos; 4 de aorta sana, 4 con coartación de aorta y 4 con síndrome de Marfan [Wilson et al. \(2013\)](#). Se describen con más detalle los modelos en la tabla 4.1.

Tabla 4.1: Datos de los modelos utilizados en la simulación y clasificación del flujo aórtico. El nombre del modelo H_AO hace referencia a que es un modelo humano de aorta. Los términos H, COA y MFS, hacen referencia a *Healthy* (saludable), *Coartaction* (coartación) y *Marfan Syndrome* (Síndrome de Marfan) respectivamente.

Modelo	Edad (años)	Sexo	Procedimiento de imagen
0008_H_AO_H	6	Masculino	TC
0009_H_AO_H	11	Masculino	TC
0010_H_AO_H	11	Femenino	RM
0011_H_AO_H	23	Femenino	RM
0013_H_AO_COA	13	Masculino	RM
0014_H_AO_COA	5	Masculino	RM
0016_H_AO_COA	11	Femenino	RM
0017_H_AO_COA	23	Femenino	RM
0021_H_AO_MFS	18	Masculino	TC
0022_H_AO_MFS	17	Masculino	RM
0023_H_AO_MFS	15	Masculino	RM
0026_H_AO_MFS	45	Masculino	TC

4.2.2. Ajuste de parámetros de simulación

El proceso de simulación comienza con el ajuste de los parámetros necesarios para que el comportamiento del flujo se asemeje lo más posible al flujo sanguíneo. Algunos parámetros ya están definidos por los modelos provenientes de la base de datos [Wilson et al. \(2013\)](#), tales como la densidad y viscosidad del fluido, con valores de 1.06 g/cm^3 y $0.04 \text{ g/(cm}\cdot\text{s)}$, respectivamente, así como las asignaciones de entrada y salida en los límites del modelo.

Los parámetros más avanzados relacionados con los solucionadores numéricos también son proporcionados por los modelos originales ver tabla 4.2. Ajustes como el número de iteraciones, el tamaño del paso de tiempo, el número total de pasos se establecieron con el objetivo de asegurar tiempos de simulación adecuados y resultados confiables sobre el comportamiento del flujo.

Se definieron un total de 1000 pasos de tiempo con un tamaño de paso de 0.001 segundos, lo cual proporciona una resolución temporal adecuada para capturar la dinámica del flujo. El método de cálculo de fuerza se basó en el campo de velocidades, lo que permite estimar el esfuerzo ejercido por el fluido sobre las paredes del modelo. La construcción de pasos se configuró con un valor de 3, implicando que cada paso de tiempo incluye sub-etapas internas para mejorar la estabilidad numérica. Se aplicaron condiciones de frontera tipo RCR (Resistencia-Capacitancia-Resistencia) en cinco superficies (IDs 2, 3, 5, 6 y 7), lo cual es común en simulaciones hemodinámicas para emular la impedancia vascular distal. Asimismo, se acoplaron cinco superficies adicionales, permitiendo la interacción entre distintos dominios del modelo.

Para mejorar la estabilidad en regiones con posible reflujo, se incluyó un coeficiente de estabilización de 0.2. Se habilitó el control del residuo, estableciendo un criterio de convergencia de 0.01 y un mínimo de tres iteraciones por paso. El solucionador GMRES fue configurado con 300 vectores de Krylov por barrido. Se impusieron tolerancias estrictas de 0.01 tanto para las ecuaciones de momento como para las de continuidad. El número máximo de iteraciones se fijó en 10 para el solucionador de Navier-Stokes, 10 para el bucle de momento, y 400 para el bucle de continuidad. Finalmente, se empleó una regla de integración temporal de segundo orden junto con un valor de *Rho Infinity* de 0.5, que permite un equilibrio entre precisión y amortiguamiento numérico en los cálculos transitorios.

Tabla 4.2: Parámetros de configuración de la simulación para modelos sanos, CoA y MFS

Parámetro	Valor
Número de pasos de tiempo	1000
Tamaño del paso de tiempo	0.001
Pasos entre reinicios	1
Método de cálculo de fuerza	Basado en velocidad
Construcción de pasos	3
Número de superficies RCR	5
Lista de superficies RCR	2 3 5 6 7
Número de superficies acopladas	5
Coeficiente de estabilización de reflujo	0.2
Control de residuo	Verdadero
Criterio de residuo	0.01
Iteraciones mínimas requeridas	3
Vectores de Krylov por barrido	300
GMRES	
Tolerancia en ecuaciones de momento	0.01
Tolerancia en ecuaciones de continuidad	0.01
Tolerancia en solver svLS NS	0.01
Máx. iteraciones svLS NS	10
Máx. iteraciones bucle momento svLS	10
Máx. iteraciones bucle continuidad	400
svLS	
Regla de integración temporal	Segundo orden
Rho Infinito	0.5

4.2.3. Resultados numéricos

Posterior al proceso de simulación, se obtienen resultados numéricos que se almacenan dependiendo del número de pasos de tiempo, el tamaño y la cantidad de procesadores disponibles en el equipo de cómputo asignado. Estos factores influyen directamente en la eficiencia del procedimiento de simulación y en la cantidad de datos generados.

Sin embargo, para representar estos resultados de forma más gráfica y obtener una visualización clara del comportamiento del flujo simulado, los datos numéricos se procesan. En nuestro caso particular, a partir de 1000 pasos de tiempo, se almacenaron 100 archivos, cada uno conteniendo 10 conjuntos de datos representativos de distintos instantes de la simulación. Los archivos se almacenaron en formato ".vtu", necesario para su visualización. Este mismo procedimiento se aplicó a las 12 simulaciones correspondientes a los distintos modelos utilizados.

4.3. Visualización

Una vez concluido el proceso de simulación, es fundamental realizar una visualización adecuada de los resultados con el fin de interpretar el comportamiento hemodinámico del flujo.

Los resultados se almacenaron como conjuntos de datos correspondientes a diferentes pasos de tiempo, lo que permite generar una representación transitoria del flujo.

Se puede visualizar variables físicas tales como la velocidad del flujo, la presión o el esfuerzo cortante en las paredes vasculares. Esto resulta especialmente útil para identificar regiones de flujo anómalo, recirculaciones o aceleraciones localizadas, las cuales suelen asociarse con condiciones patológicas como la coartación de la aorta o

el síndrome de Marfan.

La capacidad de análisis temporal es crucial para estudiar fenómenos pulsátiles y detectar variaciones que no serían evidentes en visualizaciones estáticas.

Como se mencionó en la sección 4.2.3, se almacenaron 100 archivos por cada simulación, lo que se traduce en 100 instantes de flujo simulado por modelo. Un ejemplo representativo del flujo simulado se muestra en la figura 4.2. Este proceso de visualización se aplicó a los 12 modelos simulados.




Figura 4.2: A) Ejemplo de un instante de flujo simulado del modelo "0008_H_AO_H". B) Visualización con una rotación de 90° . C) Visualización con una rotación de 180° . D) Visualización con una rotación de 270° .

En las figuras 4.3 y 4.4 se muestran, respectivamente, los instantes del flujo correspondientes a los modelos con coartación de la aorta y con síndrome de Marfan.

Gracias a la rotación de los modelos es posible obtener más detalles sobre el




Figura 4.3: A) Ejemplo de un instante de flujo simulado del modelo "0013_H_AO_COA". B) Visualización con una rotación de 90° . C) Visualización con una rotación de 180° . D) Visualización con una rotación de 270° .

comportamiento del flujo aórtico. Esta estrategia, además, permite aumentar la base de datos de imágenes utilizadas para la clasificación, incorporando distintos patrones de comportamiento hemodinámico.

Aunque se generaron 100 archivos por simulación, cada uno correspondiente a un instante de flujo, solo los archivos del 1 al 45 contienen información relevante sobre la dinámica del flujo en cada modelo.




Figura 4.4: A) Ejemplo de un instante de flujo simulado del modelo "0021_H_AO_MFS". B) Visualización con una rotación de 90° . C) Visualización con una rotación de 180° . D) Visualización con una rotación de 270° .

EXPERIMENTOS Y RESULTADOS

En esta sección se presentan los experimentos realizados con el fin de validar el método propuesto, basado en la clasificación de imágenes obtenidas de la simulación del flujo en modelos 3D de aorta. Estos experimentos fueron diseñados para clasificar las imágenes en tres categorías: aortas sanas, con coartación de la aorta y con síndrome de Marfan.

5.1. Base de datos (imágenes)

La Tabla 5.1 presenta la cantidad de imágenes generadas por cada uno de los modelos tridimensionales utilizados en la simulación del flujo aórtico. Cada modelo fue sometido a un proceso de visualización en el que se seleccionaron 45 instantes de flujo relevantes, a partir de los cuales se obtuvieron rotaciones y cortes bidimensionales que dieron lugar a un total de 180 imágenes por modelo. Este conjunto de imágenes se empleó como base para el entrenamiento de las CNN.

En total, resultó en un conjunto completo de 2160 imágenes. Esta cantidad de datos permite establecer un entorno suficientemente robusto para la tarea de clasificación, manteniendo un equilibrio entre clases y asegurando la diversidad de patrones hemodinámicos representados.

Tabla 5.1: Cantidad de imágenes generadas por cada modelo para la clasificación del flujo aórtico.

Modelo	Imágenes generadas	Resolución
0008_H_AO_H	180	3840×2160
0009_H_AO_H	180	3840×2160
0010_H_AO_H	180	3840×2160
0011_H_AO_H	180	3840×2160
0013_H_AO_COA	180	3840×2160
0014_H_AO_COA	180	3840×2160
0016_H_AO_COA	180	3840×2160
0017_H_AO_COA	180	3840×2160
0021_H_AO_MFS	180	3840×2160
0022_H_AO_MFS	180	3840×2160
0023_H_AO_MFS	180	3840×2160
0026_H_AO_MFS	180	3840×2160
Total	2160	—

5.2. Experimentos

Es fundamental ajustar correctamente ciertos parámetros durante el proceso de entrenamiento de las redes neuronales convolucionales para garantizar un desempeño óptimo en la tarea de clasificación de imágenes. Entre los parámetros más relevantes se encuentran el tamaño de las imágenes de entrada, el tamaño del lote o batch size, el número de épocas, la cantidad de iteraciones por época, el valor del learning rate, y la proporción del conjunto de datos destinada a las fases de entrenamiento, validación y prueba.

En este trabajo, se empleó una división de 5 % para entrenamiento, 45 % para validación y 50 % para prueba. Esta configuración, aunque no es la más común en tareas supervisadas, se justifica por las características particulares del conjunto de datos y los objetivos del estudio.

Dado que las imágenes utilizadas fueron generadas mediante simulaciones controladas y etiquetadas a partir de modelos anatómicos bien definidos, el propósito principal del modelo no es alcanzar una generalización máxima, sino evaluar la capacidad de distintas arquitecturas para identificar patrones hemodinámicos relevantes a partir de imágenes sintéticas generadas bajo diferentes condiciones.

La asignación del 45 % del conjunto de datos a la fase de validación permite realizar un ajuste fino a los hiperparámetros y seleccionar la arquitectura más adecuada en función de métricas de rendimiento intermedio, sin comprometer el conjunto de prueba. Por su parte, la decisión de destinar el 50 % de las imágenes a la fase de prueba responde al interés de realizar una evaluación exhaustiva y estadísticamente robusta de los modelos entrenados. Esta estrategia busca maximizar la cantidad de datos no vistos utilizados para comparar el rendimiento entre arquitecturas, reduciendo así la varianza en los resultados y permitiendo una comparación confiable entre las redes evaluadas.

Para asegurar una comparación justa entre las diferentes arquitecturas de CNN, todos los experimentos se llevaron a cabo utilizando los mismos parámetros de entrenamiento. La configuración se resume a continuación:

- **Tamaño de imagen:** 512×512 píxeles.
- **Dispositivo de cómputo:** NVIDIA GeForce RTX 4060 Laptop GPU.
- **Número de épocas:** 50.
- **Número de iteraciones por ejecución:** 700.

- **Tamaño de lote (batch size):** 8.
- **Tasa de aprendizaje (learning rate):** 1×10^{-4} .

Esta configuración fue seleccionada para mantener un equilibrio entre rendimiento computacional y capacidad de aprendizaje, garantizando condiciones homogéneas para la evaluación del desempeño de cada arquitectura CNN utilizada.

Con el objetivo de obtener resultados más robustos y reducir el impacto de la aleatoriedad inherente al proceso de entrenamiento, cada arquitectura fue evaluada mediante 10 ejecuciones independientes. Esta estrategia permite estimar de manera más confiable el rendimiento promedio del modelo.

Dado que factores como la inicialización aleatoria de pesos, el orden de muestreo de los datos y las condiciones del entorno de ejecución pueden influir en los resultados individuales, realizar múltiples ejecuciones proporciona una visión más representativa y general del comportamiento del modelo. Además, esta metodología permite realizar comparaciones más equitativas entre arquitecturas, asegurando que las conclusiones extraídas no dependan de un único experimento aislado.

5.3. Resultados

En este trabajo se evaluó el rendimiento de diferentes arquitecturas de CNN para la tarea de clasificación de imágenes de flujo sanguíneo en la aorta, generadas mediante simulaciones numéricas CFD.

Como se mencionó en la sección anterior, se diseñó una metodología que incluyó 10 ejecuciones independientes por arquitectura, utilizando medición del rendimiento mediante métricas estándar como accuracy, F1-score y tiempo de inferencia por imagen (TII).

5.3.1. Red Compact

Esta arquitectura liviana logró una precisión promedio de 98.63 % y un F1-score de 98.47 % ver tabla 5.2, destacándose por su bajo tiempo de inferencia de 3.45 ms por imagen. Debido a su bajo número de parámetros, es ideal para implementaciones en sistemas o dispositivos clínicos portátiles. A pesar de su simplicidad estructural, demostró una capacidad sobresaliente de generalización.

Tabla 5.2: Resultados obtenidos por la red **Compact** a lo largo de 10 ejecuciones. *Tiempo de ejecución. **Tiempo de inferencia por imagen.

Red	Ejecución	Validación (%)	F1-Score (%)	TE*	TI** (ms)
Compact	1	98.10	98.33	00:02:28	4.186
	2	99.60	99.72	00:02:28	4.113
	3	99.20	98.61	00:02:29	3.802
	4	97.50	97.59	00:02:29	3.854
	5	98.90	97.96	00:02:28	3.227
	6	99.40	99.44	00:03:28	2.92
	7	97.00	96.76	00:02:29	2.65
	8	98.90	98.89	00:02:30	3.238
	9	99.30	98.98	00:03:06	3.259
	10	98.40	98.43	00:03:00	3.255
Promedio	–	98.63	98.47	00:02:41	3.4504

5.3.2. Red Enhanced

Con una precisión de 98.83 % y un F1-score de 98.07 % ver tabla 5.3, esta arquitectura superó ligeramente a CompactNet en precisión pero menor en la métrica F1-score y con un mayor tiempo de inferencia por imagen de 8.66 ms. Su

desempeño más robusto sugiere que capas adicionales pueden beneficiar la extracción de características relevantes en contextos de flujo complejo, como ocurre en modelos patológicos.

Tabla 5.3: Resultados obtenidos por la red **Enhanced** a lo largo de 10 ejecuciones. *Tiempo de ejecución. **Tiempo de inferencia por imagen.

Red	Ejecución	Validación (%)	F1-Score (%)	TE	TII (ms)
Enhanced	1	99.10	98.52	00:05:39	8.240
	2	98.80	97.69	00:05:37	9.038
	3	97.50	96.48	00:05:37	9.147
	4	99.70	98.61	00:05:41	9.172
	5	99.80	99.54	00:06:56	8.596
	6	97.20	96.39	00:06:44	8.871
	7	99.20	97.69	00:06:57	8
	8	98.50	98.61	00:06:51	8.467
	9	98.90	98.24	00:06:46	7.703
	10	99.60	98.89	00:05:13	9.357
Promedio	–	98.83	98.07	00:06:12	8.6591

5.3.3. Red ResNet-50

Esta red profunda fue la que logró los mejores resultados absolutos: 99.97 % de exactitud y 99. % de F1-score ver tabla 5.4. Sin embargo, su desventaja radica en el alto costo computacional, con un tiempo de inferencia por imagen de 135.8 ms, lo que la hace menos viable para aplicaciones en tiempo real. Su profundidad (50 capas) permite una extracción jerárquica de características altamente diferenciadas, lo cual se refleja en su rendimiento.

Tabla 5.4: Resultados obtenidos por la red **ResNet-50** a lo largo de 10 ejecuciones.

Red	Ejecución	Validación (%)	F1-Score (%)	TE	TII (ms)
ResNet-50	1	100.00	99.91	00:37:28	397.493
	2	100.00	99.63	00:53:29	98.899
	3	100.00	100.00	00:48:11	69.643
	4	100.00	99.91	00:53:15	128.474
	5	99.80	99.63	02:02:03	79.698
	6	100.00	99.91	02:30:42	201.08
	7	100.00	100.00	05:14:13	57.842
	8	99.90	99.54	00:39:23	270.126
	9	100.00	99.91	00:40:31	27.405
	10	100.00	99.84	00:42:16	27.257
Promedio	–	99.97	99.84	01:30:09	135.7917

5.3.4. Red ResNet-18

Esta arquitectura más compacta de la familia ResNet alcanzó 98.71 % de accuracy y 98.35 % de F1-score ver tabla 5.5, con un tiempo de inferencia por imagen de 8.02 ms. La ResNet-18 representa un excelente compromiso entre precisión y eficiencia, por lo que es una de las alternativas para implementaciones clínicas en línea o integradas a sistemas de CFD.

Tabla 5.5: Resultados obtenidos por la red **ResNet-18** a lo largo de 10 ejecuciones.

Red	Ejecución	Validación (%)	F1-Score (%)	TE	TII (ms)
ResNet-18	1	99.50	98.52	00:04:50	8.52
	2	98.40	97.50	00:05:46	8.507
	3	98.30	98.61	00:05:43	6.969
	4	99.70	99.26	00:04:34	8.784
	5	99.50	99.54	00:05:35	8.69
	6	98.70	98.24	00:05:18	7.137
	7	97.90	97.69	00:05:37	8.82
	8	98.80	98.61	00:05:34	7.037
	9	98.70	98.06	00:05:44	7.189
	10	97.60	97.50	00:04:50	8.561
Promedio	–	98.71	98.35	00:05:21	8.0214

5.3.5. Red MobileNetV2

Con un enfoque en eficiencia móvil, esta red logró 97.09 % de accuracy y 95.17 % de F1-score ver tabla 5.6, con un tiempo de inferencia competitivo de 7.63 ms. Su menor precisión se puede atribuir a su estrategia de reducción de parámetros mediante capas de profundidad separable, lo que podría limitar su capacidad de capturar patrones hemodinámicos finos.

Tabla 5.6: Resultados obtenidos por la red **MobileNetV2** a lo largo de 10 ejecuciones.

Red	Ejecución	Validación (%)	F1-Score (%)	TE	TII (ms)
MobileNetV2	1	97.30	95.28	00:32:38	5.107
	2	97.80	95.83	00:28:19	7.907
	3	97.60	95.83	00:30:40	8.707
	4	96.60	95.19	00:20:00	8.518
	5	96.90	94.91	00:30:45	8.043
	6	97.30	95.65	00:12:39	5.412
	7	96.60	93.98	00:11:23	8.451
	8	97.30	95.00	00:11:30	8.475
	9	96.80	94.63	00:31:11	7.117
	10	96.70	95.37	00:11:04	8.526
Promedio	–	97.09	95.17	00:22:00	7.6263

5.3.6. Red AlexNet

AlexNet obtuvo 95.77 % de precisión y 96.33 % de F1-score ver tabla 5.7. Aunque su diseño es menos sofisticado que las arquitecturas modernas, aún muestra resultados aceptables, confirmando que incluso redes clásicas pueden aplicarse con éxito a este tipo de problemas si se entrenan adecuadamente.

Tabla 5.7: Resultados obtenidos por la red **AlexNet** a lo largo de 10 ejecuciones.

Red	Ejecución	Validación (%)	F1-Score (%)	TE	TII (ms)
AlexNet	1	96.00	96.57	00:05:38	4.847
	2	95.10	96.11	00:05:23	8.059
	3	95.90	95.83	00:05:12	8.198
	4	96.70	97.41	00:05:36	8.272
	5	94.50	94.44	00:06:12	5.101
	6	95.90	97.13	00:06:57	4.988
	7	93.90	94.54	00:06:18	7.958
	8	96.30	96.67	00:05:20	5.31
	9	97.20	97.69	00:06:19	8.635
	10	96.20	96.94	00:06:32	4.838
Promedio	–	95.77	96.33	00:05:56	6.6206

5.3.7. Matriz de confusión

La matriz de confusión presentada en la Figura 5.1 corresponde a la evaluación del modelo de clasificación del primer entrenamiento de la red Compact, sobre un conjunto de prueba compuesto por 1080 imágenes, distribuidas equitativamente en tres clases: coartación de la aorta (Coa), aorta sana (Healthy) y síndrome de Marfan (SMF). Cada clase contiene 360 imágenes reales, como se observa en los totales por columna.

		GROUND TRUTH			FP		
PREDICTED		360	4	9	13	373	1 Coa
		0	356	5	5	361	2 Healthy
		0	0	346	0	346	3 SMF
	FN	0	4	14	18		
		360	360	360		1080	
	1		2	3			
	Coa	Healthy	SMF				

Figura 5.1: Matriz de confusión de la arquitectura Compact del entrenamiento uno.

En términos generales, el modelo obtuvo un desempeño sobresaliente, con un total de 1062 aciertos sobre 1080 casos, lo que representa una exactitud global del 98.3%. Esta cifra indica que el modelo es capaz de identificar correctamente la clase de la gran mayoría de las imágenes, aunque se presentan diferencias sutiles entre clases.

Para la clase Coa, se registraron 360 verdaderos positivos (TP), sin falsos negativos (FN), pero con 13 falsos positivos (FP): 4 provenientes de la clase Healthy y 9 de la clase SMF. Esto indica que, aunque el modelo no falló al identificar imágenes de Coa, sí hubo casos en los que clasificó incorrectamente otras imágenes como si pertenecieran a esta categoría.

La clase Healthy mostró también un rendimiento alto, con 356 verdaderos positivos. Se detectaron 4 falsos negativos (imágenes de Healthy clasificadas como Coa) y 5 falsos positivos (imágenes de SMF clasificadas como Healthy). A pesar de estos errores menores, el modelo logra diferenciar de manera confiable la anatomía de una aorta sana.

Por otro lado, la clase SMF fue la que presentó el mayor número de errores. Aunque se obtuvieron 346 verdaderos positivos, se contabilizaron 14 falsos negativos: 9 imágenes fueron clasificadas como Coa y 5 como Healthy. Sin embargo, es importante destacar que esta clase no presentó falsos positivos, lo que indica que el modelo rara vez confunde otras clases como SMF, aunque sí puede fallar en su detección.

El análisis global de la matriz revela que la mayoría de los errores están relacionados con la clase SMF, lo que sugiere que las características de flujo simuladas para esta condición pueden solaparse parcialmente con las de otras clases, especialmente con Coa. Este comportamiento se alinea con la complejidad clínica y estructural del síndrome de Marfan, que comparte ciertas alteraciones hemodinámicas con otras patologías aórticas. A pesar de esto, los resultados generales respaldan la capacidad del modelo para realizar una clasificación multiclase precisa a partir de imágenes generadas por simulación CFD.

La Figura 5.2 muestra la matriz de confusión obtenida en uno de los experimentos de clasificación. En esta tarea se consideran tres clases: coartación de la aorta (CoA), aortas sanas (Healthy) y síndrome de Marfan (SMF), representadas en la imagen por los colores amarillo, azul y magenta, respectivamente.

		GROUND TRUTH			FP	
PREDICTED		360	1	0	1	361
		0	359	0	0	359
		0	0	360	0	360
FN		0	1	0	1	
		360	360	360		1080
		1	2	3		
		Coa	Healthy	SMF		

Figura 5.2: Matriz de confusión de la arquitectura ResNet-50 del entrenamiento uno.

Cada celda de la matriz indica la relación entre las predicciones realizadas por el modelo y las etiquetas reales (ground truth). La diagonal principal contiene las predicciones correctas, mientras que las celdas fuera de la diagonal corresponden a errores de clasificación.

- Se clasificaron correctamente 360 imágenes de CoA.
- Se clasificaron correctamente 359 imágenes de aortas sanas (Healthy).
- Se clasificaron correctamente 360 imágenes correspondientes al síndrome de Marfan (SMF).

Respecto a los errores observados:

- Una imagen de CoA fue clasificada erróneamente como Healthy (falso negativo para CoA).
- Una imagen saludable fue clasificada como CoA (falso positivo para CoA).

En total, el modelo cometió únicamente 2 errores en un conjunto de 1080 imágenes (360 por clase), lo que demuestra un alto nivel de precisión y un comportamiento equilibrado entre las clases. Además, las columnas y filas etiquetadas como FP (falsos positivos) y FN (falsos negativos) resumen el número total de errores cometidos por clase, respectivamente.

Este resultado evidencia la capacidad del modelo para distinguir con alta fiabilidad entre los tres tipos de condiciones aórticas simuladas.

5.4. Discusión de resultados

Los resultados obtenidos permiten concluir que el uso de CNN para la clasificación automática de imágenes de flujo aórtico es viable, siempre que las imágenes sean representativas. El alto rendimiento de redes como ResNet-50 y CompactNet sugiere que tanto modelos profundos como livianos pueden alcanzar altos niveles de precisión, aunque con diferentes perfiles de uso.

En términos de aplicabilidad clínica, la eficiencia computacional se convierte en un criterio clave. En contextos donde se requiere retroalimentación inmediata (por ejemplo, en sistemas de apoyo al diagnóstico en quirófano o durante simulaciones en línea), las arquitecturas de bajo tiempo de inferencia como CompactNet o ResNet-18 resultan preferibles. Por otro lado, para análisis postoperatorios o validación offline, modelos más profundos como ResNet-50 ofrecen una mayor fidelidad diagnóstica.

El uso del F1-score como métrica principal fue esencial para garantizar una evaluación balanceada entre precisión y recall, sobre todo en escenarios donde algunas clases patológicas pueden estar menos representadas. Esta métrica, junto con el análisis del tiempo de inferencia y la variabilidad entre ejecuciones, permitió realizar una evaluación integral del desempeño de cada red.

CONCLUSIONES Y TRABAJO FUTURO

6.1. Conclusiones

En este trabajo se desarrolló una metodología para la clasificación de imágenes de flujo sanguíneo en la aorta, obtenidas a partir de simulaciones CFD de modelos 3D generados mediante imágenes clínicas. La integración de redes neuronales convolucionales demostró ser efectiva para diferenciar entre tres condiciones clínicas: aortas sanas, coartación de la aorta y síndrome de Marfan. Se evaluaron múltiples arquitecturas de CNN, destacándose CompactNet por su bajo tiempo de inferencia, lo que la convierte en una candidata viable para aplicaciones en tiempo real. El uso de métricas como F1-score permitió una evaluación balanceada entre precisión y sensibilidad, evidenciando que incluso en escenarios multiclase con base de datos limitada, las CNN pueden lograr altos niveles de desempeño. Asimismo, los resultados obtenidos sugieren que las imágenes generadas por simulación CFD son suficientemente representativas para entrenar modelos robustos sin depender exclusivamente de imágenes clínicas, abriendo así nuevas oportunidades para el uso de inteligencia artificial en contextos simulados.

6.2. Trabajo futuro

A partir de los resultados obtenidos y considerando las limitaciones de este estudio, se proponen diversas líneas de trabajo a futuro que podrían fortalecer y ampliar el alcance de esta investigación:

- Automatización del preprocesamiento: Actualmente, la estandarización y etiquetado de las imágenes derivadas de la simulación se realiza de manera semiautomática. Un siguiente paso lógico sería desarrollar herramientas automáticas de extracción de cortes representativos, segmentación del flujo relevante, y rotulado basado en características geométricas o dinámicas del modelo.
- Segmentación asistida por simulación: La clasificación podría beneficiarse al incorporar módulos previos de segmentación que aislen regiones críticas del flujo, como zonas de alta vorticidad, recirculación o esfuerzo cortante elevado. Estas regiones podrían usarse como entradas específicas para redes especializadas, incrementando la sensibilidad diagnóstica.
- Integración con plataformas clínicas o quirúrgicas: Uno de los objetivos a largo plazo es trasladar esta metodología hacia entornos hospitalarios reales, ya sea como parte de sistemas de planificación quirúrgica personalizados o como herramienta de apoyo al diagnóstico. Esto requerirá validaciones clínicas formales, compatibilidad con formatos, y diseño de interfaces gráficas intuitivas.
- Exploración de arquitecturas más avanzadas: Aunque redes como ResNet y MobileNet ofrecen un rendimiento sólido, futuras investigaciones podrían explorar arquitecturas más recientes como Vision Transformers (ViT), EfficientNet-V2 o modelos híbridos CNN-transformer que podrían captar patrones espaciales y contextuales con mayor profundidad.

Bibliografía

- Ahrens, J., Geveci, B., and Law, C. (2005). Paraview: An end-user tool for large-data visualization. In Hansen, C. D. and Johnson, C. R., editors, *The Visualization Handbook*, pages 717–731. Elsevier.
- An, K., Zhang, F., Ouyang, W., and Pan, X. (2024). Blood flow dynamics in the ascending aorta of patients with bicuspid aortic valve before and after transcatheter aortic valve replacement: a computational fluid dynamics study. *BMC Cardiovascular Disorders*, 24(717):1–6.
- Brown, M. L., Burkhart, H. M., Connolly, H. M., Dearani, J. A., Cetta, F., and Schaff, H. V. (2013). Coarctation of the aorta: Lifelong surveillance is mandatory. *Journal of the American College of Cardiology*, 62(11):1020–1025.
- Capellini, K., Gasparotti, E., Castiglione, V., Palmieri, C., Berti, S., Rizza, A., and Celi, S. (2025). Computational fluid dynamics-driven comparison of endovascular treatment strategies for penetrating aortic ulcer. *Journal of Clinical Medicine*, 14(4):1290.
- Ferziger, J. H., Perić, M., and Street, R. L. (2020). *Computational Methods for Fluid Dynamics*. Springer, Cham, 4 edition. Softcover ISBN: 978-3-319-99691-2.
- Gillis, E., Van Laer, L., and Loeys, B. L. (2013). Genetics of thoracic aortic

- aneurysm: At the crossroad of transforming growth factor- signaling and vascular smooth muscle cell contractility. *Circulation Research*, 113(3):327–340.
- Hall, J. E. (2020). *Guyton and Hall Textbook of Medical Physiology*. Elsevier, 14th edition.
- Hassan, A., Hemeida, A., and Hassan, M. (2022). Image classification based deep learning: A review. *Aswan University Journal of Sciences and Technology*, 2.
- Keshmiri, A. and Andrews, K. (2015). Vascular flow modelling using computational fluid dynamics. In Slevin, M. and McDowell, G., editors, *Handbook of Vascular Biology Techniques*, pages 343–361. Springer.
- Kilner, P. J., Gatehouse, P. D., Firmin, D. N., et al. (2007). Flow measurement by magnetic resonance: a unique asset for cardiovascular imaging. *European Heart Journal*, 28(5):596–604.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6):84–90.
- LaDisa, J. F., Dholakia, R. J., Figueroa, C. A., Vignon-Clementel, I. E., Chan, F. P., Samyn, M. M., Cava, J. R., Taylor, C. A., and Feinstein, J. A. (2011). Computational simulations demonstrate altered wall shear stress in aortic coarctation patients treated by resection with end-to-end anastomosis. *Congenital Heart Disease*, 6(5):432–443.
- Lee, B.-K. (2011). Computational fluid dynamics in cardiovascular disease. *Korean Circulation Journal*, 41(8):423–430.
- Litjens, G., Kooi, T., Ehteshami Bejnordi, B., Setio, A. A. D., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., and Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42:60–88.

- Lundervold, A. S. and Lundervold, A. (2019). An overview of deep learning in medical imaging focusing on mri. *Zeitschrift für Medizinische Physik*, 29(2):102–127.
- Martínez-Jiménez, E. O., Altamirano-Robles, L., Díaz-Hernández, R., and Zapotecas-Martínez, S. (2025). Classification of cfd-generated aortic flow images using neural networks. In López-Monroy, A. P., Rosales-Pérez, A., Carrasco-Ochoa, J. A., Martínez-Trinidad, J. F., and Olvera-López, J. A., editors, *Pattern Recognition*, pages 279–289, Cham. Springer Nature Switzerland.
- Morris, P. D., Narracott, A., von Tengg-Kobligh, H., Silva Soto, D. A., Hsiao, S., Lungu, A., Evans, P., Bressloff, N. W., Lawford, P. V., Hose, D. R., and Gunn, J. P. (2016). Computational fluid dynamics modelling in cardiovascular medicine. *Heart*, 102(1):18–28.
- Nichols, W. W. and O’Rourke, M. F. (2011). *McDonald’s Blood Flow in Arteries: Theoretical, Experimental and Clinical Principles*. CRC Press, 6th edition.
- Nitesh Kumar, Ganesha A, G. H. S. K. and B, G. S. (2023). Advances in the application of computational fluid dynamics in cardiovascular flow. *Cogent Engineering*, 10(1):2178367.
- Pellón, P. L. (2020). Técnicas de diagnóstico automatizado de patologías cardiovasculares mediante imagen hiperespectral. Trabajo fin de máster, Universidad de Cantabria, Escuela Técnica Superior de Ingenieros Industriales y de Telecomunicación.
- Ramzan, F., Khan, M. U. G., Rehmat, A., Iqbal, S., Saba, T., Rehman, A., and Mehmood, Z. (2020). A deep learning approach for automated diagnosis and multi-class classification of alzheimer’s disease stages using resting-state fmri and residual neural networks. *Journal of Medical Systems*, 44(2):37.

- Raza, S., Aggarwal, S., Jenkins, P., Kharabish, A., Anwer, S., Cullington, D., Jones, J., Dua, J., Papaioannou, V., Ashrafi, R., and Mohareem-Elgamal, S. (2023). Coarctation of the aorta: Diagnosis and management. *Diagnostics*, 13(13):2189.
- Schena, M., Testa, F., Bozzetto, M., Remuzzi, A., Lanterna, L. A. A., and Lanzarone, E. (2024). A cfd-based framework to evaluate surgical alternatives in cerebral aneurysms. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 12(1):2325351.
- Shen, D., Wu, G., and Suk, H.-I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19:221–248.
- Sokolova, M. and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4):427–437.
- Song, J., Gao, S., Xie, E., Wang, W., Dai, L., Zhao, R., Zhou, C., Qiu, J., and Yu, C. (2023). Systematic review of the application of computational fluid dynamics for adult aortic diseases. *Reviews in Cardiovascular Medicine*, 24(12):355.
- Sun, Z. and Xu, L. (2014). Computational fluid dynamics in coronary artery disease. *Computerized Medical Imaging and Graphics*, 38(7):651–663.
- Taebe, A. (2024). Computational fluid dynamics in medicine and biology. *Bioengineering*, 11(11).
- Tango, A. M., Monteleone, A., Ducci, A., and Burriesci, G. (2025). Analysis of the haemodynamic changes caused by surgical and transcatheter aortic valve replacements by means fluid-structure interaction simulations. *Computers in Biology and Medicine*, 186:109673.
- Thubrikar, M. M. (1990). *The Aortic Valve*. CRC Press.
- Wilson, N. M., Ortiz, A. K., and Johnson, A. B. (2013). The vascular model

repository: A public resource of medical imaging data and blood flow simulation results. *Journal of Medical Devices*, 7(4):040923.

ARTÍCULOS PUBLICADOS

De esta tesis se derivó un artículo [Martínez-Jiménez et al. \(2025\)](#) que fue aceptado para su presentación en el congreso internacional *The 17th Mexican Conference on Pattern Recognition (MCPR 2025)*, el cual se llevó a cabo en Guanajuato, Gto., México, del 25 al 28 de junio de 2025. Este evento es organizado por el Departamento de Ciencias de la Computación del Centro de Investigación en Matemáticas (CIMAT), en colaboración con la Coordinación de Ciencias Computacionales del Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE), y cuenta con el aval de la *International Association for Pattern Recognition (IAPR)* y de la *Mexican Association for Computer Vision, Neurocomputing and Robotics (MACVNR)*, afiliada a la IAPR.