



**UNIVERSIDAD DE CONCEPCIÓN  
FACULTAD DE INGENIERÍA  
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA**



**RECONSTRUCCIÓN DE IMÁGENES A PARTIR DE MEDICIONES DE  
TOMOGRFÍA POR IMPEDANCIA ELÉCTRICA USANDO ALGORITMOS  
DE DEEP LEARNING**

POR

**Bruno Fernández Arroyo**

Tesis presentada a la Facultad de Ingeniería de la Universidad de Concepción para optar al grado académico de Magíster en Ciencias de la Ingeniería con Mención en Ingeniería Eléctrica

Profesor guía  
Esteban Pino Quiroga

Comisión  
Christopher Flores Jara  
Sebastián Dubó Araya  
Sebastián Godoy Medel

Marzo, 2026  
Concepción, Chile

© 2026 Bruno Fernández Arroyo

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

## **Agradecimientos**

Agradecer a mi familia por siempre ser mi pilar fundamental, apoyarme y creer en mi, sin ellos nada de esto sería posible. A mi Mariangelita por siempre estar para mi con una palabra de aliento, un abrazo cálido y acompañándome a lo largo de todo este camino académico de altos y bajos.

También a mis amigos de laboratorio, por las sacadas de vuelta y momentos de hiperfoco colectivo. A Fabian por tenerme paciencia y enseñarme en todo momento. Al profesor Pino por su ayuda y esmero en el aprendizaje durante estos años. A mis amigos de la u, a mis amigos de la vida, gracias por despejarme la mente, por tan buenos momentos vividos y por tantas risas.

Agradezco a todos quienes contribuyeron para que este trabajo fuera posible, ya sea con palabras de apoyo, compañía, o desde el ámbito académico. A todos, infinitas gracias, siempre estarán en mis recuerdos.

Finalmente agradecer al Centro Nacional de Inteligencia Artificial CENIA FB210017, Financiamiento Basal ANID.

## Resumen

Las enfermedades respiratorias representan una carga crítica de salud pública mundial, lo que motiva la búsqueda de herramientas de monitoreo que superen las limitaciones de costo y accesibilidad de los estándares clínicos actuales. En este contexto, la Tomografía por Impedancia Eléctrica (TIE) surge como una alternativa funcional y no ionizante; sin embargo, los sistemas comerciales existentes suelen ser voluminosos y de alto costo. Por ello, existe una necesidad de desarrollar soluciones portátiles y económicas capaces de resolver con precisión el problema inverso de la TIE, el cual es intrínsecamente no lineal, mal condicionado y sensible al ruido. El presente trabajo de tesis aborda este desafío mediante la reconstrucción de imágenes con algoritmos de *deep learning* aplicados a un dispositivo portátil diseñado en laboratorio, utilizando un fantoma pulmonar para su validación experimental.

La metodología se inició con el diseño y construcción de un fantoma físico equipado con 16 electrodos de cobre para un sistema de adquisición TIE portátil y de bajo costo. Dada la alta demanda temporal que implica la toma de muestras experimentales masivas para el entrenamiento de modelos de inteligencia artificial, se implementó un gemelo digital en COMSOL Multiphysics. Este permitió generar un dataset sintético robusto de 7.992 configuraciones distintas, proporcionando la base necesaria para que las redes aprendieran la física del problema. Posteriormente, se evaluaron tres arquitecturas de deep learning: una Red Neuronal Convolutiva (CNN), una U-Net y un modelo KAN-ViT. Para cerrar la brecha entre la simulación y la realidad, se aplicó una estrategia de *fine-tuning* utilizando 7.115 datos experimentales recolectados en el fantoma físico a partir de 150 configuraciones distintas, adaptando así los modelos al ruido electrónico y las no-idealidades del *hardware* real.

Los resultados obtenidos validan la hipótesis de investigación al demostrar que es posible realizar reconstrucciones precisas y de alta calidad estructural en tiempo real. La arquitectura U-Net destacó como la más robusta, alcanzando un índice de similitud estructural (SSIM) de 0.9453 y un coeficiente de correlación de 0.8785 en datos reales, resultados que superan a los métodos clásicos. El sistema integrado logró una tasa de procesamiento de 1.94 cuadros por segundo, con una latencia de inferencia de apenas 15 ms. Este trabajo no solo aporta una metodología rigurosa para compensar las limitaciones del *hardware* portátil mediante inteligencia artificial, sino que demuestra que la combinación de un fantoma físico y un gemelo digital permite obtener imágenes de alta fidelidad a través de estrategias de *transfer learning*. Estos hallazgos sientan las bases tecnológicas para el futuro desarrollo de herramientas de monitoreo clínico que sean verdaderamente portátiles, seguras y accesibles.

## Abstract

Respiratory diseases represent a critical global public health burden, motivating the search for monitoring tools that overcome the cost and accessibility limitations of current clinical standards. In this context, Electrical Impedance Tomography (EIT) emerges as a functional and non-ionizing alternative; however, existing commercial systems are typically bulky and expensive. Therefore, there is a need to develop portable and affordable solutions capable of accurately solving the EIT inverse problem, which is inherently non-linear, ill-posed, and sensitive to noise. This thesis addresses this challenge through image reconstruction using deep learning algorithms applied to a lab-designed portable device, utilizing a lung phantom for experimental validation.

The methodology began with the design and construction of a physical phantom equipped with 16 copper electrodes for a portable, low-cost EIT acquisition system. Given the high temporal demand involved in collecting massive experimental samples for training artificial intelligence models, a digital twin was implemented in COMSOL Multiphysics. This allowed for the generation of a robust synthetic dataset of 7,992 distinct configurations, providing the necessary foundation for the networks to learn the physics of the problem. Subsequently, three architectures were evaluated: a Convolutional Neural Network (CNN), a U-Net, and a KAN-ViT model. To bridge the gap between simulation and reality, a fine-tuning strategy was applied using 7,115 experimental data points collected from the physical phantom across 150 distinct configurations, thus adapting the models to electronic noise and real-world hardware non-idealities.

The results validate the research hypothesis by demonstrating that accurate, high-structural-quality real-time reconstructions are possible. The U-Net architecture stood out as the most robust, achieving a Structural Similarity Index (SSIM) of 0.9453 and a correlation coefficient of 0.8785 on real data results that outperform classical methods. The integrated system achieved a processing rate of 1.94 frames per second, with an inference latency of just 15 ms. This work not only contributes a rigorous methodology for compensating the limitations of portable hardware through artificial intelligence but also demonstrates that the combination of a physical phantom and a digital twin enables high-fidelity imaging through transfer learning strategies. These findings lay the technological foundations for the future development of clinical monitoring tools that are truly portable, safe, and accessible.

# Tabla de contenidos

<b>Agradecimientos</b> .....	<b>III</b>
<b>Resumen</b> .....	<b>IV</b>
<b>Abstract</b> .....	<b>V</b>
<b>Índice de Tablas</b> .....	<b>IX</b>
<b>Índice de Figuras</b> .....	<b>X</b>
<b>Glosario</b> .....	<b>XII</b>
<b>1 Introducción</b> .....	<b>1</b>
1.1 INTRODUCCIÓN GENERAL .....	1
1.2 HIPÓTESIS .....	2
1.3 OBJETIVO GENERAL .....	2
1.4 OBJETIVOS ESPECÍFICOS .....	2
1.5 ALCANCES Y LIMITACIONES .....	3
1.6 ESTRUCTURA DEL DOCUMENTO .....	3
1.7 PLAN DE TRABAJO .....	3
1.8 PUBLICACIONES.....	4
<b>2 Marco Teórico</b> .....	<b>5</b>
2.1 INTRODUCCIÓN .....	5
2.2 TOMOGRAFÍA POR IMPEDANCIA ELÉCTRICA .....	5
2.2.1 <i>Historia</i> .....	5
2.2.2 <i>Propiedades eléctricas de los tejidos</i> .....	8
2.3 SISTEMAS DE ADQUISICIÓN DE DATOS DE TIE .....	9
2.3.1 <i>Arquitectura del sistema</i> .....	9
2.3.2 <i>Patrones de estimulación</i> .....	10

2.4	MODELADO DEL PROBLEMA MATEMÁTICO .....	11
2.4.1	<i>Formulación del problema directo y discretización por FEM</i> .....	12
2.4.2	<i>Problema inverso</i> .....	13
2.5	ALGORITMOS DE RECONSTRUCCIÓN TRADICIONALES .....	14
2.5.1	<i>Imágenes absoluta y diferencial</i> .....	14
2.5.2	<i>Métodos lineales de un paso (One-step)</i> .....	16
2.5.3	<i>Métodos Iterativos</i> .....	17
2.5.4	<i>Algoritmos de Dispersión Inversa: El Método D-Bar</i> .....	19
2.5.5	<i>Métodos Basados en Datos y Consenso: GREIT</i> .....	19
2.5.6	<i>Software de reconstrucción de imágenes a partir de señales TIE</i> .....	20
2.6	MÉTRICAS DE EVALUACIÓN .....	21
<b>3</b>	<b>Estado del Arte</b> .....	<b>24</b>
3.1	INTRODUCCIÓN .....	24
3.2	APLICACIÓN CLÍNICAS Y EMERGENTES .....	24
3.3	INTELIGENCIA ARTIFICIAL EN TIE .....	29
3.4	TRANSFER LEARNING Y ADAPATACIÓN DE DOMINIO .....	42
3.5	DISCUSIÓN .....	46
<b>4</b>	<b>Metodología</b> .....	<b>49</b>
4.1	INTRODUCCIÓN .....	49
4.2	DISEÑO Y FABRICACIÓN DE FANTOMA PULMONAR .....	49
4.2.1	<i>Diseño geométrico</i> .....	49
4.2.2	<i>Fabricación</i> .....	50
4.3	GEMELO DIGITAL EN COMSOL .....	51
4.3.1	<i>Definición geométrica</i> .....	52
4.3.2	<i>Formulación física y propiedades de materiales</i> .....	53
4.3.3	<i>Protocolo de estimulación y condiciones de borde</i> .....	54
4.3.4	<i>Generación automatizada de la base de datos</i> .....	56
4.4	ARQUITECTURA DE REDES NEURONALES .....	58
4.4.1	<i>Convolutional Neural Network (CNN)</i> .....	60
4.4.2	<i>U-Net</i> .....	61
4.4.3	<i>Kolgomorov-Arnold Visual Transformer (KAN-ViT)</i> .....	62
4.4.4	<i>Evaluación de métricas de rendimiento</i> .....	64
4.5	SISTEMA DE ADQUISICIÓN TIE .....	64

4.5.1	<i>Instrumentación</i> .....	65
4.5.2	<i>Protocolo de adquisición</i> .....	65
4.5.3	<i>Diferencia de dominio</i> .....	66
4.6	ADAPTACIÓN DE DOMINIO MEDIANTE TRANSFER LEARNING .....	67
4.6.1	<i>Adquisición y digitalización de datos reales</i> .....	67
4.6.2	<i>Proceso de Fine-tuning</i> .....	70
4.6.3	<i>Análisis estadístico de resultados</i> .....	71
4.7	INTEGRACIÓN DEL SISTEMA DE INFERENCIA EN TIEMPO REAL .....	72
4.7.1	<i>Arquitectura de comunicación y flujo de datos</i> .....	72
4.7.2	<i>Pre-procesamiento dinámico y reconstrucción de imagen</i> .....	73
<b>5</b>	<b>Resultados</b> .....	<b>76</b>
5.1	INTRODUCCIÓN .....	76
5.2	FANTOMA FÍSICO Y MODELADO EN COMSOL .....	76
5.3	GENERACIÓN DEL DATASET SIMULADO .....	79
5.4	EVALUACIÓN DE LAS ARQUITECTURAS CON DATOS SIMULADOS.....	84
5.5	TOMA DE MUESTRAS Y RESULTADOS DEL FINE-TUNING.....	92
5.6	EVALUACIÓN DEL SISTEMA DE TIEMPO REAL .....	99
<b>6</b>	<b>Discusión y Conclusiones</b> .....	<b>101</b>
6.1	INTRODUCCIÓN .....	101
6.2	DISCUSIÓN .....	101
6.3	CONCLUSIONES .....	108
6.4	TRABAJO A FUTURO .....	109
<b>7</b>	<b>Referencias</b> .....	<b>111</b>

# Índice de Tablas

3.1	TIE comerciales . . . . .	25
4.1	Posibilidades de escenarios para una medición . . . . .	57
5.1	Distribución del dataset simulado tras la partición y el aumento de datos. . . . .	83
5.2	Resultados CNN con datos simulados . . . . .	85
5.3	Resultados U-Net con datos simulados . . . . .	87
5.4	Resultados KAN-ViT con datos simulados . . . . .	89
5.5	Métricas de desempeño con datos simulados entre CNN, U-Net y KAN-ViT . . . . .	92
5.6	Resumen muestras reales totales . . . . .	96
5.7	Resultados finales de las arquitecturas con datos reales realizando fine-tuning . . . . .	97

# Índice de Figuras

2.1	Neumografía por impedancia eléctrica . . . . .	7
2.2	Primer prototipo de TIE . . . . .	7
2.3	Sistema de adquisición de datos Sheffield . . . . .	7
2.4	Patrón de adquisición Sheffield . . . . .	11
2.5	Ejemplos reconstrucción con métodos clásicos . . . . .	18
2.6	Ejemplo de reconstrucción utilizando GREIT . . . . .	20
3.1	TIEs comerciales . . . . .	25
3.2	Análisis por regiones de interés . . . . .	28
3.3	Sistema para detección de cáncer de mamas . . . . .	28
3.4	Ejemplo de reconstrucción utilizando ADALINE . . . . .	30
3.5	Ejemplo de arquitectura CNN . . . . .	31
3.6	Ejemplo de reconstrucción utilizando CNN . . . . .	32
3.7	Ejemplo de arquitectura U-Net . . . . .	33
3.8	Ejemplo de reconstrucción utilizando D-Bar + U-Net . . . . .	34
3.9	Arquitectura de GraphEIT . . . . .	35
3.10	Ejemplo de reconstrucción con GraphEIT . . . . .	36
3.11	<i>Noising y denoising</i> en CDEIT . . . . .	37
3.12	Arquitectura de CDEIT . . . . .	37
3.13	Ejemplos de reconstrucción con CDEIT . . . . .	38
3.14	Comparación entre una MLP y una red KAN . . . . .	39
3.15	Modelo <i>Visual transformer</i> generalizado . . . . .	40
3.16	Modelo KAN-ViT . . . . .	41
3.17	Ejemplo de reconstrucción con KAN-ViT . . . . .	42
3.18	Estructura de entrenamiento MLAE. . . . .	44
3.19	Sistema completo de adquisición y reconstrucción MLAE. . . . .	44
3.20	Arquitectura propuesta TSDL . . . . .	45
3.21	Sistema experimental DLEIP . . . . .	46

4.1	Modelo FEM y CAD fantoma. . . . .	50
4.2	Imagen referencial fantoma torácico . . . . .	52
4.3	Mallado de gemelo digital en COMSOL. . . . .	53
4.4	Protocolo de adquisición TIE. . . . .	55
4.5	Diagrama de flujo del proceso de generación de datos. . . . .	58
4.6	Arquitectura de la Red Neuronal Convolutiva (CNN). . . . .	60
4.7	Arquitectura de la Red U-Net para TIE. . . . .	62
4.8	Arquitectura Kolmogorov-Arnold Visual Transformer (KAN-ViT). . . . .	63
4.9	Diagrama de bloque de sistema TIE utilizado. . . . .	66
4.10	Setup de adquisición de datos reales . . . . .	68
4.11	Prisma triangular y paralelepípedo de PLA . . . . .	69
4.12	Pipeline sistema de reconstrucción en tiempo real. . . . .	75
5.1	Fantoma físico impreso con 16 electrodos. . . . .	77
5.2	Potencial eléctrico y líneas de densidad de corriente gemelo digital. . . . .	77
5.3	Comparación modelo físico y simulado. . . . .	78
5.4	Regresión lineal entre datos simulados y reales. . . . .	79
5.5	Simplificación del fondo en las imágenes de conductividad. . . . .	80
5.6	Variabilidad geométrica del dataset. . . . .	81
5.7	Mapeo logarítmico de conductividades. . . . .	82
5.8	Data augmentation mediante inversión en el eje Y. . . . .	83
5.9	Curvas de aprendizaje y métricas de correlación durante el entrenamiento . . . . .	85
5.10	Ejemplos representativos de reconstrucción mediante la arquitectura CNN . . . . .	86
5.11	Curvas de aprendizaje y métricas de correlación durante el entrenamiento . . . . .	87
5.12	Ejemplos representativos de reconstrucción mediante la arquitectura U-Net . . . . .	88
5.13	Curvas de aprendizaje y métricas de correlación durante el entrenamiento . . . . .	90
5.14	Ejemplos representativos de reconstrucción mediante la arquitectura KAN-ViT . . . . .	91
5.15	Comparación de reconstrucción con datos simulados de GN, TR, CNN, U-Net, KAN-ViT . . . . .	93
5.16	Dispersión temporal de señales en el <i>hardware</i> real. . . . .	94
5.17	Resultados del proceso de digitalización manual del Ground Truth . . . . .	95
5.18	Imagen comparativa de reconstrucción entre GN, TR, CNN, U-Net, KAN-ViT . . . . .	98
5.19	Reconstrucción en tiempo real con U-Net en fantoma . . . . .	100

## **Glosario**

**ADC** Conversor Análogo-Digital

**ANN** Redes Neuronales Artificiales

**CAD** Diseño Asistido por Computadora

**CC** Coeficiente de correlación

**CDEIT** *Conditional Diffusion Model for EIT*

**CEM** Modelo de Electrodo Completo

**CNN** Redes Neuronales Convolucionales

**DAC** Conversor Digital-Análogo

**DDPM** Modelos de Difusión Probabilística de Eliminación de Ruido

**DDS** Síntesis Digital Directa

**DLEIP** Deep-Learning-Based Error Image Prior

**EIP** Neumografía por Impedancia Eléctrica

**EIT** Electrical Impedance Tomography

**EPOC** Enfermedad Pulmonar Obstructiva Crónica

**EQS** electro-cuasi-estático

**FEM** Modelo de Elementos Finitos

**FPGA** Field-Programmable Gate Array

**fps** frames por segundo

**GNN** Redes Neuronales de Grafos

**IA** Inteligencia Artificial

**IEC** Comisión Electrotécnica Internacional

**KAN** Redes de Kolmogorov-Arnold

**MLAE** autoencoder multicapa

**MLP** Perceptrones Multicapa

**MSE** Error Cuadrático Medio

**OTA** Amplificador de Transconductancia Operacional

**PEEP** Presión Positiva al Final de la Espiración

**PLA** ácido poliláctico

**PSNR** Relación Señal-Ruido Pico

**RBF** Redes de Funciones de Base Radial

**RIE** Error relativo de imagen

**RM** Resonancia Magnética

**RMSE** Raíz del Error Cuadrático Medio

**ROI** Regiones de Interés

**SDRA** Síndrome de Dificultad Respiratoria Aguda

**SSIM** Índice de Similitud Estructural

**TC** Tomografía Computarizada

**TIE** Tomografía por Impedancia Eléctrica

**TV** Variación Total

**UCI** Unidad de Cuidados Intensivos

**V/Q** Ventilación/Perfusión

**VCCS** Fuente de Corriente Controlada por Voltaje

**ViT** *Vision Transformer*

## Capítulo 1 Introducción

---

### 1.1 Introducción General

Las enfermedades respiratorias crónicas constituyen un desafío crítico para la salud pública mundial, afectando a más de mil millones de personas y ocasionando una mortalidad anual superior a los cuatro millones de casos. La etiología de estas cifras se vincula estrechamente con factores de exposición ambiental, destacando el impacto de la combustión de biomasa en dos mil millones de personas, sumado a la incidencia de la contaminación del aire exterior y el consumo de tabaco. Ante este panorama, resulta de suma urgencia profundizar en el estudio y mitigación de las patologías pulmonares.

A pesar de los avances en medicina respiratoria, las herramientas diagnósticas tradicionales como la Tomografía Computarizada (TC) o la Resonancia Magnética (RM), aunque son precisas, presentan limitaciones para el monitoreo continuo, además de su alto costo, el uso de radiación y la imposibilidad de ser trasladadas a la cabecera del paciente. En este contexto, surge la TIE como una alternativa prometedora, al ser una técnica de imagenología funcional, no ionizable, que permite visualizar la distribución de la conductividad eléctrica en el tórax mediante inyección de corrientes imperceptibles para el paciente, facilitando el monitoreo dinámico.

Sin embargo, la implementación de la TIE enfrenta un desafío matemático fundamental como problema inverso, el cual es altamente no lineal y mal condicionado. Los algoritmos de reconstrucción clásicos, basados en métodos iterativos o lineales, presentan problemas con la reconstrucción de la conductividad siendo imprecisos en diferentes casos. En los últimos años, la integración de la Inteligencia Artificial (IA) y específicamente el *deep learning*, ha revolucionado este campo. Al entrenar modelos con grandes volúmenes de datos, es posible aprender representaciones complejas de la física del problema, permitiendo reconstrucciones de mejor calidad y precisión que las técnicas tradicionales.

A pesar de los avances teóricos, persiste una brecha en la transición de los modelos de reconstrucción desde los entornos simulados hacia su implementación en *hardware* portátil de bajo costo. Si bien la simulación computacional permite generar grandes volúmenes de datos bajo condiciones ideales, estos modelos a menudo fallan al enfrentarse a las no-idealidades del mundo real, como el ruido electrónico, las variaciones en la conductividad del medio y las imprecisiones en la ubicación de los electrodos. La necesidad de contar con un sistema que no solo sean precisos, sino también que aprendan de estas perturbaciones experimentales, motiva el desarrollo de esta investigación.

Este trabajo aborda este desafío situando al fantoma físico como pilar fundamental de la validación experimental. El fantoma no solo actúa como un sustituto del tórax humano, sino como una herramienta de calibración esencial que permite el proceso de *fine-tuning* de las redes neuronales. Al integrar la variabilidad del modelado simulado con el rigor de las mediciones obtenidas en un entorno controlado físicamente, esta tesis busca demostrar que es posible superar las limitaciones tradicionales de la TIE.

## 1.2 Hipótesis

La aplicación de modelos de *deep learning* permite reconstruir imágenes a partir de mediciones de TIE obtenidas con un dispositivo portátil y de bajo costo, alcanzando un desempeño superior en términos de calidad estructural y velocidad de procesamiento en tiempo real en comparación con métodos tradicionales.

## 1.3 Objetivo General

Desarrollar métodos de reconstrucción de imágenes a partir de mediciones de tomografía por impedancia eléctrica en fantoma con modelos de *deep learning* para visualización en tiempo real.

## 1.4 Objetivos Específicos

- Generar una base de datos experimental de referencia a partir de mediciones en un fantoma físico, con el fin de establecer un estándar de calibración para el ajuste de algoritmos de reconstrucción en condiciones reales.
- Desarrollar un modelo computacional de alta fidelidad basado en el Método de Elementos Finitos para la generación de datos sintéticos masivos en distintas configuraciones.
- Determinar la arquitectura de *deep learning* óptima para la reconstrucción de imágenes TIE, mediante un análisis comparativo entre modelos que cuantifique su robustez estructural, precisión estadística y viabilidad técnica para el monitoreo en tiempo real.

## 1.5 Alcances y Limitaciones

La presente tesis es la continuidad del trabajo de tesis titulado “Sistema de tomografía por impedancia eléctrica como prueba de función pulmonar ambulatoria” por Fabian Alvarado [1]. El dispositivo utilizado se encuentra detallado en ese trabajo, además de en el paper ligado a este [2]. Para el desarrollo de esta investigación no se modificó el *hardware* del dispositivo, mientras que el software se modificó levemente para propósitos de transmisión de datos.

## 1.6 Estructura del documento

El presente informe está dividido en los siguientes capítulos:

1. **Introducción:** Se presenta la hipótesis y objetivos general y específicos, junto al problema que aborda esta tesis.
2. **Marco teórico:** Se realiza una sección que abarca contenidos esenciales para comprender TIE.
3. **Estado del arte:** Se investiga cuales han sido los últimos avances en torno a la TIE.
4. **Metodología:** Se presenta el cómo se realizan todas las actividades en torno a la tesis, desde el diseño del fantoma pulmonar, hasta el sistema de reconstrucción en tiempo real.
5. **Resultados:** Se muestran los resultados obtenidos en cada etapa cubierta por esta tesis.
6. **Discusión y conclusiones:** Se discuten los resultados presentados, el logro de objetivos, las dificultades afrontadas y las mejoras que pueden haber en el futuro.

## 1.7 Plan de trabajo

El plan de trabajo para esta tesis consiste en construir un fantoma pulmonar de 16 electrodos, simular el fantoma en un entorno ideal junto a los patrones de inyección y medición del dispositivo par adquirir datos sintéticos, para con estos datos entrenar tres arquitecturas de redes neuronales. En base a estas arquitecturas, y con datos obtenidos desde el fantoma real con el dispositivo TIE, utilizar técnicas de *transfer learning* para reconstruir finalmente imágenes del propio fantoma con distintas figuras. Luego de esto, juntar este proceso con una interfaz de preprocesamiento e inferencia para la reconstrucción de imágenes en tiempo real en el fantoma torácico con el dispositivo TIE.

## 1.8 Publicaciones

En torno al área de TIE, se colaboró en dos artículos científicos:

- F. Alvarado, B. Fernández, S. Rebolledo and E. J. Pino, “Portable EIT System Validation with a FEM Model-based Resistance Phantom,” *2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Orlando, FL, USA [3]. Se trabajó en el proceso de validación prematura del dispositivo TIE, aportando en la reconstrucción de imágenes y se presentó en la conferencia en formato póster.
- F. Alvarado, B. Fernández, S. Rebolledo and E. J. Pino, “Development and Validation of a Portable EIT System for Real-Time Respiratory Monitoring,” *2024, Sensors* 24, 6642 [2]. Se colaboró en la reconstrucción de imágenes en este trabajo que valida el dispositivo TIE.
- Se envió un artículo a la revista *Inverse Problems* de *IOP Publishing*, titulado “Deep Learning-Based Image Reconstruction for portable EIT device: Enhancing Robustness through Sim-to-Real Transfer Learning”. En este artículo se presenta la metodología y los resultados obtenidos en la presente tesis.

## Capítulo 2 Marco Teórico

---

### 2.1 Introducción

El desarrollo de un sistema de reconstrucción de imágenes a partir de señales TIE requiere una comprensión profunda de la interacción entre los principios físicos del electromagnetismo y las capacidades predictivas de *deep learning*. Este capítulo establece los fundamentos teóricos necesarios para abordar el problema inverso de la TIE. En primer lugar, se analizan las bases fisiológicas y eléctricas del tórax humano que permiten utilizar la conductividad como biomarcador de la función respiratoria. Posteriormente, se describe el marco matemático que rige la propagación de corrientes en medios conductores y la complejidad inherente a la recuperación de información interna a partir de mediciones de voltaje. Finalmente, se introducen los conceptos de redes neuronales convolucionales y arquitecturas avanzadas de inteligencia artificial, las cuales se presentan como la herramienta disruptiva capaz de superar las limitaciones de los métodos numéricos tradicionales en términos de velocidad y resolución espacial.

### 2.2 Tomografía por Impedancia Eléctrica

La TIE se ha consolidado como una modalidad de imagenología médica funcional no invasiva, libre de radiación ionizante y con una alta resolución temporal, características que la posicionan como una herramienta complementaria vital frente a modalidades anatómicas estáticas como la TC o la RM. El principio operativo fundamental de la TIE reside en la inyección de corrientes alternas de baja amplitud y alta frecuencia a través de una serie de electrodos dispuestos en la superficie del cuerpo, para posteriormente medir los potenciales eléctricos resultantes en los límites del dominio bajo estudio. Su objetivo es la reconstrucción de la distribución de la conductividad (o impedancia) interna, aprovechando el hecho fisiológico de que los tejidos biológicos poseen propiedades dieléctricas marcadamente heterogéneas dependiendo de su composición celular, contenido de agua y estado patológico [4].

#### 2.2.1 Historia

El nacimiento de la TIE se sustenta en la comprensión de las propiedades eléctricas de los tejidos biológicos. En bioimpedancia, el concepto fundamental reside en la determinación de la impedancia ( $Z$ ),

que se define como la relación entre el potencial eléctrico aplicado ( $V$ ) y la corriente resultante ( $I$ ). Esta interacción permite estudiar cómo los tejidos reaccionan y se oponen al flujo de corriente en función de su composición, contenido de agua y estructura celular [5].


A principios del siglo XX, se desarrollan los primeros sistemas primitivos de medición de resistencia eléctrica en tejidos, sentando las bases de la Neumografía por Impedancia Eléctrica (EIP). Esta técnica utilizaba dos electrodos para monitorizar la dinámica respiratoria, basándose en el principio de que el incremento del volumen de aire en el tórax reduce la conductividad en relación con el tejido extracelular [6, 7]. Aunque la EIP permitía estimar el ritmo respiratorio y cambios de volumen pulmonar, carecía de resolución espacial, funcionando como una señal de una dimensión de la fisiología torácica [8]. En la Figura 2.1, se puede observar un esquemático de cómo funciona la EIP.

El salto cualitativo hacia la TIE se produjo al intentar llevar la medición puntual hacia la generación de imágenes de la distribución interna de la impedancia. Los primeros sistemas propusieron el diseño de cámaras de impedancia para obtener mediciones espacialmente específicas y proporcionar datos cuantitativos sobre el agua y volumen pulmonar [9]. Este prototipo puede verse en la Figura 2.2. Sin embargo, esta tecnología naciente enfrentó desafíos críticos, como la baja sensibilidad de los electrodos, la distorsión de las líneas de campo y la fuerte competencia de modalidades de imagen anatómica consolidadas, como la radiografía, ultrasonido o TC.

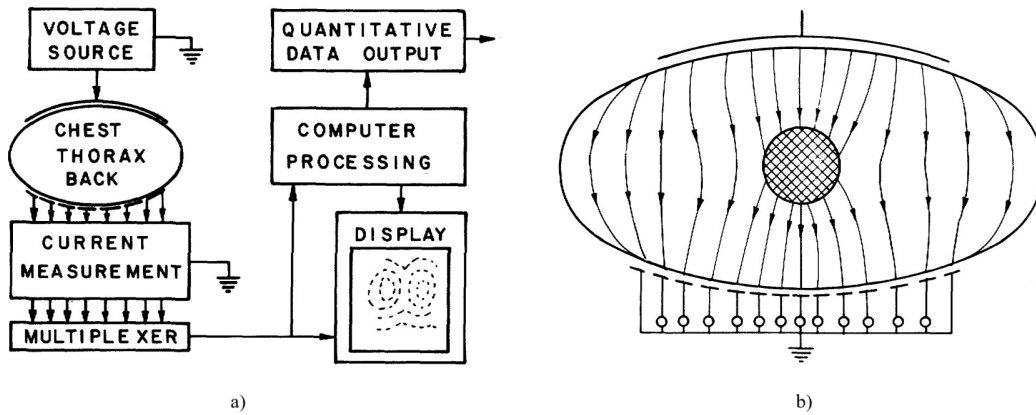
Un hito fundamental en la resolución de estas limitaciones fue la introducción del sistema de adquisición de datos de Sheffield en la década de 1980. Este sistema propuso una configuración de anillo de 16 electrodos alrededor de la región de interés, mejorando significativamente la precisión de las mediciones de potencial en superficie y la sensibilidad para captar cambios sutiles en la conductividad tisular [10]. En la Figura 2.3 se observa el prototipo propuesto por Brown, siendo este el primer prototipo más parecido a lo que conocemos hoy en día como Electrical Impedance Tomography (EIT).

Históricamente, la evolución de la TIE ha transitado desde estas arquitecturas tempranas hacia sistemas complejos de inyección de corriente controlada y demodulación digital. En sus inicios, la técnica enfrentó escepticismo debido a la baja resolución espacial inherente al problema inverso mal condicionado; no obstante, el avance exponencial en la capacidad computacional y el refinamiento de los algoritmos de regularización han permitido superar estas barreras [11].

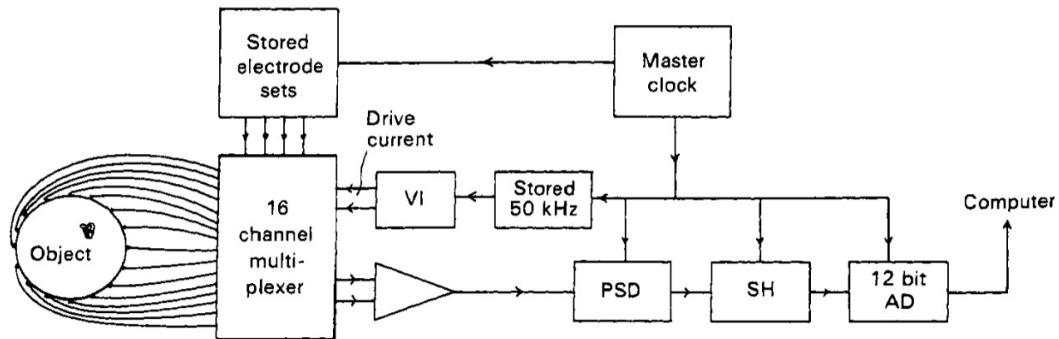
En la actualidad, la TIE se encuentra en una fase de madurez tecnológica. A diferencia de otras técnicas que proporcionan imágenes instantáneas anatómicas, TIE ofrece una ventana continua a la fisiología dinámica, permitiendo observar cambios rápidos como el ciclo respiratorio o el latido cardíaco [12].



**Fig. 2.1:** Representación esquemática de la posición del electrodo en el sistema EIP. Parte delantera (izquierda) y trasera (derecha) del torso de un sujeto [6].



**Fig. 2.2:** a) Diagrama de bloque de cámara de impedancia propuesta. b) Curvatura de las líneas de campo provoca la distorsión del volumen de medición [9].



**Fig. 2.3:** Diagrama de bloque del sistema de adquisición de datos Sheffield, y el nuevo posicionamiento de electrodos propuesto [10].

### 2.2.2 Propiedades eléctricas de los tejidos

El fundamento fisiológico de la TIE reside en el contraste de impedancia intrínseco de los diversos tejidos anatómicos. En términos biofísicos, el tejido se comporta como un conductor heterogéneo cuya respuesta ante un campo eléctrico externo se describe mediante la impedancia compleja  $Z(\omega)$ , definida como:

$$Z(\omega) = R + jX, \quad (1)$$

donde la componente resistiva ( $R$ ) está asociada a la movilidad de los iones libres en los medios intra y extracelulares, mientras que la reactancia ( $X$ ) se deriva de la capacidad de almacenamiento de carga de las membranas celulares y las interfaces macromoleculares [13, 14].

Esta interacción de los campos electromagnéticos con el material biológico no es estática, sino que varía significativamente con la frecuencia de la señal aplicada, un fenómeno conocido como dispersión dieléctrica. La literatura científica, fundamentada en los trabajos de Schwan [15], clasifica estas variaciones en tres regiones principales:

- Dispersión  $\alpha$  en frecuencias bajas ( $mHz$  a  $kHz$ ), vinculada a la difusión iónica superficial y el desplazamiento de contra iones en la doble capa eléctrica celular
- La dispersión  $\beta$  en el rango de radiofrecuencia ( $10kHz$  a  $100MHz$ ), originada por la polarización de interfaces o efecto Maxwell-Wagner donde las membranas actúan como barreras aislantes
- Dispersión  $\gamma$  en el rango de las microondas ( $GHz$ ), asociada a la relajación dipolar de las moléculas de agua libre.

Para las aplicaciones clínicas de la TIE, la dispersión  $\beta$  es la de mayor relevancia, operando típicamente en un rango de frecuencias entre 10 kHz y 1 MHz. En este intervalo, las membranas celulares se comportan como condensadores imperfectos con una reactancia capacitiva inversamente proporcional a la frecuencia ( $X_C = 1/\omega C$ ). A bajas frecuencias, la alta reactancia de la membrana impide que la corriente penetre, llevando el flujo de carga casi exclusivamente al espacio extracelular. Sin embargo, a medida que la frecuencia aumenta, la reactancia disminuye, fenómeno de cortocircuito capacitivo, permitiendo que la corriente atraviese las membranas y fluya a través del espacio intracelular [16].

Este comportamiento diferencial es el que permite la caracterización fisiopatológica del tejido mediante la TIE. Por ejemplo, un tejido edematoso, caracterizado por un exceso de fluido en el intersticio, presentará una resistencia marcadamente baja a frecuencias reducidas. Por el contrario, tejidos con alteraciones morfológicas, como los procesos isquémicos, donde existen variaciones en la densidad celular y la integridad de las membranas, exhibirán un espectro de impedancia alterado respecto al tejido sano [17]. Por tanto, la capacidad de la TIE para discriminar entre estas rutas de conducción eléctrica a través de la dispersión  $\beta$  constituye una gran importancia para la reconstrucción de imágenes con valor clínico.

## 2.3 Sistemas de adquisición de datos de TIE

La arquitectura de un sistema de adquisición de datos para TIE es el componente crítico que determina la precisión de las señales recolectadas y, por ende, la resolución de la imagen final. Un sistema robusto debe integrar de manera eficiente la generación de señales, la inyección de corriente, la conmutación de electrodos y el procesamiento digital de los potenciales de superficie [18].

### 2.3.1 Arquitectura del sistema

El proceso general de adquisición comienza con un controlador digital, típicamente una combinación de Field-Programmable Gate Array (FPGA) y un microcontrolador, que supervisa la generación de la señal y la sincronización de los buses de datos [19, 20]. Para la generación de ondas sinusoidales, se emplea la técnica de Síntesis Digital Directa (DDS), ya sea mediante chips especializados o implementada en FPGA para minimizar costos y maximizar la integración. Esta señal digital se convierte al dominio analógico a través de un Conversor Digital-Análogo (DAC) y se introduce en un convertidor de voltaje a corriente ( $V/I$ ), el cual debe poseer una alta impedancia de salida para asegurar una inyección de corriente constante independientemente de la carga tisular [21].

En cumplimiento con la normativa de seguridad electrofisiológica Comisión Electrotécnica Internacional (IEC) 60601-1-11 [22], la corriente inyectada debe limitarse estrictamente para evitar daños biológicos. Los límites establecidos dependen de la frecuencia de operación:

- Frecuencias bajas (0.1 Hz a 1 kHz): El límite se sitúa en  $100 \mu A_{rms}$ .
- Frecuencias intermedias (1 kHz a 100 kHz): El límite aumenta proporcionalmente a la frecuencia ( $f/10$ ).


- Frecuencias altas (>100 kHz): Se permite una inyección máxima de  $10 \text{ mA}_{rms}$ .

La etapa de recepción obtiene los potenciales de superficie mediante amplificadores de instrumentación de alta precisión y bajo ruido. Debido al patrón de voltajes en forma de “U” (donde la amplitud decrece conforme aumenta la distancia a los electrodos de inyección), se suelen emplear amplificadores de ganancia programable acoplados a controladores automáticos de ganancia para optimizar el rango dinámico de la señal antes de su digitalización por un Conversor Análogo-Digital (ADC) de alta velocidad [23]. Finalmente, la señal se procesa mediante técnicas de demodulación de fase, ya sea de forma analógica o digital, para extraer las componentes de resistencia y reactancia del tejido [24].

### 2.3.2 Patrones de estimulación

La configuración de los patrones de estimulación y medición constituye un factor crítico en la TIE, ya que define la secuencia de inyección de corriente y captura de potenciales que permitirá reconstruir la distribución de la conductividad interna. El protocolo predominante en el ámbito clínico y de investigación es el modo adyacente, también conocido como protocolo de Sheffield [10]. En esta estrategia, la corriente se inyecta a través de un par de electrodos contiguos, mientras que las diferencias de potencial se miden de forma secuencial entre los pares adyacentes restantes. Una vez finalizada la captura para una posición, el par de estimulación se desplaza hacia el siguiente par de electrodos en sentido horario, repitiendo el ciclo hasta completar la rotación total del anillo. Para un sistema estándar de 16 electrodos, este proceso implica que por cada una de las 16 inyecciones se obtienen 13 mediciones de voltaje independientes, lo que resulta en un conjunto de 208 datos totales por cada cuadro o frame de imagen [25]. La Figura 2.4 se puede ver un ejemplo de adquisición con el método Sheffield.

A pesar de su extensa adopción debido a su simplicidad de implementación y alta relación señal-ruido (SNR), el modo adyacente presenta una sensibilidad espacial heterogénea, la cual decrece drásticamente hacia el centro del dominio debido a que la densidad de las líneas de corriente es mucho mayor en la periferia. Para mitigar esta limitación y mejorar la penetración del campo eléctrico, se han propuesto alternativas como los patrones de salto o skip y el patrón opuesto. Los patrones skip consisten en inyectar corriente o medir voltaje saltando uno (skip-1), dos (skip-2) o más electrodos, lo que permite que las líneas de corriente atraviesen regiones más profundas del tórax en comparación con el modo adyacente. Por su parte, el patrón opuesto realiza la inyección entre electrodos situados a  $180^\circ$  de distancia, logrando la mayor uniformidad posible en la sensibilidad central, aunque a costa de obtener señales de voltaje de menor magnitud que exigen una instrumentación más precisa [25].



**Fig. 2.4:** a) Primer patrón de medición, inyectando corriente por E1-E2 y midiendo voltaje de forma adyacente en los demás electrodos restantes. b) Segundo patrón de medición, inyectando corriente por E2-E3 y midiendo voltaje de forma adyacente en los demás electrodos restantes [25]

No obstante, la implementación de estrategias que divergen del modo adyacente presenta desafíos significativos en la práctica actual. La gran mayoría de los algoritmos de reconstrucción, tanto comerciales como de código abierto, así como las plataformas de *hardware* estandarizadas, han sido diseñados y optimizados específicamente para el modo de estimulación adyacente. Esta dependencia algorítmica y técnica hace que la utilización de patrones alternativos sea, en muchos casos, poco viable para aplicaciones clínicas inmediatas, a pesar de sus ventajas teóricas en la detección de anomalías en tejidos profundos. Por consiguiente, el modo adyacente se mantiene como el estándar para el desarrollo y validación de nuevas tecnologías de reconstrucción, incluyendo aquellas basadas en modelos de aprendizaje profundo que requieren bases de datos consistentes y comparables.

## 2.4 Modelado del problema matemático

La base de la TIE radica en describir cómo se comporta un campo eléctrico dentro de un volumen conductor  $\Omega$  a partir de las ecuaciones de Maxwell. Dado que la TIE opera generalmente en bajas frecuencias, se asume un régimen electro-cuasi-estático (EQS). En este estado, la variación del campo magnético es despreciable ( $\nabla \times \mathbf{E} \approx 0$ ), lo que permite definir el campo eléctrico como el gradiente de un potencial escalar ( $\mathbf{E} = -\nabla u$ ), donde  $u$  representa la distribución del potencial eléctrico (voltaje) en el interior del dominio.

Combinando esta definición con la ley de conservación de la carga y las relaciones constitutivas del

medio (Ley de Ohm generalizada  $\mathbf{J} = \gamma\mathbf{E}$ ), se obtiene la ecuación fundamental de la TIE:

$$\nabla \cdot (\gamma(\mathbf{x}, \omega) \nabla u) = 0 \quad \text{en } \Omega, \quad (2)$$

donde  $\gamma = \sigma + i\omega\epsilon$  es la admitividad compleja, que representa tanto la conductividad ( $\sigma$ ) como la permitividad ( $\epsilon$ ) del tejido. Esta ecuación describe el fenómeno de “campo suave”, donde la corriente se difunde por todo el dominio buscando los caminos de menor resistencia, a diferencia de la TC por ejemplo, donde los rayos X viajan en trayectorias lineales (campo duro) [26, 27, 28].

### 2.4.1 Formulación del problema directo y discretización por FEM

El problema directo consiste en determinar el potencial eléctrico  $u$  en el interior y los voltajes  $U$  en los electrodos, asumiendo que la distribución de conductividad  $\sigma$  y las corrientes de inyección  $I$  son conocidas [29]. Para que este modelo sea físicamente preciso, se debe integrar el Modelo de Electrodo Completo (CEM), el cual añade a la ecuación gobernante condiciones de contorno que modelan tres fenómenos críticos:

1. Efecto Shunt: La alta conductividad de los electrodos metálicos frente al tejido genera superficies isopotenciales bajo el contacto.
2. Impedancia de Contacto ( $z_l$ ): Modela la caída de tensión en la interfaz electrodo-tejido debida a efectos electroquímicos.
3. Singularidad del gradiente: En los bordes de los electrodos, la densidad de corriente tiende teóricamente a infinito [30], lo que exige una alta densidad de elementos en la discretización de estas zonas para evitar errores numéricos.

Debido a la geometría irregular de los dominios biológicos, no existe una solución analítica para este sistema, por lo que se emplea el Modelo de Elementos Finitos (FEM). Al discretizar el dominio  $\Omega$  en una malla de elementos finitos y aproximar el potencial mediante funciones de base locales, el problema se transforma en un sistema de ecuaciones lineales algebraicas  $\mathbf{Ax} = \mathbf{b}$ . Aquí, la matriz de rigidez global  $\mathbf{A}$  presenta una estructura de bloques característica:

$$\mathbf{A} = \begin{pmatrix} \mathbf{G} + \mathbf{B} & \mathbf{C} \\ \mathbf{C}^T & \mathbf{D} \end{pmatrix} \quad (3)$$

donde el bloque  $G$  representa la conducción interna del volumen, mientras que los bloques  $B$ ,  $C$  y  $D$  incorporan la física de los electrodos definida por el CEM. La resolución de este sistema permite obtener los voltajes predichos para cualquier configuración de conductividad dada [30].

## 2.4.2 Problema inverso

El problema inverso constituye el núcleo de la TIE y consiste en estimar la distribución de conductividad interna  $\sigma$  a partir de los voltajes medidos en la frontera ( $V_{meas}$ ). Matemáticamente, esto se formula como un problema de optimización donde se busca minimizar el funcional de error entre las mediciones reales y las predicciones generadas por el modelo directo  $F(\sigma)$ :

$$\hat{\sigma} = \arg \min_{\sigma} \left( \frac{1}{2} \|F(\sigma) - V_{meas}\|^2 + \lambda R(\sigma) \right) \quad (4)$$

Este proceso presenta tres desafíos fundamentales que condicionan la calidad de la imagen:

- **No linealidad:** El mapa directo  $F(\sigma)$ , que surge de la resolución del sistema de elementos finitos (FEM), no posee una relación lineal con la conductividad. Un cambio local en  $\sigma$  altera la distribución global del potencial  $u$ , lo que obliga a emplear métodos iterativos de resolución.
- **Mal condicionamiento:** La TIE es extremadamente sensible al ruido de medición. Debido a la naturaleza difusiva de la corriente, variaciones mínimas en  $V_{meas}$  pueden interpretarse erróneamente como grandes cambios en la conductividad interna, generando artefactos inestables.
- **Matriz de Sensibilidad (Jacobiana):** Para guiar la optimización, se requiere calcular la matriz  $J$ , que representa la derivada del potencial respecto a la conductividad ( $\partial V / \partial \sigma$ ). Su cálculo se optimiza mediante el método adjunto, basado en el teorema de reciprocidad, el cual permite obtener la sensibilidad de todos los elementos de la malla utilizando solo dos soluciones del problema directo por cada configuración de inyección [31].

Para estabilizar la reconstrucción, se introduce el término de regularización  $R(\sigma)$  ponderado por el parámetro  $\lambda$ . Los enfoques más comunes son:

- **Regularización de Tikhonov ( $L_2$ ):** Penaliza la magnitud de la solución o su suavidad espacial. Es altamente efectiva para estabilizar el problema ante ruido, aunque tiende a producir imágenes con bordes difuminados [32].

- Variación Total (TV,  $L_1$ ): Penaliza la norma  $L_1$  del gradiente, lo cual permite la existencia de discontinuidades agudas. Es la estrategia preferida cuando se busca preservar bordes definidos e interfaces claras entre órganos con propiedades eléctricas dispares [33].
- Método D-Bar: Un enfoque directo y no iterativo basado en la teoría de dispersión inversa. Es matemáticamente elegante y robusto, pero actúa efectivamente como un filtro paso bajo no lineal en el dominio de la frecuencia espacial, eliminando intrínsecamente los detalles finos necesarios para un diagnóstico preciso [34].

La efectividad de las estrategias de regularización mencionadas depende críticamente del parámetro  $\lambda$ , el cual actúa como un factor de equilibrio entre la fidelidad a los datos medidos y la estabilidad matemática de la solución. Una selección inadecuada de este hiperparámetro puede derivar en una sobre-regularización, que elimina detalles anatómicos esenciales bajo un suavizado excesivo, o en una sub-regularización, donde el ruido de medición se amplifica hasta generar artefactos inestables que oscurecen la señal real [35].

## 2.5 Algoritmos de reconstrucción tradicionales

La reconstrucción de imágenes en TIE es un ejercicio de inferencia estadística y física bajo condiciones de alta incertidumbre. Para abordar los algoritmos de reconstrucción con el rigor necesario, es necesario establecer primero las distinciones fundamentales que rigen la adquisiciones de datos, específicamente la diferencia entre imágenes absoluta y diferencial.

### 2.5.1 Imágenes absoluta y diferencial

La arquitectura de cualquier algoritmo de TIE está dictada primariamente por la naturaleza de los datos de entrada y el objetivo clínico o industrial de la imagen. La literatura científica distingue tajantemente entre la imagenología absoluta (estática) y la imagenología de diferencia (dinámica), siendo esta última la predominante en aplicaciones clínicas debido a las severas limitaciones impuestas por los errores de modelado [36].

La imágenes absolutas aspiran a reconstruir la distribución espacial absoluta de la conductividad  $\sigma(x, y)$  a partir de un único conjunto de medidas de voltaje  $V_{meas}$ . Matemáticamente, esto implica invertir el operador directo  $F(\sigma)$  tal que:

$$\sigma = F^{-1}(V_{meas}) \quad (5)$$

Sin embargo, el éxito de esta inversión depende críticamente de la precisión del modelo directo. Investigaciones fundamentales han demostrado que los errores en la estimación de la resistividad absoluta están dominados por incógnitas en el modelado directo. En particular, la incertidumbre en la geometría exacta del contorno del cuerpo  $\partial\Omega$  y, más críticamente, la posición exacta de los electrodos, introduce errores sistemáticos en  $V_{meas}$  que son indistinguibles de las variaciones de conductividad interna [37].

Como señala el estudio anterior mencionado sobre errores en reconstrucción absoluta, una desviación milimétrica en la posición de un electrodo o una suposición incorrecta sobre la forma del tórax (por ejemplo, modelarlo como un círculo perfecto en lugar de una elipse anatómica) genera artefactos de gran magnitud cerca de los límites, que a menudo oscurecen completamente las características internas de interés. Por tanto, la imagenología absoluta requiere o bien una precisión geométrica extrema, difícil de obtener en tejidos vivos y deformables, o algoritmos sofisticados capaces de compensar o resolver simultáneamente la geometría y la conductividad, lo cual incrementa el mal condicionamiento del problema [38].

Por otra parte, las imágenes diferenciales se han establecido como el estándar para aplicaciones clínicas como el monitoreo de la ventilación pulmonar. Este enfoque no busca el valor absoluto de  $\sigma$ , sino el cambio en la conductividad  $\Delta\sigma$  ocurrido entre dos instantes de tiempo  $t_1$  (referencia) y  $t_2$  (actual).

$$\Delta\sigma \approx J^{-1}(V_{t_2} - V_{t_1}), \quad (6)$$

donde  $J$  representa la matriz de sensibilidad o Jacobiana, calculada habitualmente sobre una distribución de conductividad de referencia. Es importante notar que, debido al mal condicionamiento del problema, el término  $J^{-1}$  denota generalmente una inversa regularizada.

La ventaja decisiva de este método radica en la cancelación de errores sistemáticos. Si asumimos que la geometría del cuerpo, la posición de los electrodos y las impedancias de contacto electrodo-piel permanecen constantes o varían muy lentamente comparado con el fenómeno fisiológico de interés (como la respiración o el ciclo cardíaco), la sustracción  $V_{t_2} - V_{t_1}$  elimina eficazmente los errores introducidos por el modelo geométrico inexacto [39].

El análisis de la literatura sugiere que la preferencia por la imagenología diferencial es una respuesta funcional a la dificultad de obtener estimaciones de resistividad absoluta fiables [37]. Incluso algoritmos

avanzados como D-Bar, que teóricamente permiten reconstrucción absoluta, demuestran una robustez superior ante errores de posición de electrodos cuando se aplican en modo diferencial, superando en estabilidad a los métodos regularizados tradicionales en presencia de incertidumbre geométrica [40]. No obstante, la dependencia de una medida de referencia limita su uso a la monitorización de cambios, siendo ciega a patologías estáticas preexistentes a menos que se induzca un contraste dinámico.

## 2.5.2 Métodos lineales de un paso (One-step)

La necesidad de procesamiento en tiempo real con *hardware* limitado impulsó el desarrollo de métodos no iterativos que asumen una relación lineal entre pequeños cambios en la conductividad  $\delta\sigma$  y cambios en el potencial de frontera  $\delta V$ :

$$\delta V \approx J\delta\sigma, \quad (7)$$

donde  $J$  es la matriz Jacobiana o de sensibilidad.

- Retroproyección (Back-projection): El algoritmo de Retroproyección, específicamente la variante desarrollada por Barber y Brown en Sheffield (Sheffield Back-projection), fue el motor de los primeros sistemas de TIE clínicos en los años 80 y 90. A diferencia de la retroproyección en tomografía de rayos X, donde la señal se retroproyecta a lo largo de líneas rectas, en TIE la corriente se difunde. Barber y Brown propusieron una aproximación heurística brillante: retroproyectar la señal a lo largo de las líneas equipotenciales que existirían en un medio homogéneo. Dado que las perturbaciones de conductividad alteran el potencial medido principalmente a lo largo del camino de la corriente inyectada, se asume que la región entre dos líneas equipotenciales contribuye uniformemente al voltaje medido [38, 41].

El algoritmo aplica una matriz de retroproyección  $B$  precalculada a los voltajes normalizados. Aunque computacionalmente es extremadamente eficiente (solo multiplicaciones matriciales), la suposición de que las equipotenciales permanecen fijas (aproximación de campo duro) es físicamente incorrecta. Esto resulta en imágenes con baja resolución espacial, artefactos en forma de estrella y una incapacidad para resolver múltiples objetos cercanos o complejos. Además, su formulación original estaba limitada a geometrías circulares 2D, requiriendo transformaciones complejas para aplicarse a anatomías reales. A pesar de ello, su robustez ante errores de medición lo mantuvo vigente por décadas para la monitorización cualitativa [42].

- NOSER (Newton's One-Step Error Reconstructor): El algoritmo NOSER, introducido por Cheney et al. [43], marcó la transición hacia una formulación algebraica formal basada en la minimización de errores de mínimos cuadrados. Se concibe como el primer paso de un método de Newton-Raphson, partiendo de una conductividad constante inicial.

La contribución fundamental de NOSER reside en su manejo del mal condicionamiento de la matriz Hessiana aproximada ( $H \approx J^T J$ ). Debido a la física de la difusión de corriente, la sensibilidad en el centro del dominio es órdenes de magnitud menor que en la periferia, haciendo que  $J^T J$  sea casi singular. NOSER propone una regularización específica:

$$\Delta\sigma = (J^T J + \lambda\Psi)^{-1} J^T \delta V, \quad (8)$$

donde  $\Psi$  es una aproximación diagonal de  $J^T J$ . Esta elección tiene un profundo significado físico: normaliza la sensibilidad. Sin esta regularización ponderada por sensibilidad, el algoritmo tendería a colocar todas las perturbaciones cerca de los electrodos (donde la sensibilidad es máxima) para minimizar el error residual rápidamente. Al penalizar más fuertemente los cambios en zonas de baja sensibilidad (o viceversa, dependiendo de la interpretación de la varianza a priori), NOSER logra estabilizar la solución en todo el dominio [43].


### 2.5.3 Métodos Iterativos

Cuando las perturbaciones de conductividad son grandes (invalidando la linealización) o se requiere mayor precisión espacial, se recurre a métodos iterativos que minimizan una función de costo penalizada:

$$\Phi(\sigma) = \|V_{meas} - F(\sigma)\|^2 + \lambda^2 R(\sigma) \quad (9)$$

- Algoritmo de Gauss-Newton (GN): El método de Gauss-Newton es el estándar de oro para resolver el problema de mínimos cuadrados no lineal en TIE. En cada iteración  $k$ , se linealiza el problema alrededor de la solución actual  $\sigma_k$  y se calcula una actualización  $\Delta\sigma_k$ .

Para garantizar la estabilidad de esta inversión, se integra habitualmente la regularización de Tikhonov basada en la norma  $L_2$ , la cual puede implementarse mediante una matriz de identidad que penaliza las amplitudes elevadas en favor de soluciones de energía mínima, o a través de un operador Laplaciano que restringe las disparidades entre elementos vecinos bajo la premisa de que la conductividad en tejidos biológicos presenta una distribución suave.



**Fig. 2.5:** Comparación de reconstrucción de imágenes a partir de señales TIE de un fantoma. De izquierda a derecha: Gauss-Newton, Tikhonov, NOSER, Back-projection [47].

Sin embargo, a pesar de su robustez y convergencia cuadrática, esta estrategia impone un compromiso significativo en la fidelidad de la imagen debido al fenómeno de suavizado excesivo o *oversmoothing*. Esta limitación intrínseca de las normas cuadráticas difumina las interfaces anatómicas donde existen contrastes eléctricos abruptos, como la transición entre el corazón y el tejido pulmonar aireado, lo que deriva en una pérdida de resolución espacial y en una definición deficiente de los bordes de los órganos [44, 45].

- Regularización de Variación Total (TV): Como respuesta a las limitaciones del suavizado excesivo, la comunidad científica ha adoptado la regularización de Variación Total (TV), la cual penaliza la norma  $L_1$  del gradiente de la conductividad a través del funcional  $R_{TV}(\sigma) = \int_{\Omega} |\nabla \sigma| d\Omega$ .

A diferencia de la norma  $L_2$ , que suprime drásticamente cualquier gradiente elevado, la norma  $L_1$  permite la existencia de discontinuidades o saltos abruptos siempre que estos sean escasos dentro del dominio. Esta propiedad conduce a la reconstrucción de imágenes con una apariencia de bloques que preservan la nitidez en las transiciones entre tejidos, ofreciendo un marco fisiológicamente más coherente para la segmentación de órganos y facilitando su posterior segmentación.

No obstante, la implementación numérica de la TV presenta desafíos considerables, principalmente debido a que el funcional de valor absoluto no es diferenciable en el origen, lo que invalida el uso directo de algoritmos de gradiente convencionales [46].

En la Figura 2.5 se puede observar cuatro reconstrucciones utilizando los cuatro algoritmos anteriormente mencionados.

## 2.5.4 Algoritmos de Dispersión Inversa: El Método D-Bar


A diferencia de los esquemas de optimización iterativa, el método D-Bar constituye un enfoque directo y no lineal basado en la teoría de dispersión inversa. Este algoritmo aborda el problema de reconstrucción mediante la transformación de las mediciones de frontera en datos de dispersión en el plano complejo, resolviendo una ecuación diferencial parcial para recuperar la conductividad de forma global [48].

La principal virtud del método D-Bar radica en su estabilidad y predictibilidad computacional. Al ser un método no iterativo, no requiere de una estimación inicial ni enfrenta el riesgo de quedar atrapado en mínimos locales, problemas recurrentes en los métodos de tipo Gauss-Newton. Además, es capaz de capturar la naturaleza no lineal del problema de Calderón de manera rigurosa, lo que teóricamente lo hace más robusto ante grandes contrastes de conductividad [49].

Sin embargo, su implementación práctica con datos experimentales presenta un compromiso crítico entre estabilidad y resolución. Para manejar el ruido intrínseco de las señales de TIE, el algoritmo requiere un truncamiento en el dominio espectral que actúa físicamente como un filtro paso bajo extremadamente agresivo. Si bien este filtrado garantiza que el algoritmo no genere artefactos inestables ante el ruido, tiene como consecuencia directa la eliminación de las altas frecuencias espaciales. Por ello, las imágenes obtenidas mediante D-Bar son reconocidas por su alta robustez pero baja resolución, presentando bordes difuminados que dificultan la identificación de detalles anatómicos finos [34].

## 2.5.5 Métodos Basados en Datos y Consenso: GREIT

A mediados de la década de 2000, la proliferación de algoritmos y parámetros de regularización ad-hoc dificultaba la comparación de estudios clínicos entre diferentes centros de investigación. En respuesta, un consorcio internacional desarrolló el GREIT (Graz Consensus Reconstruction Algorithm for EIT) [50]. Este método introdujo un cambio desde la derivación puramente analítica de la matriz de reconstrucción  $R$  hacia un enfoque de aprendizaje supervisado lineal. En lugar de depender exclusivamente de la regularizada del Jacobiano, GREIT propone optimizar la matriz de reconstrucción a través de un entrenamiento previo basado en conjuntos de datos simulados. Este proceso implica la movilización de pequeños objetivos de conductividad a través de mallas de elementos finitos que replican la anatomía real (como tórax de adultos o neonatos) permitiendo que el algoritmo aprenda a relacionar la perturbación real o ground truth con las señales de voltaje capturadas, incluso en presencia de ruido.



**Fig. 2.6:** Imagen reconstruida con GREIT de tres distintas respiraciones de un neonato [51].

La configuración de esta matriz de reconstrucción se rige por un conjunto de figuras de mérito definidas por consenso experto, diseñadas para estandarizar la calidad de la imagen resultante. Entre estas métricas destaca la Respuesta de Amplitud (AR), que garantiza una sensibilidad uniforme en todo el dominio para corregir la tendencia natural de la TIE a atenuar los cambios en el centro, y el Error de Posición (PE), que asegura la coincidencia espacial entre la reconstrucción y la ubicación real del objeto. Asimismo, el algoritmo busca mantener una Resolución (RES) constante, minimizar la Deformación de Forma (SD) para evitar distorsiones geométricas y suprimir el Ringing, que consiste en la aparición de artefactos de oscilación o lóbulos negativos alrededor de las áreas de interés. En la Figura 2.6 se puede ver la reconstrucción de imágenes a partir de mediciones TIE de un neonato utilizando GREIT.

En la actualidad, GREIT representa el gold standard para la monitorización pulmonar clínica debido a su capacidad de procesamiento en tiempo real y su comportamiento altamente predecible, lo que genera la confianza necesaria para su implementación en entornos hospitalarios. Sin embargo, es importante considerar que, al ser un método linealizado y entrenado bajo supuestos anatómicos específicos, su capacidad de generalización puede verse comprometida ante patologías complejas o geometrías que difieran significativamente de los escenarios contemplados en los datos de entrenamiento originales.

### **2.5.6 Software de reconstrucción de imágenes a partir de señales TIE**

La implementación de los algoritmos de reconstrucción requiere de un marco computacional capaz de gestionar mallas de elementos finitos complejas, resolver el problema directo y optimizar el problema inverso. A lo largo de las últimas décadas, la comunidad científica ha desarrollado herramientas de código abierto que han estandarizado la investigación en el área.

- EIDORS (*Electrical Impedance and Diffuse Optical Tomography Reconstruction Software*) es, indiscutiblemente, el ecosistema más influyente en la investigación de TIE a nivel global. Desarrollado en MATLAB/Octave, este proyecto de código abierto proporciona un marco modular que permite a los investigadores modelar geometrías 2D y 3D, simular protocolos de inyección y probar diversos algoritmos de reconstrucción [52].

La potencia de EIDORS radica en su extensa biblioteca de modelos precalculados y su capacidad para implementar desde los métodos más antiguos, como la Retroproyección de Sheffield, hasta el estándar clínico actual, GREIT. Su estructura permite una alta reproducibilidad, lo que lo ha convertido en la referencia obligatoria para comparar nuevos algoritmos frente a los métodos clásicos de Gauss-Newton y regularización de Tikhonov.

- Con el auge de la Inteligencia Artificial y la ciencia de datos, ha surgido la necesidad de herramientas integradas en entornos de programación más modernos. pyEIT es una biblioteca de código abierto basada en Python que ofrece una alternativa ligera y eficiente a EIDORS.

A diferencia de su contraparte en MATLAB, pyEIT está diseñado para integrarse fácilmente con bibliotecas de aprendizaje profundo como PyTorch o TensorFlow. Aunque su biblioteca de modelos anatómicos es menos extensa que la de EIDORS, proporciona implementaciones robustas de algoritmos como Back-projection, Gauss-Newton y GREIT, facilitando la creación de *pipelines* de datos para el entrenamiento de redes neuronales directamente en el lenguaje predominante de la IA actual [53].

## 2.6 Métricas de evaluación

Para evaluar la calidad de las imágenes reconstruidas existen distintos métodos de evaluación comúnmente utilizados en investigaciones de TIE.

Índice de Similitud Estructural (SSIM) [54] es una métrica que considera la luminancia, contraste y estructura de la imagen, por lo que ayuda a evaluar los cambios de calidad, por ejemplo en la aparición de bordes y textura. Siendo  $X$  la imagen actual, e  $Y$  la imagen reconstruida, entonces se tiene:

$$(SSIM)(X, Y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (10)$$

En esta ecuación,  $\mu$  representa los valores promedio,  $\sigma^2$  las varianzas,  $\sigma_{xy}$  la covarianza y  $c_1, c_2$  son constantes de estabilidad para evitar divisiones por cero.

Coeficiente de correlación (CC) es una métrica que cuantifica la fuerza y dirección de la relación lineal entre las dos imágenes píxel a píxel. Su valor oscila entre -1 y 1, donde 1 indica una coincidencia anatómica perfecta. Se calcula de la siguiente manera:

$$CC = \frac{\sum_{i=1}^n (\hat{\sigma}_i - \bar{\hat{\sigma}})(\sigma_i - \bar{\sigma})}{\sqrt{\sum_{i=1}^n (\hat{\sigma}_i - \bar{\hat{\sigma}})^2 \sum_{i=1}^n (\sigma_i - \bar{\sigma})^2}} \quad (11)$$

Donde  $\hat{\sigma}_i$  es el valor de conductividad predicho por el modelo para el píxel o nodo,  $i$ .  $\sigma_i$  es el valor de conductividad real (*ground truth*) para el píxel o nodo  $i$ ,  $\bar{\hat{\sigma}}$  y  $\bar{\sigma}$  son los valores promedio de las distribuciones de conductividad predicha y real respectivamente, y  $n$  es el número total de píxeles en la imagen o nodos en la malla de elementos finitos.

El Error relativo de imagen (RIE), computa el error entre nuestro *ground truth* y la imagen reconstruida comparando los valores de los píxeles. Un valor 0 es una reconstrucción perfecta, y se define así:

$$RIE = \frac{\|Y - X\|_2}{\|X\|_2} \quad (12)$$

El Error Cuadrático Medio (MSE) es una de las métricas más utilizadas para cuantificar la diferencia promedio entre los píxeles de la imagen reconstruida ( $Y$ ) y la imagen real ( $X$ ). Al elevar al cuadrado las diferencias, esta métrica penaliza con mayor severidad los errores grandes, lo que ayuda a los optimizadores de las redes neuronales a corregir desviaciones significativas durante el entrenamiento. Por su parte, el Raíz del Error Cuadrático Medio (RMSE) es simplemente la raíz cuadrada del MSE.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - X_i)^2 \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - X_i)^2} \quad (14)$$

La Relación Señal-Ruido Pico (PSNR) es una métrica clásica utilizada para evaluar la calidad de la reconstrucción frente al ruido de fondo y los errores de aproximación. En el contexto de la TIE, cuantifica la claridad de la imagen de conductividad generada en relación con el error cuadrático medio respecto a la verdad de campo.

$$PSNR = 10 \cdot \log_{10} \left( \frac{MAX_I^2}{MSE} \right) \quad (15)$$

Siendo  $I$  la imagen o el conjunto de datos (señal) que se está evaluando. En el contexto de la TIE, se refiere a la distribución de conductividad reconstruida. Y  $MAX$  el valor máximo posible que puede tomar un píxel en la imagen  $I$ . Generalmente, en la literatura, se normalizan en el rango de  $[0, 1]$  para propósitos de evaluación, como en [55].

## Capítulo 3 Estado del Arte

---

### 3.1 Introducción

El presente capítulo ofrece un análisis detallado de la evolución de las técnicas de reconstrucción de imágenes en TIE, situando esta tesis dentro del panorama científico actual. La revisión comienza examinando los enfoques tradicionales, basados en modelos matemáticos deterministas que, si bien han sido el estándar durante décadas, presentan limitaciones críticas frente a la naturaleza no lineal y mal condicionada del problema inverso de la TIE.

Posteriormente, se explora el cambio de paradigma hacia el aprendizaje profundo (*deep learning*), analizando cómo diversas arquitecturas han logrado superar las barreras de los métodos clásicos mediante la extracción de características y la optimización de los tiempos de cómputo. El análisis se enfoca especialmente en la transición desde entornos puramente simulados hacia la validación experimental en tiempo real, identificando las brechas metodológicas existentes en el uso de *hardware* portátil de bajo costo.

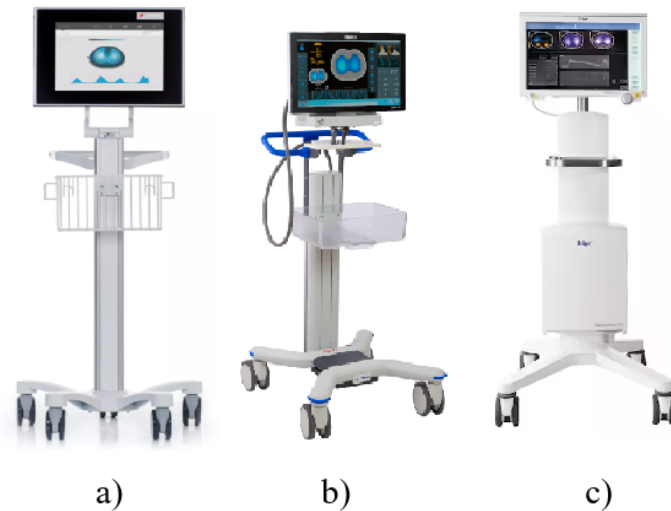
### 3.2 Aplicación clínicas y emergentes

Desde el nacimiento de los primeros prototipos, la evolución de la TIE ha estado marcada por una transición gradual desde aplicaciones experimentales hacia usos clínicos consolidados. Actualmente, la aplicación clínica más consolidada y de mayor impacto es el monitoreo continuo de la ventilación mecánica pulmonar en Unidad de Cuidados Intensivos (UCI), donde la técnica se ha validado como una herramienta fundamental para la optimización de la ventilación y prevención del daño pulmonar inducido por ventilador [56]. Esta consolidación se refleja en el incremento sostenido de publicaciones científicas y en la diversificación de equipos comerciales que existen en la actualidad para uso médico.

El primer sistema TIE con propósitos comerciales fue detallado por Barber y Brown [10], sentando las bases para una industria que hoy cuenta con múltiples fabricantes especializados tanto en el ámbito clínico como en el de investigación. Como se observa en la Tabla 3.1 y la Figura 3.1, los dispositivos actuales presentan variaciones significativas en su arquitectura de *hardware* y *software*, destacando diferencias en el número de electrodos (típicamente entre 16 y 32) y en los algoritmos de reconstrucción

Marca	Sistema TIE	Número de electrodos	Algoritmo de Reconstrucción
Swisstom AG	BB2	32	GREIT
Timpel SA	Enlight	32	Newton-Raphson
CareFusion	Goe-MF II	16	Sheffield
Drager Medical	PulmoVista 500	16	Newton-Raphson
Maltron Inc	Mark 1	16	Sheffield

**Tabla 3.1:** TIE comerciales, la cantidad de electrodos y que algoritmo de reconstrucción de imágenes usan [12].



**Fig. 3.1:** TIEs comerciales. a) Swisstom AG, b) Timpel SA, c) Drager Medical.

empleados, que oscilan desde métodos lineales como GREIT hasta enfoques iterativos basados en el método de Newton-Raphson [12].

Más allá del monitoreo pulmonar en UCI, que representa la realidad clínica actual del estándar de cuidado, la TIE ha demostrado un potencial disruptivo en diversas áreas de la medicina mediante investigaciones de vanguardia. Entre estas aplicaciones emergentes destacan la detección temprana de neoplasias de mama debido al alto contraste de impedancia de los tejidos tumorales [57], el monitoreo de la función cardíaca y el gasto cardíaco de forma no invasiva [12], el seguimiento de la perfusión cerebral tras eventos cerebrovasculares [58], la evaluación dinámica de la función gástrica [59] y el estado de hidratación sistémica [60].

## Monitoreo Pulmonar

La aplicación más importante de la TIE es el monitoreo de la función pulmonar en pacientes críticos. La TIE permite visualizar la distribución regional de la ventilación, detectando fenómenos invisibles a la espirometría global como el “Pendelluft”, que es el movimiento de gas entre regiones pulmonares sin intercambio exterior, el colapso alveolar llamado atelectasia y la sobredistensión regional causada por la ventilación mecánica. Estudios clínicos recientes han validado el uso de TIE para guiar la Presión Positiva al Final de la Espiración (PEEP), optimizando el reclutamiento pulmonar y minimizando el daño inducido por el ventilador, especialmente crucial en el manejo de Síndrome de Dificultad Respiratoria Aguda (SDRA) [11, 61].

Más allá de la ventilación, la TIE está emergiendo como una herramienta para evaluar la perfusión pulmonar. Mientras que métodos anteriores requerían la inyección de bolos de solución salina hipertónica (que actuaban como contraste de impedancia), nuevos algoritmos de filtrado de señal permiten separar la componente pulsátil cardíaca de la señal de impedancia torácica. Esto posibilita la generación de mapas de perfusión continuos y no invasivos, permitiendo la evaluación de la relación Ventilación/Perfusión (V/Q) a pie de cama, fundamental para diagnosticar embolias pulmonares o desajustes V/Q en tiempo real [62, 63, 12].

## Imágenes Funcionales y Análisis de Regiones de Interés (ROI)

La utilidad clínica del monitoreo pulmonar mediante TIE, descrita previamente, se materializa a través de la generación de imágenes funcionales y el análisis de Regiones de Interés (ROI), herramientas que permiten transformar las variaciones globales de impedancia en parámetros fisiológicos localizables. A diferencia de las imágenes estáticas, las imágenes funcionales en TIE se derivan de operaciones matemáticas aplicadas a secuencias temporales de imágenes reconstruidas (*raw images*) y sus respectivas formas de onda [64]. Estas representaciones permiten cuantificar y caracterizar la distribución espacial de la ventilación y la perfusión pulmonar, facilitando el análisis de fenómenos dinámicos como los cambios en la ventilación pulmonar, la distribución de la frecuencia de impedancia y los tiempos respiratorios regionales [65].

Para extraer información diagnóstica específica de estas imágenes funcionales, se recurre a la segmentación del dominio en ROI, definidas como subconjuntos de píxeles que permiten aislar comportamientos fisiológicos en áreas anatómicas precisas. Debido a la naturaleza dinámica de la TIE, la forma de onda de la impedancia a lo largo del tiempo varía significativamente entre diferentes ROIs, lo que permite, por

ejemplo, aislar el flujo respiratorio de un sector específico del pulmón.

Estas regiones se clasifican fundamentalmente en dos categorías: geométricas y pulmonares. Las ROI geométricas constituyen la forma más simplificada de segmentación y se definen mediante divisiones horizontales o verticales del dominio de la imagen. Este enfoque es común cuando existe un interés clínico en comparar el comportamiento anteroposterior (división horizontal), la simetría entre los pulmones izquierdo y derecho [66, 67], o el análisis por cuadrantes para evaluar la homogeneidad de la ventilación [68]. Por otro lado, las ROI pulmonares se enfocan exclusivamente en las partes pulmonares, requiriendo procesos de segmentación más complejos. Para su delimitación, se suelen aplicar técnicas de umbralización que permiten detectar y aislar el tejido pulmonar del resto del tórax. No obstante, la determinación del valor de umbral óptimo es un tema de debate en la comunidad científica especializada [69, 70]. En la Figura 3.2 se observan los distintos de ROIs posibles.

## DetECCIÓN ONCOLÓGICA

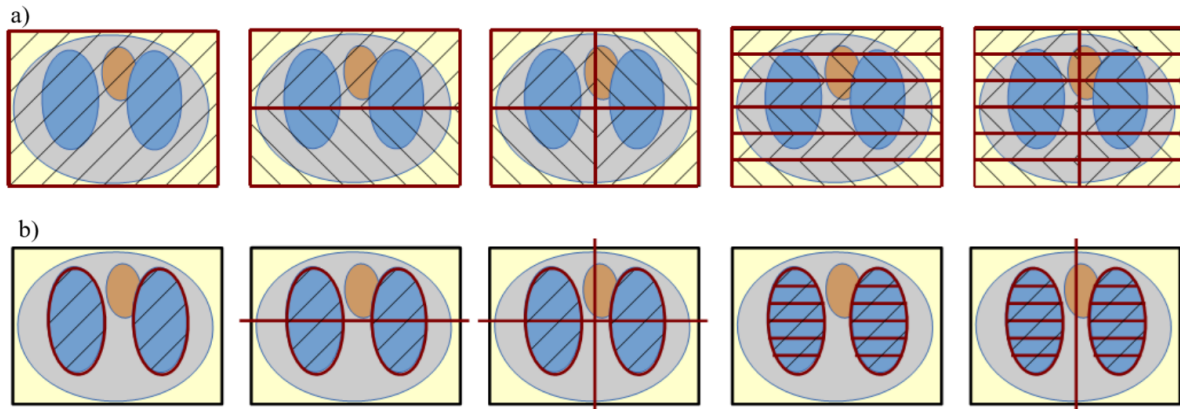
En el ámbito de la oncología, la TIE explota las diferencias en los parámetros de Cole-Cole entre tejidos sanos y malignos. Estudios *ex vivo* e *in vivo* han demostrado que la TIE puede distinguir tejido de cáncer de mama y pulmón basándose en el contraste de espectroscopia de impedancia. Específicamente, la frecuencia de relajación y la conductividad a alta frecuencia muestran correlaciones significativas con la malignidad, abriendo la puerta a sistemas de *screening* libres de radiación y bajo costo que podrían complementar a la mamografía tradicional [71, 17].

Como se nombró anteriormente, en el trabajo realizado por Hong *et al.* [57], se aborda la detección temprana de cáncer de mamas, presentando un prototipo de dispositivo wearable para la ayuda diagnóstica. En la Figura 3.3 se puede observar el dispositivo, compuesto de 90 electrodos.

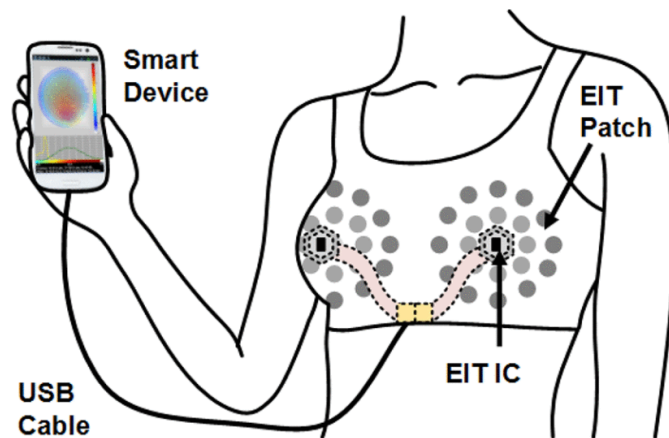
## SISTEMAS PORTÁTILES Y DE BAJO COSTO

La frontera tecnológica de la TIE se sitúa en el desarrollo de dispositivos wearables inalámbricos y de bajo consumo [72, 73, 74, 2]. Estos sistemas buscan miniaturizar la electrónica de control y emplear arquitecturas de comunicación tipo “*gateway*”, enviando los datos vía Bluetooth/BLE o WiFi a dispositivos móviles para su posterior almacenamiento en la nube y análisis en centros de servicio remotos [75].

Este enfoque portátil no solo facilita el monitoreo a pie de cama en la UCI, sino que abre la posibilidad de un seguimiento domiciliario continuo para pacientes con enfermedades crónicas como la Enfermedad



**Fig. 3.2:** Diferentes tipos de ROIs usada para caracterizar la distribución de ventilación. En la a) se encuentran las ROIs geométricas con distintos cortes de cuadrantes. En b) ROIs pulmonares y combinaciones de este tipo de ROI con geométricas [36]



**Fig. 3.3:** Sistema propuesto para la detección temprana de cáncer de mamas [57]

Pulmonar Obstruictiva Crónica (EPOC) o insuficiencia cardíaca. La capacidad de la TIE para proporcionar una ventana dinámica a la fisiología pulmonar sin radiación ionizante la posiciona como un sistema de alerta temprana indispensable en la medicina personalizada del futuro.

### 3.3 Inteligencia Artificial en TIE


La llegada de la IA, y específicamente el auge del *deep learning*, ha precipitado un cambio de paradigma radical en este campo [76]. Al tratar el problema inverso no como una optimización matemática rígida basada en un modelo físico imperfecto, sino como un problema de aprendizaje estadístico basado en datos, las redes neuronales han demostrado la capacidad de aprender la compleja relación no lineal entre los voltajes de frontera y la conductividad interna. Este enfoque permite incorporar “*priors*” o conocimientos previos complejos sobre la anatomía y la fisiología directamente en la estructura de la red, permitiendo reconstrucciones que superan las barreras de resolución espacial impuestas por los algoritmos clásicos [40].

#### Comienzos

A principios de la década de los 90s, investigadores pioneros como Guardo *et al.* [77] exploraron el uso de ADALINE para TIE. ADALINE, desarrollada en los 60s por Bernard Widrow, es una red neuronal de una sola capa que utiliza la regla de aprendizaje delta para ajustar sus pesos para minimizar el error cuadrático medio entre la salida predicha y la salida deseada. En el contexto de la TIE, se utilizaba esta red para mapear directamente las mediciones de voltajes medidos a una distribución de conductividad aproximada. Dado que esta red es esencialmente un modelo lineal, su capacidad para capturar las complejas relaciones no lineales era extremadamente limitada. Un ejemplo de estos resultados se puede ver en la Figura 3.4 Más resultados se puede observar el trabajo de Adler y Guardo [78].

Los siguientes trabajos, investigadores propusieron distintos métodos basados en el reconocimiento de patrones, redes de *back-projection*, Redes Neuronales Artificiales (ANN) (redes neuronales artificiales, sistemas computacionales que imitan el procesamiento biológico de la información), y perceptrones Bayesianos multicapa para resolver el problema inverso de la TIE. Sin embargo, estos estudios se basaban en entrenar los operadores de reconstrucción lineales y sus mediciones de voltaje, no en la no linealidad de la TIE [79, 80, 81, 82, 83].

A medida que avanzaba la tecnología, se introdujeron los Perceptrones Multicapa (MLP) (perceptrones

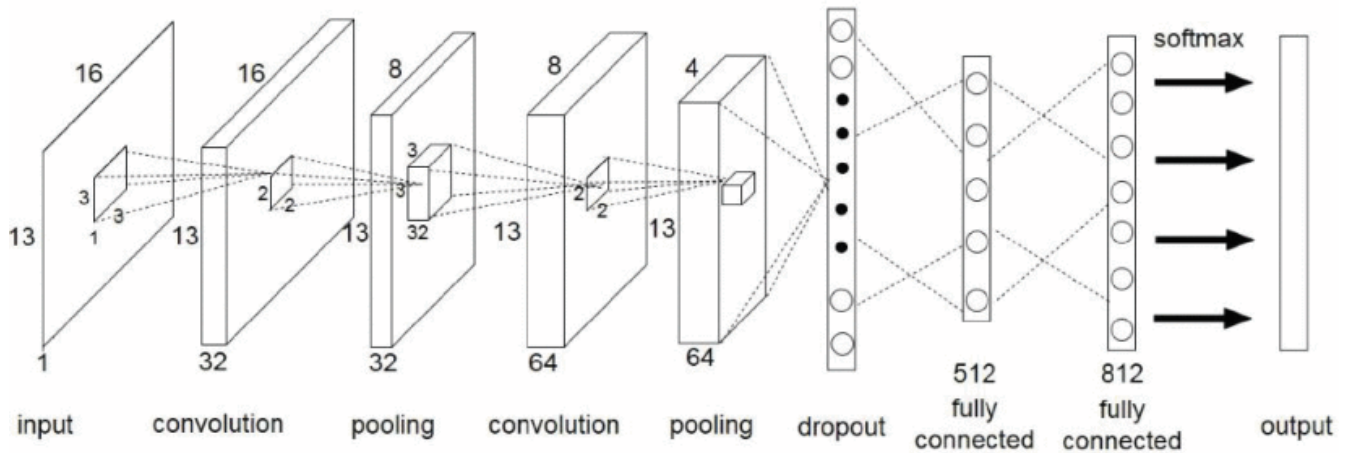


**Fig. 3.4:** En la izquierda reconstrucción realizada con red neuronal ADALINE, a la derecha realizada con *back-projection* [78].

multicapa), que son redes estructuradas en varias capas de “neuronas” que procesan la información en cascada. Para que estas redes pudieran aprender relaciones más difíciles que una simple línea recta, se incorporaron funciones de activación no lineales (como la sigmoide o la tangente hiperbólica), que actúan como filtros matemáticos que deciden qué información es relevante para pasar a la siguiente capa. También se exploraron las Redes de Funciones de Base Radial (RBF). Sin embargo, estas redes eran del tipo totalmente conectadas (*fully connected*), lo que significa que cada neurona de una capa está unida a todas las neuronas de la capa siguiente, creando una red de conexiones masiva. Esto generaba graves problemas de dimensionalidad: una imagen estándar en TIE de  $64 \times 64$  píxeles requiere 4096 salidas independientes (una por cada píxel). Al intentar conectar esto a 208 mediciones de entrada mediante capas densas, el sistema debía calcular millones de parámetros internos. Con los limitados conjuntos de datos de la época, las redes caían en el *overfitting* (o sobreajuste), un fenómeno donde el modelo simplemente “memoriza” los datos de ejemplo con su ruido incluido, en lugar de aprender las reglas generales. Como consecuencia, las redes no eran capaces de generalizar (aplicar lo aprendido a nuevos pacientes) y las imágenes resultantes eran ruidosas y carecían de coherencia espacial [84, 85, 86, 87, 88].

La verdadera transformación para la TIE en cuanto a reconstrucción de imágenes comenzó en la década de 2010. El redescubrimiento de las Redes Neuronales Convolucionales (CNN), impulsado con AlexNet [89] en visión de computadora, proporcionó la herramienta perfecta para TIE: una arquitectura diseñada específicamente para encontrar correlaciones espaciales, es decir, para entender cómo los datos vecinos se agrupan para formar estructuras coherentes.

Las CNNs permitieron tratar la reconstrucción de imágenes de TIE como un problema de traducción de señal a imagen (o imagen a imagen), aprendiendo filtros espaciales que detectan bordes, formas y texturas. Estas redes toman un vector de 1D (una dimensión), lo proyectan a un espacio 2D mediante una capa densa inicial, y luego aplica una serie de capas convolucionales y de *pooling* (submuestreo)

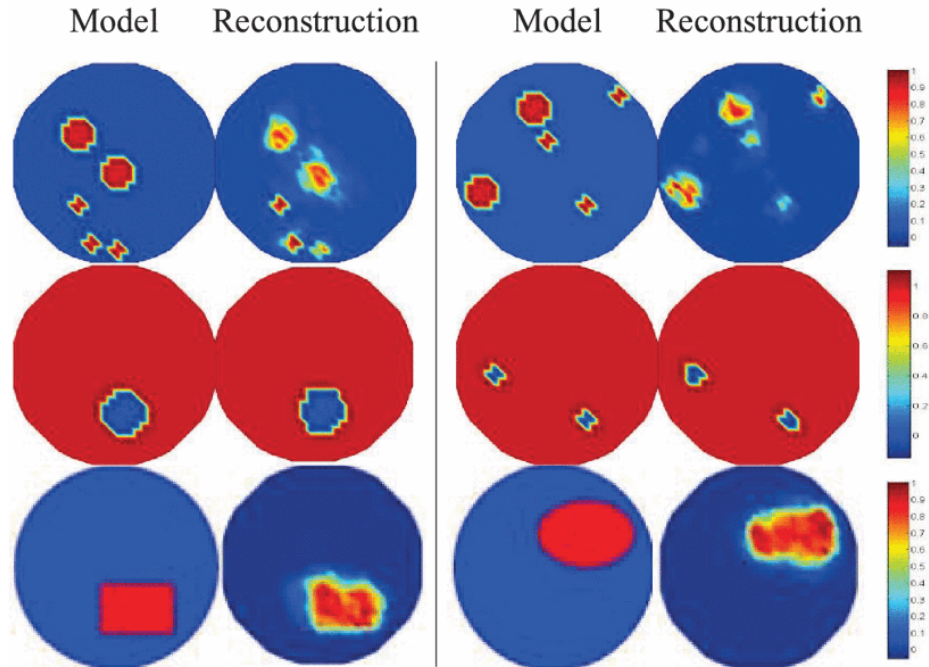


**Fig. 3.5:** Estructura CNN utilizada en [93].

para refinar la solución. El pooling es una técnica que simplifica la información quedándose solo con los rasgos más importantes para reducir el ruido y la carga computacional. Una vez entrenada una CNN es puramente “*feed-forward*”. Esto significa que la información viaja en un solo sentido, desde la entrada hasta el resultado final, sin necesidad de realizar los ciclos iterativos ni los costosos cálculos matemáticos de los métodos clásicos. Gracias a esto, el tiempo de inferencia es de milisegundos, permitiendo un monitoreo en tiempo real [90, 88, 91, 92]. Un ejemplo de arquitectura diseñada para la reconstrucción de imágenes a partir de señales TIE con CNN, fue el realizado por Tan et al. en [93]. El diseño se puede ver en la Figura 3.5, y los resultados de este método pueden verse en Figura 3.6.

Otra estrategia utilizada de manera exitosa, fue a combinación entre los algoritmos de reconstrucción tradicionales y las redes neuronales, para obtener una mejor resolución. De forma resumida, en lugar de pedirle a la red neuronal que resuelva el problema desde cero, se utiliza un algoritmo clásico rápido y robusto como Gauss-Newton o Back-projection para obtener una imagen inicial de baja resolución para utilizar de referencia. Luego, como método para eliminar el ruido, una CNN toma esta imagen preliminar como entrada y le “quita” el ruido, corrigiendo artefactos y mejorando la definición de bordes.

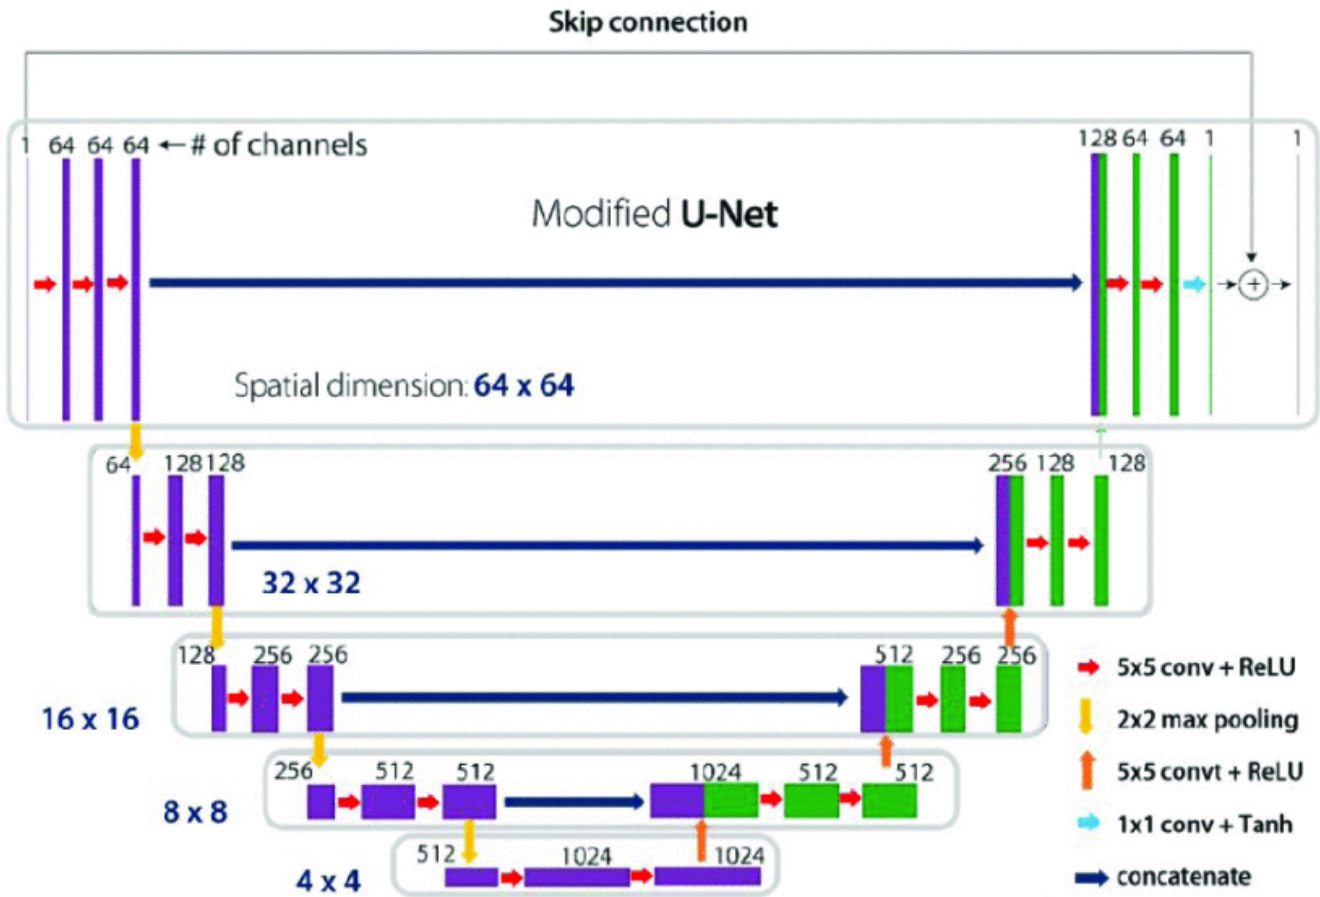
Algunos de los estudios que utilizan esta técnica pueden ser por ejemplo el realizado por Martin y Choi [94], quienes proponen una estrategia donde utilizan el método Gauss-Newton para generar una solución inicial, para luego procesar esta imagen por una red neuronal para corregir la distribución de conductividad. Esta metodología demostró una precisión y robustez superior al compararse con reconstrucciones directas mediante redes neuronales puras o algoritmos iterativos convencionales. También destaca el trabajo realizado por Dumdum *et al.* [95], quienes basándose en el trabajo anterior, utilizaron una D-Bar para la reconstrucción inicial y una U-Net como etapa de post-procesamiento. La U-Net es




**Fig. 3.6:** Resultados de reconstrucción de imágenes con CNN. Utilizando figuras con distintas conductividades [93].

una arquitectura de red convolucional cuya estructura es simétrica y en forma de ‘U’, compuesta por dos fases principales: una ruta de contracción (codificador) que condensa la información esencial de la imagen, y una ruta de expansión (decodificador) que reconstruye la imagen a su resolución original. El rasgo distintivo de esta red son las “conexiones de salto” (*skip connections*), las cuales funcionan como puentes de información que permiten transferir detalles anatómicos finos directamente desde la entrada hacia la salida, evitando que se pierdan durante el procesamiento y garantizando una imagen final más nítida y fiel a la realidad. En la Figura 3.7 se puede ver la U-net implementada en el trabajo de Dum Dum *et al.* junto a sus resultados obtenidos en 3.8. Por su parte, Wang *et al.* [96], por su parte utilizó NOSER para la fase de reconstrucción preliminar, refinando los resultados con redes basadas en MobileNet [97] y PSPNet [98].

Otro de los avances notables en este ámbito es el desarrollo del Deep D-bar. Hamilton *et al.* [99] propusieron este método para superar las limitaciones de resolución espacial y los artefactos de submuestreo inherentes al filtrado de bajas frecuencias del algoritmo D-bar tradicional. En esta configuración, el algoritmo D-bar proporciona una imagen de conductividad de baja calidad que sirve como base para que una U-Net elimine artefactos, obteniendo imágenes estáticas de alta fidelidad con un retardo temporal mínimo.



**Fig. 3.7:** Estructura U-Net utilizada para postprocesamiento en [95].



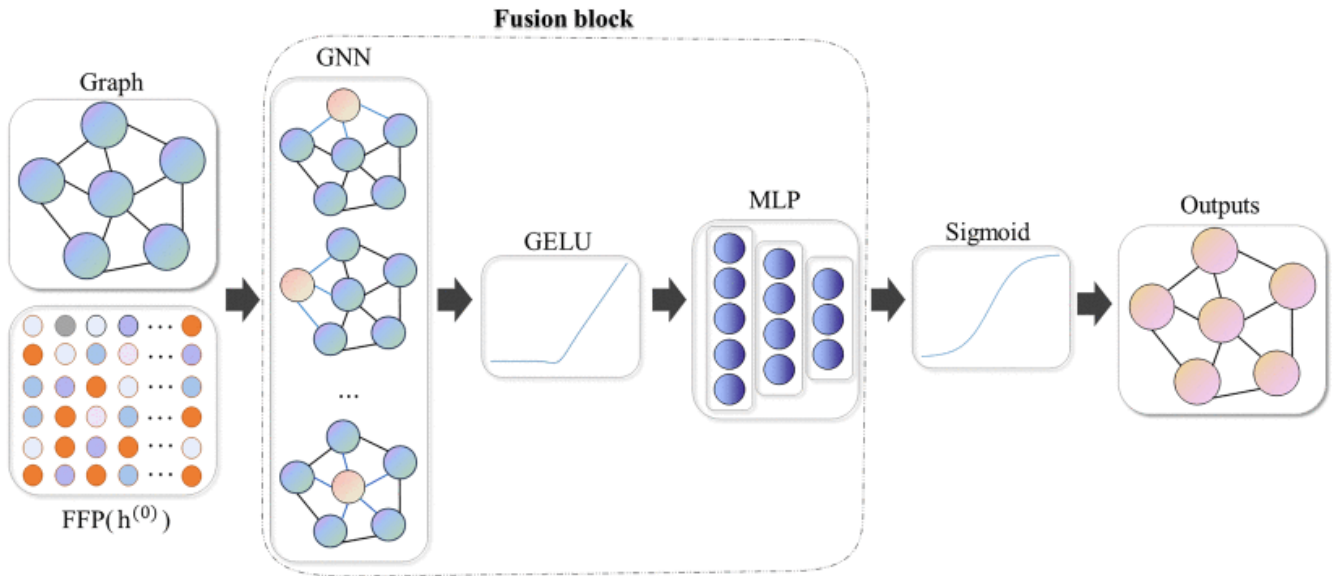
**Fig. 3.8:** Resultados de reconstrucción de imágenes utilizando D-Bar más U-Net. En la primera fila están las imágenes de referencia, en la segunda un método convencional (Gauss-Newton) y en la tercera el método combinando un método clásico con una red convolucional [95].

## Actualidad

A partir del 2022, la complejidad y capacidad de los modelos alcanzan niveles sin precedentes. La investigación se ha centrado en superar las limitaciones de métodos anteriores, como la dificultad de manejar dependencias globales y mallas irregulares, mediante tres pilares tecnológicos: grafos, modelos de difusión y transformers.

Un avance significativo en el manejo de geometrías complejas es GraphEIT, propuesto por Liu *et al.* [100]. Esta arquitectura introduce una metodología de aprendizaje no supervisado, un enfoque que permite al modelo aprender directamente de las leyes físicas y las mediciones sin necesidad de imágenes previas de referencia, fusionando capas de Redes Neuronales de Grafos (GNN) (Redes Neuronales de Grafos) con MLPs. La estructura de este trabajo se puede observar en la Figura 3.9.

A diferencia de las redes convencionales que procesan píxeles cuadrados, las GNN operan directamente sobre los nodos y conexiones de la malla de elementos finitos, respetando la geometría irregular del cuerpo humano. Su núcleo técnico incorpora una proyección de características de Fourier, una técnica diseñada para mitigar el sesgo espectral. Este fenómeno es la tendencia natural de las redes neuronales a



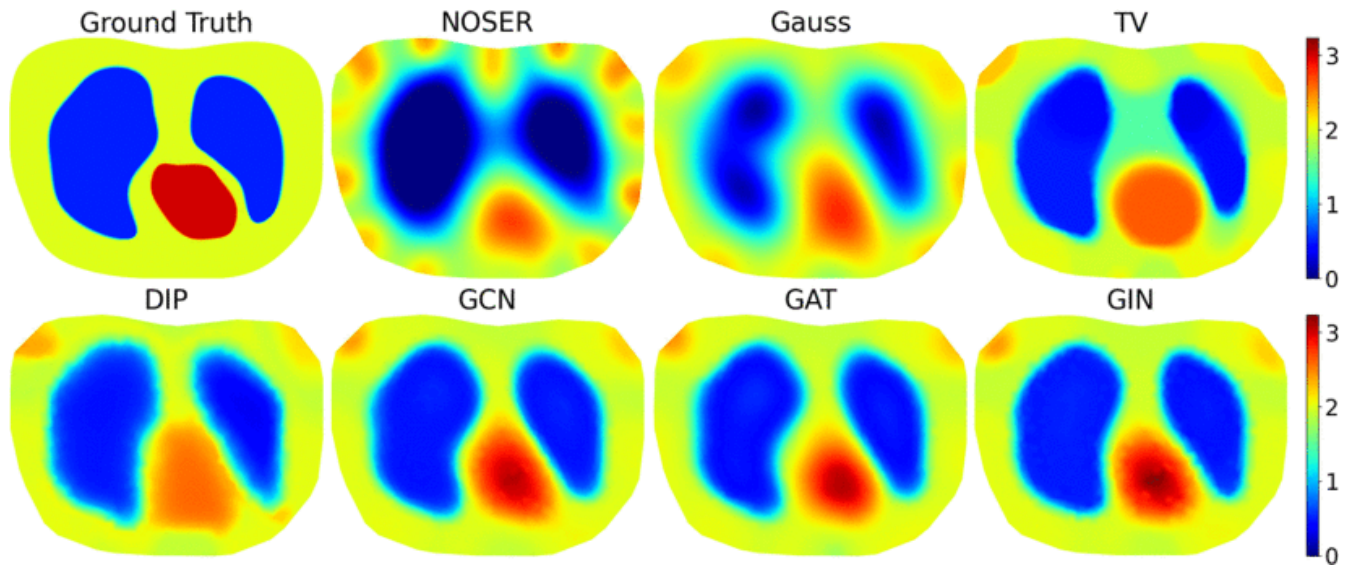
**Fig. 3.9:** Estructura de GraphEIT.  $h^{(0)}$  corresponde a las coordenadas de los elemento finitos, mientras que FFP es *Fourier feature projection* [100].

aprender primero las formas globales y borrosas (baja frecuencia); la proyección de Fourier actúa como un mecanismo que obliga al modelo a capturar los detalles finos, bordes y texturas de alta frecuencia que de otro modo se perderían.

Gracias a esto, GraphEIT ha demostrado una capacidad superior de preservación de forma en mallas no uniformes, alcanzando un SSIM de 0.91 y un PSNR de 30.34 en simulaciones de tórax. Al ser validado experimentalmente con el dataset KIT-4 (tanque cilíndrico) [101] y el fantoma ACT-3 (geometría de corazón y pulmones) [49], el modelo logró recuperar el perfil de conductividad real con una precisión de 7.5 mS/cm, donde los métodos tradicionales fallaron sistemáticamente al subestimar los valores. Algunos resultados de reconstrucción utilizando esta arquitectura se puede analizar en la Figura 3.10.

Para abordar la borrosidad característica de los métodos regresivos convencionales, Shi *et al.* introdujeron el modelo *Conditional Diffusion Model for EIT* (CDEIT) [55]. Esta arquitectura representa un cambio de paradigma al emplear Modelos de Difusión Probabilística de Eliminación de Ruido (DDPM), una técnica generativa de vanguardia que, en lugar de realizar una estimación directa, aprende a modelar la distribución de probabilidad de las imágenes de conductividad condicionándolas a los voltajes medidos en la frontera.

Técnicamente, el funcionamiento de CDEIT se basa en un proceso de difusión inversa compuesto por múltiples pasos de refinamiento iterativo. El modelo comienza a partir de una distribución de ruido gaussiano y, mediante una secuencia de etapas de “*denoising*” o eliminación de ruido, restaura progresi-

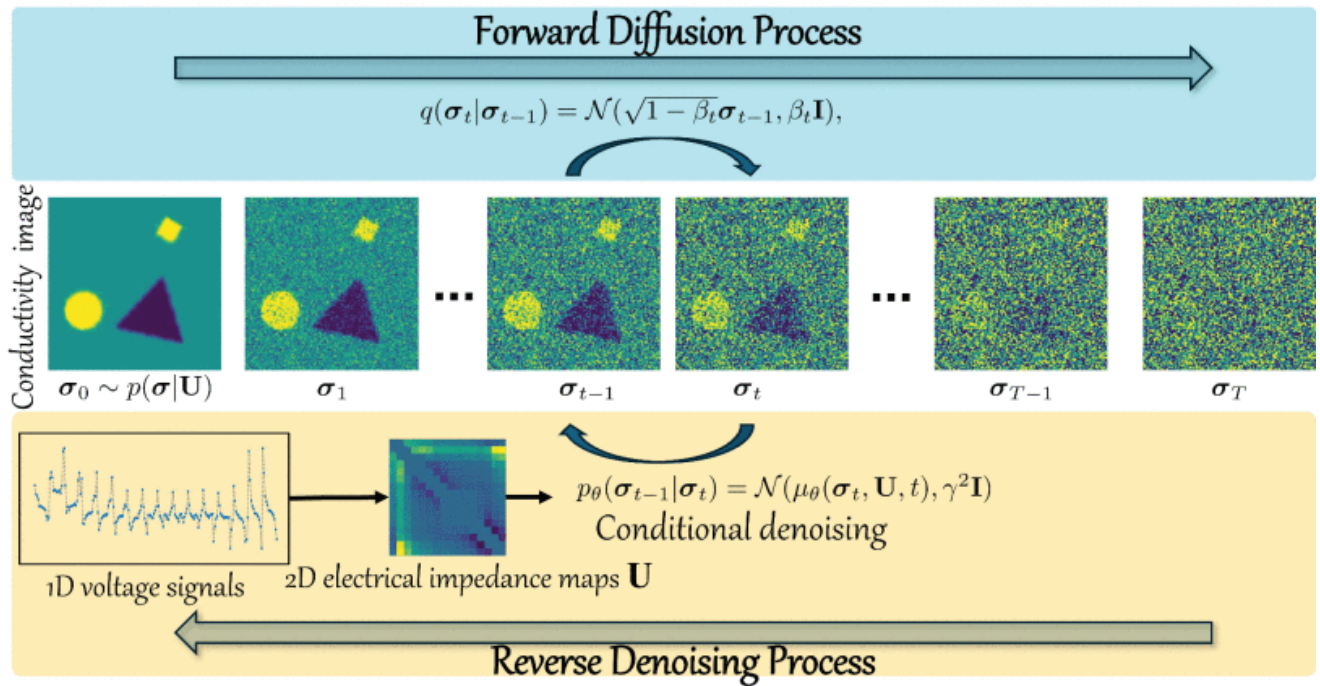


**Fig. 3.10:** Reconstrucción de tórax simulado utilizando distintos métodos utilizando el *framework* de GraphEIT. En la fila superior, de izquierda a derecha: *Ground Truth*, NOSER, Gauss-Newton, Variación total. En la fila inferior de izquierda a derecha: DIP [102], GCN [103], GAN [104], GNN[105]. Imagen de [100].

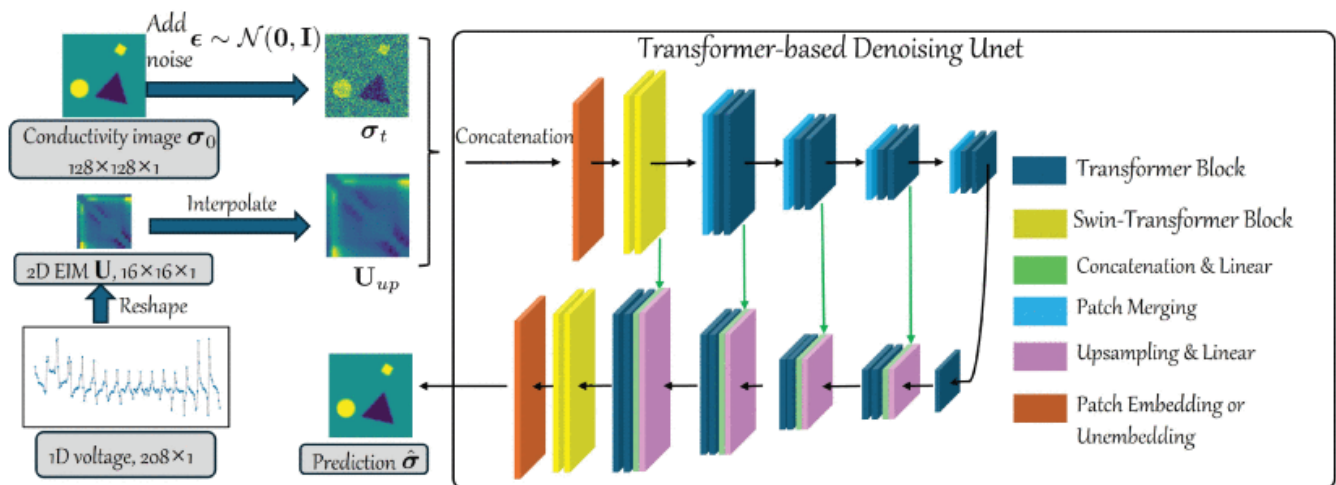
vamente los detalles espaciales hasta reconstruir la imagen de conductividad final. En cada uno de estos pasos, la red utiliza los voltajes de frontera como una “guía condicional” para asegurar que la imagen generada no solo sea visualmente nítida, sino físicamente coherente con las señales eléctricas capturadas. Se puede ver gráficamente como se agrega y elimina ruido en la Figura 3.11.

La estructura interna del modelo emplea un “*backbone*” de U-Net basado en *transformers*. A diferencia de las arquitecturas tradicionales que analizan la imagen de forma local, el uso de transformadores permite implementar mecanismos de atención global. Esto significa que la red tiene la capacidad de capturar relaciones y dependencias de largo alcance entre regiones distantes del dominio, lo cual es fundamental para resolver la naturaleza difusiva de la corriente en la TIE. Asimismo, incorpora bloques de tipo *swin-transformer* para optimizar el consumo de memoria computacional mediante el procesamiento por ventanas de atención. La arquitectura generada de U-Net con sus correspondientes bloques *transformer* se puede apreciar en la Figura 3.12.

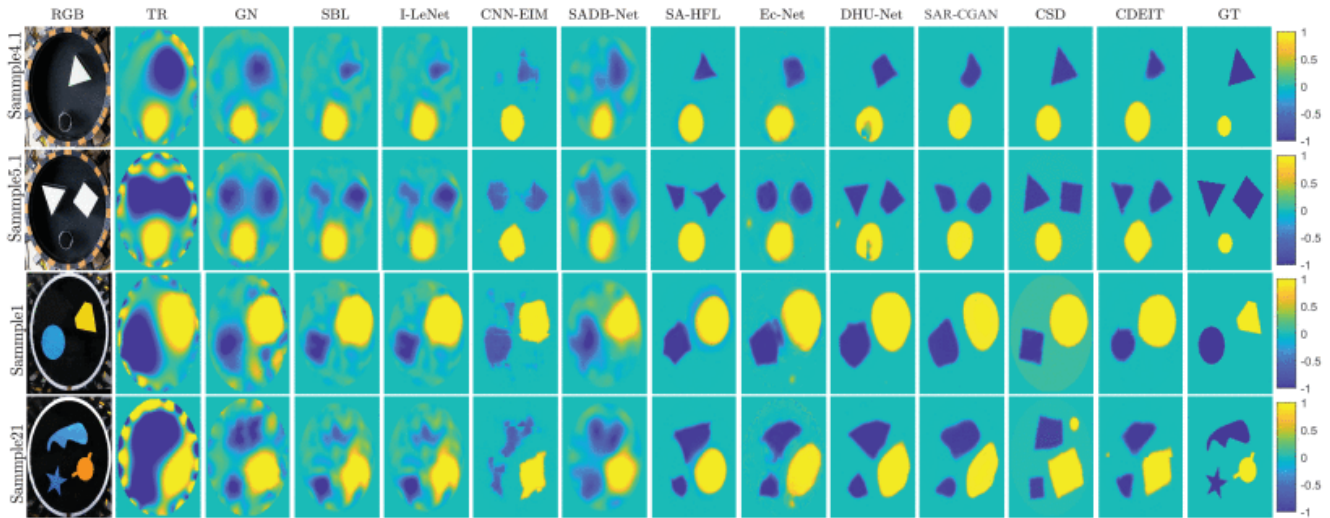
Una *transformer* es arquitectura de aprendizaje profundo basada fundamentalmente en mecanismos de auto-atención (*self-attention*), la cual permite al modelo evaluar la relevancia de cada elemento de la entrada en relación con todos los demás de forma simultánea. A diferencia de las redes convolucionales, que poseen un campo receptivo limitado por el tamaño del filtro, los *transformers* calculan la atención de manera global sobre el mapa de características. Esta capacidad es crítica en la TIE para capturar dependencias de largo alcance y resolver la naturaleza difusiva de la corriente eléctrica, donde la información



**Fig. 3.11:** Descripción general de CDEIT. Abarca el proceso de difusión directa, donde se agrega ruido gaussiano y como se elimina y restauran progresivamente los detalles espaciales de conductividad original condicionadas por  $U$  [55].



**Fig. 3.12:** Framework de CDEIT [55].

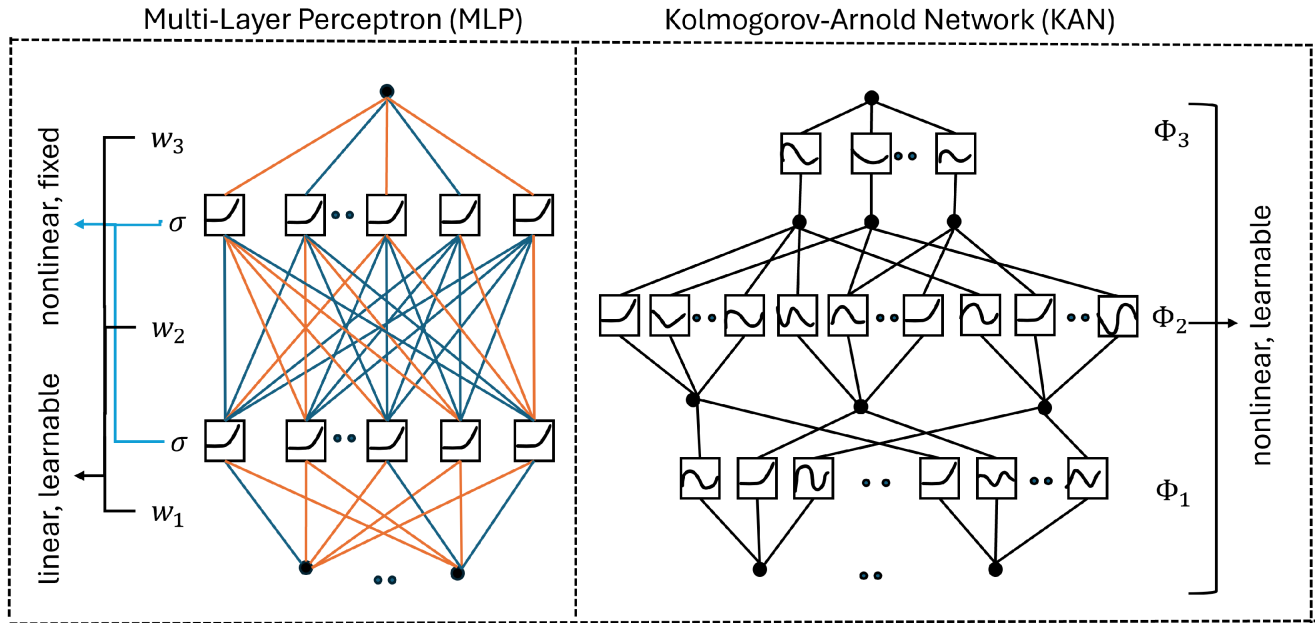


**Fig. 3.13:** Reconstrucción de imágenes a partir de base de datos KIT-4 con múltiples arquitecturas y con distintas condiciones. En la columna última derecha, se pueden ver los resultados con CDEIT [55].

de un electrodo puede estar vinculada a variaciones en regiones distantes del dominio [106]. Por otra parte una *swin-transformer* [107] es una evolución jerárquica para tareas de visión. Este introduce el concepto de ventanas de atención desplazadas (*shifted windows*). En lugar de computar la atención sobre todos los píxeles de la imagen, lo cual resultaría computacionalmente inviable en altas resoluciones, esta arquitectura divide el mapa en parches o ventanas pequeñas para realizar el cálculo de forma local y eficiente. Mediante el desplazamiento de estas ventanas entre capas, la red logra integrar la información local en una representación global, optimizando drásticamente el uso de memoria y la capacidad de extracción de características multiescala.

Los resultados de esta aproximación estocástica realizados en este trabajo son notables, reportando un PSNR de 39.57 y un SSIM de 0.998. La principal fortaleza metodológica de CDEIT se refleja en su validación con los datasets reales KIT-4 [101] y KTC2023 [108], donde demostró una robustez excepcional ante el desplazamiento de electrodos y el ruido de medición. A pesar de su naturaleza iterativa, el modelo alcanza una velocidad de 29.25 frames por segundo (fps), lo que valida su viabilidad para el monitoreo clínico de alta fidelidad en tiempo real. Algunas reconstrucciones realizadas con CDEIT pueden verse en la Figura 3.13.

Finalmente, la integración de las Redes de Kolmogorov-Arnold (KAN) [109] y las *Vision Transformer* (ViT) [110] han marcado una diferencia, dando lugar a una nueva arquitectura híbrida denominada KAN-ViT [111]. Este modelo propone un cambio fundamental en la forma en que las redes neuronales procesan la información, optimizando la capacidad de respuesta ante la extrema no linealidad de los



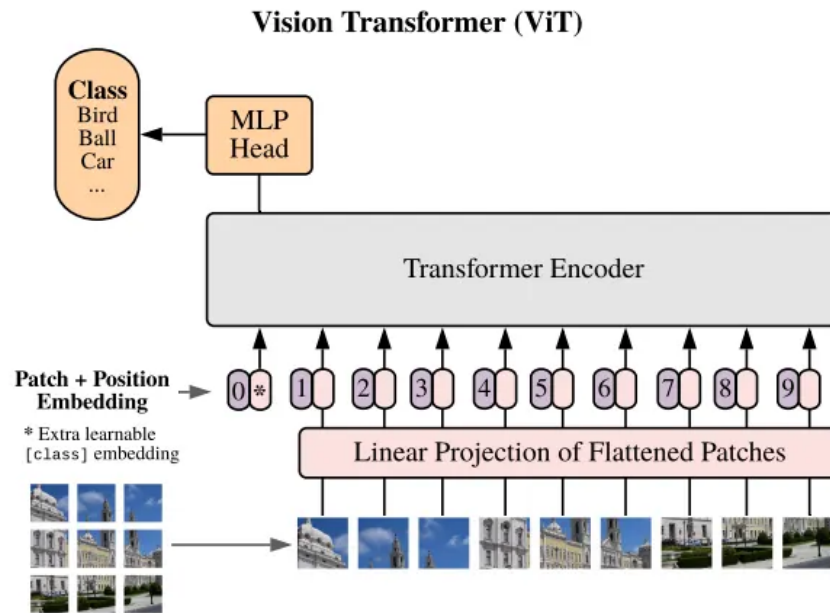
**Fig. 3.14:** Este diagrama resalta la diferencia entre la capa de composición y de función de activación de modelos MLP y KAN. Imagen de [112].

tejidos biológicos.

La propuesta de KAN realizada recientemente por Liu *et al.* [109] presenta una alternativa prometedora a los (MLP) tradicionales. Su fundamento matemático reside en el teorema de representación de Kolmogorov-Arnold, el cual postula que cualquier función continua multivariable puede descomponerse en una suma finita de funciones continuas de una sola variable.

A diferencia de las MLPs, donde las funciones de activación son fijas en los nodos y los pesos en las aristas son los que se aprenden, las KAN eliminan los pesos lineales de las conexiones y colocan funciones de activación aprendibles directamente en las aristas. Estas funciones se modelan comúnmente mediante B-splines (funciones definidas por trozos mediante polinomios), lo que permite que la red adapte de forma flexible y precisa su respuesta local ante los datos de entrada. Esta característica otorga a las KAN una precisión superior y una mayor eficiencia en el uso de parámetros frente a los modelos densos clásicos. Un ejemplo visual de una comparativa entre las redes KAN y las MLP se puede observar en la Figura 3.14.

Por otra parte, las ViT, son una arquitectura que revolucionó el campo al adaptar el mecanismo de atención, que originalmente estaba diseñado para el lenguaje, al procesamiento de imágenes. Las ViT descomponen una imagen en una secuencia de parches (*patches*) o pequeñas regiones cuadradas de ta-

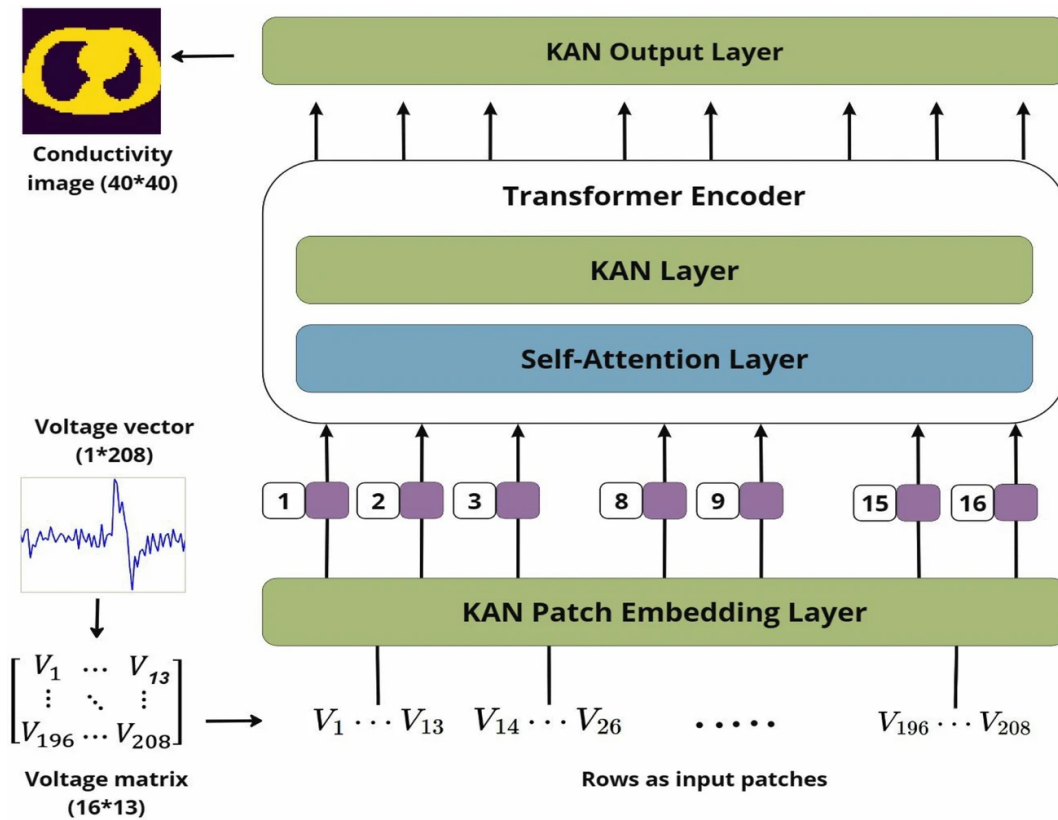


**Fig. 3.15:** Descripción general de modelo ViT. Se divide una imagen en fragmentos de tamaño fijo, se ubican de forma lineal, se añade su posición y con esos datos se entrena una red *transformer* estándar [110].

maño fijo, por ejemplo  $16 \times 16$  píxeles, tratándolos de manera análoga a las palabras en una oración. Mediante el uso de atención global, la red evalúa la relación de cada parche con todos los demás simultáneamente, permitiendo una comprensión integral de la estructura anatómica que supera las limitaciones de campo receptivo de las CNN. Esta arquitectura fue introducida formalmente por Dosovitskiy *et al.* en 2020 [110] para superar los paradigmas convolucionales vigentes.

El modelo KAN-ViT, detallado por Amin *et al.* [111], sustituye las capas de MLP que se encuentran tras el codificador del *transformer* por capas KAN. En esta arquitectura, las señales de voltaje de la TIE se transforman inicialmente en *embeddings* o incrustaciones vectoriales, que proyectan los datos crudos a un espacio de mayor dimensión donde la red puede extraer características latentes de forma eficiente.

Para complementar esta estructura, el modelo incorpora un mecanismo de codificación de posición (*positional encoding*), el cual es esencial para que el *transformer* reconozca la ubicación espacial relativa de los electrodos en la faja de medición. Una vez que los voltajes han sido transformados en estos vectores de información, pasan a través de un bloque de auto-atención múltiple (*Multi-head Self-Attention*). Este componente es el núcleo del procesamiento global: permite que cada medición de voltaje “preste atención” y se relacione con todas las demás simultáneamente. Esta capacidad de visión integral es fundamental para modelar la física de la TIE, donde la corriente se difunde por todo el volumen y una



















**Fig. 3.16:** Modelo de trabajo utilizado en KAN-ViT [111].

perturbación en una zona profunda del pulmón afecta de manera única a la distribución de potencial capturada por cada electrodo en el contorno.

La innovación de Amin *et al.* [111] ocurre en el bloque de salida del codificador. En un *Vision Transformer* convencional, la información refinada por la atención pasaría a través de capas densas de MLP. Sin embargo, el modelo KAN-ViT sustituye estas capas por bloques KAN, donde la relación entre los datos no se rige por pesos lineales fijos, sino por funciones de activación basadas en B-splines. Estas splines son curvas matemáticas suaves que la red “moldea” durante su entrenamiento para ajustarse con precisión a la respuesta no lineal de los tejidos. Al situar estas funciones aprendibles directamente en las conexiones de la red, el modelo logra una capacidad de aproximación superior, permitiendo que la reconstrucción final capture interfaces anatómicas nítidas que los modelos lineales tradicionales tienden a difuminar.

En la siguiente Figura 3.16, se puede ver el diagrama de flujo utilizado en el trabajo anterior. Desde la señal TIE de entrada hasta la reconstrucción.

Desde el punto de vista metodológico, la robustez de KAN-ViT se fundamenta en un proceso de

Patient	113				114			
Phase	P2	P4	P6	P8	P2	P4	P6	P8
Actual								
Proposed								

**Fig. 3.17:** Ejemplos de reconstrucción pulmonar basada en TIE utilizando KAN-ViT. Las variaciones de color en los pulmones corresponden a diferentes niveles de conductividad en diversas fases respiratorias [111].

entrenamiento y validación masivo. Los autores emplearon un conjunto de datos compuesto por más de 3,000 escaneos de (TC) reales de tórax humano, los cuales actuaron como *ground truth* [113]. Estas imágenes médicas fueron procesadas mediante el software EIDORS para simular la inyección de corriente y obtener los voltajes correspondientes a través de mallas de elementos finitos de alta densidad. Este enfoque de aprendizaje supervisado permitió que la red aprendiera a reconstruir la conductividad interna basándose en morfologías pulmonares y cardíacas verídicas, en lugar de depender únicamente de simulaciones geométricas simplificadas.

Los resultados reportados confirman que esta hibridación entre la atención global y la flexibilidad de los splines representa el estado del arte en la disciplina. KAN-ViT alcanzó un SSIM de 0.9676 y un RIE de apenas 0.11, superando ampliamente a los algoritmos clásicos y a las redes convolucionales previas. Además, el modelo demostró una alta resiliencia frente al ruido de medición, manteniendo una coincidencia anatómica casi perfecta en todas las fases del ciclo respiratorio. Esta precisión permite no solo visualizar la ventilación pulmonar, sino también preservar la morfología exacta de los órganos, proporcionando una herramienta de monitoreo clínico con una fidelidad espacial sin precedentes en la TIE. Resultados de imágenes reconstruidas con KAN-ViT se observan en la Figura 3.17.

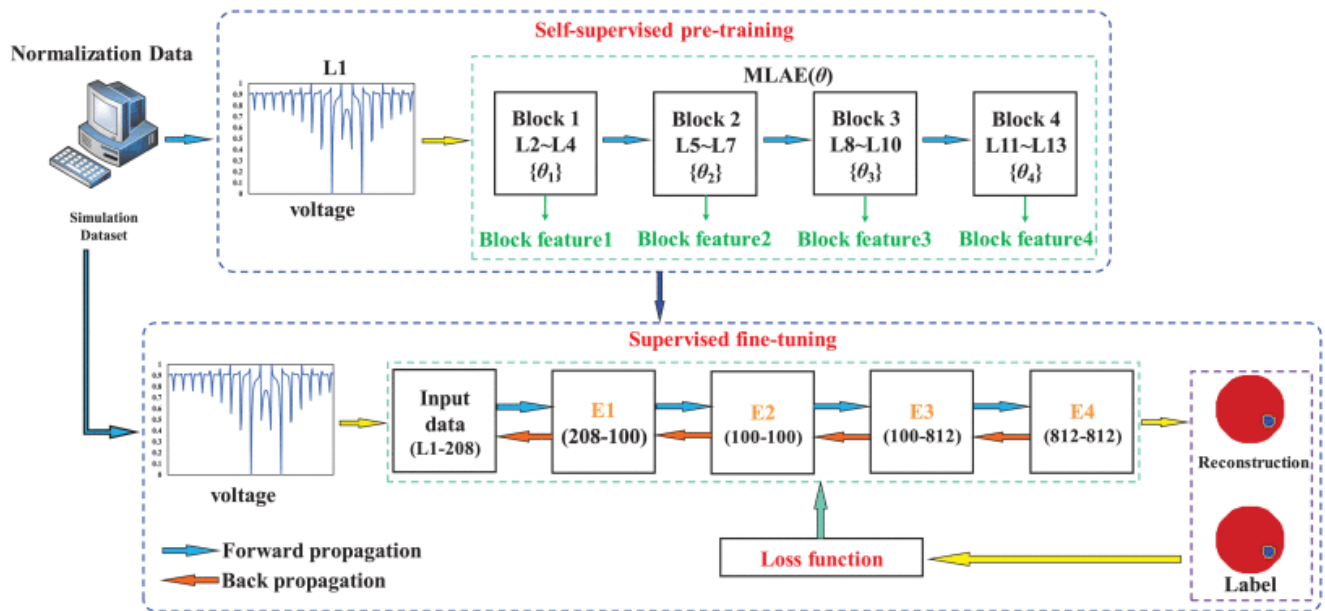
### 3.4 Transfer learning y adaptación de dominio

Uno de los obstáculos más persistentes en la reconstrucción de imágenes TIE mediante *deep learning* es la denominada brecha entre simulación y realidad (*Sim-to-Real gap*). Dado que es físicamente inviable obtener bases de datos reales masivas y etiquetadas, la mayoría de los investigadores optan por generar


datos sintéticos mediante el FEM en entornos como COMSOL o EIDORS. En este contexto, COMSOL Multiphysics [114] se presenta como una herramienta de simulación basada en el FEM, que permite resolver las ecuaciones diferenciales parciales que gobiernan el problema directo de la tomografía, como la ecuación de Laplace para la distribución de potencial. Al utilizar COMSOL para crear un “gemelo digital”, es posible simular miles de escenarios de conductividad y obtener sus correspondientes mediciones de voltaje en los electrodos, generando así los pares de datos necesarios para el aprendizaje supervisado. Sin embargo, a pesar de la precisión física del software, existe una discrepancia inherente entre estas simulaciones deterministas y el comportamiento de un sistema físico real, lo que da lugar al denominado *Sim-to-Real gap* [115]. Este fenómeno se manifiesta cuando un modelo alcanza una alta precisión en datos sintéticos pero falla al aplicarse en fantasmas reales debido al ruido electrónico, las capacitancias parásitas y las imperfecciones geométricas no modeladas. Para mitigar este fenómeno, se recurre a la adaptación de dominio, un conjunto de técnicas diseñadas para reducir la discrepancia estadística entre un “dominio fuente” idealizado y un “dominio destino” real y complejo [116].

Dentro de este marco, el aprendizaje por transferencia (*transfer learning*) se ha consolidado como una estrategia fundamental. Esta técnica consiste en utilizar un modelo pre-entrenado en una tarea masiva (por ejemplo, miles de simulaciones sintéticas) como punto de partida para el aprendizaje de una segunda tarea relacionada. El objetivo es que la red neuronal retenga la comprensión física del problema inverso aprendida en la simulación y solo necesite ajustar sus parámetros para reconocer las firmas de ruido del *hardware* físico [117]. Un ejemplo destacado de esta implementación se encuentra en el trabajo de Chen *et al.* [118], quienes propusieron una red de autoencoder multicapa (MLAE). Su metodología integra una fase de pre-entrenamiento auto-supervisado con un posterior ajuste fino (*fine-tuning*) supervisado, en el cual la red se entrena con un conjunto reducido de datos específicos para capturar relaciones no lineales que el modelo base no lograba resolver inicialmente. Como se observa en la Figura 3.18, este enfoque permitió superar en precisión a los algoritmos tradicionales de regularización al identificar mejor los bordes y contornos en condiciones de “campo suave”. Además, en Figura 3.19, se puede ver una reconstrucción con el sistema completo implementado en un fantoma circular junto a elementos dentro del tranque.

La necesidad de integrar el conocimiento físico en el proceso de aprendizaje ha llevado al desarrollo de modelos híbridos dirigidos por imágenes (*image-driven*). Ren *et al.* [119] introdujeron un método de dos etapas (TSDL: *two-stage deep learning*) que combina un módulo de pre-reconstrucción para generar una imagen inicial gruesa y una CNN para el refinamiento final. Esta estrategia de aprendizaje en dos fases, ilustrada en la Figura 3.20, ha demostrado ser más eficaz que los métodos NOSER o de Variación Total (TV) para manejar errores de modelado y ruido de medición. Los resultados obtenidos



**Fig. 3.18:** Proceso de entrenamiento de *autoencoder*. Con pre-entrenamiento auto-supervisado y *fine-tuning* supervisado [118].



**Fig. 3.19:** Sistema completo de adquisición y reconstrucción con fantoma circular [118].




**Fig. 3.20:** Arquitectura propuesta con métodos de dos etapas. A partir de una imagen inicial, se refina esta con una CNN para llegar al resultado final [119].

con la arquitectura propuesta son un SSIM de 0.84 y un RMSE de 9.2 para su estudio con fantasmas pulmonares. No obstante, una debilidad identificada en este tipo de redes es que su alta dependencia de recursos de GPU las hace poco viables para sistemas embebidos o portátiles en tiempo real, donde el consumo de potencia y la memoria son limitados.

Para cerrar la brecha entre la teoría computacional y la aplicación clínica, ha surgido el concepto de gemelo digital (*digital twin*). Wang *et al.* [120] propusieron un marco que utiliza modelos de acoplamiento fluido-electrostático 3D para generar datos virtuales que replican con mayor fidelidad los escenarios reales. Al combinar estos gemelos digitales con redes neuronales profundas (DNNs), es posible realizar una adaptación de dominio más suave, reduciendo la necesidad de grandes cantidades de datos reales para el *fine-tuning*. Esta evolución desde arquitecturas simples como la 1D-CNN, que procesa voltajes directamente para preservar la estructura de la señal, hacia marcos de gemelos digitales, representa el estado del arte actual. Aun así, la literatura todavía carece de soluciones integrales que demuestren un *pipeline* funcional de extremo a extremo: desde un fantoma físico 3D capturado por *hardware* portátil ad-hoc hasta una inferencia en tiempo real en Python, lo cual sigue siendo un desafío tecnológico abierto debido a la complejidad de calibrar modelos sintéticos con señales de baja relación señal-ruido generadas fuera de entornos de laboratorio controlados.

Una alternativa emergente para mitigar la brecha entre simulación y realidad es el uso de algoritmos no supervisados que no dependen de un conjunto masivo de datos reales etiquetados para la adaptación. En este ámbito, Zhang *et al.* [121] propusieron el algoritmo *Deep-Learning-Based Error Image Prior (DLEIP)*, diseñado específicamente para la TIE pulmonar. A diferencia de los métodos de *fine-tuning* tradicionales, su red AD-Net utiliza la retropropagación integrada para optimizar la distribución de conductividad de forma iterativa, utilizando la arquitectura de la red como un regularizador estructural.



**Fig. 3.21:** a) Setup experimental de DLEIP. b) Esquema del sistema de adquisición con reconstrucción de imágenes de fantoma circular [121].

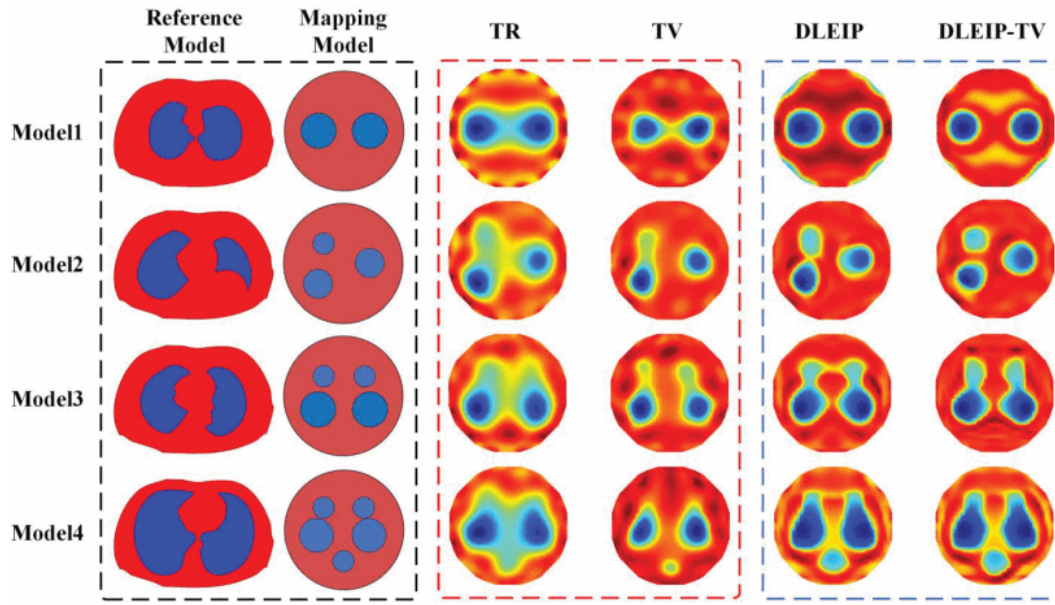
Este trabajo es particularmente relevante para la validación experimental, ya que los autores construyeron un modelo de mapeo en un dominio circular para verificar la practicidad del algoritmo con fantasmas reales, como se puede ver en Figura 3.21. Los resultados reportados muestran una alta fidelidad en la reconstrucción de áreas de ventilación y lesiones, alcanzando CC superiores a 0.82 y RIE inferiores a 0.40. Alguno de los resultados pueden verse en Figura 3.22.

Sin embargo, a pesar de su precisión y de no requerir una base de datos real para el entrenamiento, este tipo de enfoques no supervisados suele presentar una limitación en aplicaciones de monitoreo dinámico: la carga computacional del proceso de optimización in-situ. Esto refuerza la necesidad de investigar métodos basados en Transfer Learning supervisado, que permitan realizar una adaptación de dominio previa para garantizar una inferencia instantánea y en tiempo real, manteniendo métricas de error competitivas con las obtenidas por métodos iterativos de vanguardia.

### 3.5 Discusión

La revisión de la literatura muestra que la TIE ha experimentado una transición significativa desde los métodos clásicos, como Gauss-Newton o la regularización de Tikhonov, hacia modelos avanzados basados en *deep learning*. Si bien existen diversos trabajos que han demostrado la superioridad de las redes neuronales en términos de velocidad y calidad de reconstrucción, la mayoría de estas investigaciones se limitan a entornos puramente simulados, o a implementaciones de *hardware* de alta gama y costo elevado.

En primer lugar, se observa que las arquitecturas más vanguardistas, como el modelo híbrido KAN-ViT propuesto por [111] o los modelos de difusión CDEIT de [55], reportan métricas de fidelidad es-



**Fig. 3.22:** Resultados de reconstrucciones de imágenes experimentales utilizando TR, TV, DLEIP y DLEIP con TV [121].

tructural excepcionales ( $SSIM > 0.96$ ). No obstante, estos trabajos dependen de una calidad de señal idealizada o de infraestructuras computacionales robustas para el entrenamiento con miles de imágenes de TC reales [113]. Existe una desconexión entre estos modelos de “alta gama” y la realidad de la instrumentación portátil de bajo costo. Mientras que [100] con GraphEIT aborda con éxito la geometría irregular del tórax, su validación se apoya en datasets consolidados como KIT-4 [101]. Esta investigación se diferencia al proponer un control total sobre la cadena de datos, desde la fabricación de un fantoma físico ad-hoc hasta la adquisición con hardware basado en el microcontrolador ESP32, enfrentando un ruido de sistema que autores como [93] o [91] suelen omitir en sus modelos puramente sintéticos.

En segundo lugar, el desafío del *Sim-to-Real gap* es abordado de forma parcial en la literatura. Estrategias como el TSDL de [119] o la red MLAE de [118] han validado el uso de *transfer learning* para adaptar modelos sintéticos a fantasmas circulares, logrando una reducción del error notable. Sin embargo, persiste una carencia de estudios que integren este proceso de adaptación en un *pipeline* funcional de extremo a extremo que sea verdaderamente portátil. A diferencia del enfoque de [120], que utiliza gemelos digitales 3D para procesos de acoplamiento fluido-electrostático complejos, esta tesis simplifica y optimiza dicha transición mediante un gemelo digital en COMSOL diseñado específicamente para reflejar las no-idealidades del prototipo físico construido en laboratorio.

Existe por tanto una brecha relevante en la transferencia de estos modelos hacia dispositivos portátiles de bajo costo, y su validación en entornos físicos reales con ruidos de adquisición inherentes. Gran parte

del estado del arte omite este desafío de la brecha que existe entre pasar de las simulaciones ideales a instrumentación electrónica limitada, como la basada en microcontroladores de consumo general. Esta investigación cubre dicha brecha al proponer una metodología de *fine-tuning* que permite adaptar modelos entrenados con datos simulados a un sistema físico portable. Además, se introduce una comparativa entre arquitecturas convolucionales clásicas y modelos emergentes como KAN-ViT, explorando su capacidad de funcionamiento en sistemas reales y su generalización en tiempo real, un aspecto aún no explorado en la literatura de TIE portable de bajo costo.

## Capítulo 4 Metodología

---

### 4.1 Introducción

La metodología de esta investigación abarca 6 grandes conceptos para validar la hipótesis: Diseño y fabricación de fantoma pulmonar, gemelo digital en COMSOL, arquitectura de redes neuronales, sistema de adquisición TIE, adaptación de dominio mediante *transfer learning*, e integración del sistema de inferencia en tiempo real. Todo estas secciones muestran una línea cronológica de como se plantearon los procesos para esta tesis.

### 4.2 Diseño y fabricación de fantoma pulmonar

La validación de un sistema de TIE requiere de un entorno experimental controlado que replique, con un grado de fidelidad adecuado, las propiedades geométricas y eléctricas del tórax humano. En este contexto, el desarrollo de un fantoma físico no solo permite evaluar el desempeño del *hardware* de adquisición, sino que constituye el pilar fundamental para abordar el problema del *Sim-to-Real gap*, al proporcionar datos reales que contrasten con los modelos computacionales ideales.

En esta sección se detalla el proceso de creación de dicho entorno, abarcando desde el diseño geométrico basado en estándares anatómicos, hasta los procedimientos técnicos de manufactura y el ensamblaje de electrodos necesarios para la captura de señales.

#### 4.2.1 Diseño geométrico

El diseño del fantoma del estudio se fundamentó en la necesidad de replicar una morfología torácica realista para validar la reconstrucción de imágenes pulmonares mediante el dispositivo TIE. Para ello, se utilizó como referencia el FEM 'i2t3' del software EIDORS. Este modelo es un estándar en la literatura de TIE pulmonar, ya que se asemeja a la sección transversal del tórax humano, capturando la asimetría y las curvaturas anatómicas que caracterizan la zona torácica humana.

A partir de esta malla, se realizó la extracción de las coordenadas de frontera del dominio. El perfil 2D resultante fue importado al software de Diseño Asistido por Computadora (CAD) Autodesk Fusion

360, donde se procedió a la generación del modelo volumétrico. En este entorno, la capa 2D fue extruida para otorgar profundidad al fantoma, configurando una estructura de contenedor mediante la creación de una cavidad interna. Se definió un espesor de pared de 1 cm, garantizando la integridad estructural del fantoma.


Esta geometría base fue escalada a dimensiones humanas representativas, con un ancho de 28 cm, un largo de 15 cm y una altura total de 22 cm. El diseño se configuró con un arreglo de 16 electrodos equidistantes, distribuidos periféricamente para cubrir el contorno torácico y maximizar la sensibilidad en la región de interés. La altura de 22 cm fue seleccionada deliberadamente para asegurar que los objetos insertados en el medio conductor abarquen la totalidad del medio conductor, aproximando el comportamiento del sistema a un modelo de corrientes de plano.

El escalado y diseño final sirvieron tanto como plano maestro para la fabricación del fantoma físico, como para la generación del gemelo digital 2D en COMSOL Multiphysics. La elección de una geometría compartida entre ambos entornos es clave para reducir el error de modelado durante la etapa posterior de *transfer learning*. En la Figura 4.1 se puede observar el modelo FEM utilizado como referencia junto al plano CAD final.

## 4.2.2 Fabricación

La construcción del prototipo físico se divide en dos etapas: la impresión del fantoma en sí, y el desarrollo de los electrodos personalizados.

El cuerpo del fantoma fue fabricado mediante impresión 3D utilizando ácido poliláctico (PLA). Debido a la naturaleza porosa de las piezas impresas en 3D, se configuró una alta densidad de los perímetros, y un flujo de material optimizado para minimizar la formación de vacíos entre capas que pudieran derivar



**Fig. 4.1:** Transición desde FEM ‘i2t3’ de EIDORS hacia diseño geométrico final para fabricación.

en fugas del líquido conductor interior, utilizando una densidad de capa de 0.1 mm.

Tras la impresión, se aplicó un tratamiento de sellado en la superficie interna del fantoma. Este consistió en una capa densa de revestimiento impermeabilizante. El objetivo de este recubrimiento fue garantizar que el fantoma no presentara fugas y además proporcionar una superficie lisa.


Por otra parte, se fabricaron 16 electrodos de contacto utilizando láminas de cobre de 1 mm de espesor dada su alta conductividad. Cada lámina fue cortada de 1 cm de ancho por 28 cm de alto. Dado que la altura interna del fantoma es de 22, se definió un excedente de 6 cm en cada electrodo con un propósito funcional doble: primero, actúa como una pestaña de conexión externa al doblarse hacia el exterior del fantoma, situando el punto de unión eléctrica fuera del medio conductor; segundo, previene la corrosión en la zona de soldadura, minimizando el ruido que derivaría de la exposición de las conexiones a la humedad.

Con el fin de garantizar una compatibilidad estándar con los cables del dispositivo de adquisición TIE, se integraron conectores tipo *snap* extraídos de electrodos clínicos 3M Red Dot. Estos fueron soldados en el extremo de la pestaña externa, asegurando una conexión de fácil acoplamiento.

El posicionamiento de los electrodos en el interior del fantoma se realizó siguiendo la distribución angular del modelo 'i2t3' de EIDORS. Las láminas de cobre se fijaron a las paredes internas utilizando cinta Kapton, seleccionada por sus propiedades aislantes, evitando cortocircuitos indeseados en las paredes del fantoma. Además, para asegurar que los electrodos quedaran todos bien adheridos a la pared, se aplicó un sellado con silicona. Por lo que finalmente, y a modo de referencia, el sistema completo quedaría como se ve en la Figura 4.2. En esta imagen se puede ver un como estaría construido este fantoma con sus electrodos, junto al dispositivo TIE y el líquido conductor en su interior junto a una figura.

### 4.3 Gemelo digital en COMSOL

Para el entrenamiento de los modelos de reconstrucción basados en *deep learning*, es fundamental contar con un conjunto de datos extenso y preciso que represente fielmente la física del problema de TIE. Con este objetivo, se desarrolló un gemelo digital utilizando el software COMSOL Multiphysics V6.2, el cual permite simular el comportamiento eléctrico del fantoma bajo condiciones controladas y realistas. En esta sección se detalla la implementación de dicho modelo virtual, describiendo la construcción geométrica del dominio, la formulación matemática de las corrientes eléctricas, la configuración de las condiciones de borde y el sistema de automatización diseñado para la generación de muestras sintéticas.




**Fig. 4.2:** Imagen referencial del fantoma torácico. Se ve como va conectado el dispositivo con el fantoma, con los electrodos por la parte de afuera y el medio líquido conductor junto a una figura en su interior.

### 4.3.1 Definición geométrica

Con el fin de asegurar la consistencia geométrica entre los dominios físico y virtual, la frontera torácica del modelo se creó a partir de la exportación del perfil 2D desde Autodesk Fusion 360. El archivo resultante fue importado a COMSOL, para luego diseñar los 16 electrodos garantizando que estos coincidieran con el prototipo real. Luego de emplear múltiples funciones de geometría en COMSOL, como rotaciones, escalados, polígonos, entre otros, se logró replicar fielmente la estructura del fantoma físico.

Es importante destacar que a pesar de que el fantoma físico es un sistema de tres dimensiones, el gemelo digital se implementó como un modelo de dos dimensiones. Esta simplificación es físicamente válida y computacionalmente eficiente debido a que las inclusiones de prueba en el fantoma 3D poseen una geometría regular y se posicionan de forma que atraviesan longitudinalmente la totalidad del líquido conductor. Dado que la sección transversal de estos objetos es constante a lo largo del eje vertical, cualquier corte 2D en el plano de los electrodos representa fielmente la distribución de materiales en el volumen.

Para la discretización y el mallado del dominio, se implementó una malla de elementos finitos de tipo triangular. Se aplicó un refinamiento local en la zona cercana a los electrodos, donde los gradientes son más pronunciados utilizando una malla más fina controlada por la física para asegurar la convergencia numérica de la solución. Esta malla controlada por la física produce una mayor cantidad de triángulos al encontrarse con vértices de polígonos y ángulos cerrados que requieran una mejor resolución. En la



**Fig. 4.3:** Mallado utilizado en COMSOL para el gemelo digital. En la izquierda se nota el modelo completo, mientras que en la derecha se observa el detalle del mallado cerca de los electrodos.

Figura 4.3 se puede observar el mallado final del modelo.

### 4.3.2 Formulación física y propiedades de materiales

El comportamiento del campo eléctrico dentro del fantoma se rige por la aproximación cuasi-estática de las ecuaciones de Maxwell, dada la baja frecuencia de operación del sistema TIE que se está queriendo simular. En COMSOL, se utilizó la interfaz Corrientes Eléctricas (ec) del módulo AC/DC, la cual resuelve el potencial eléctrico  $V$  a partir de la ecuación de continuidad para la densidad de corriente total  $J$ :

$$\nabla \cdot \mathbf{J} = Q_{j,v}, \quad (16)$$

donde  $Q_{j,v}$  representa las fuentes de carga externas. La densidad de corriente total  $\mathbf{J}$  en un estudio temporal integra tanto los componentes de conducción como los de desplazamiento, definidos por la relación constitutiva:

$$\mathbf{J} = \sigma \mathbf{E} + \frac{\partial \mathbf{D}}{\partial t} + \mathbf{J}_e \quad (17)$$

En esta expresión,  $\sigma \mathbf{E}$  corresponde a la ley de Ohm ( $\mathbf{J}_c$ ), que domina el transporte de carga en el medio conductor. El término  $\frac{\partial \mathbf{D}}{\partial t}$  describe las corrientes de desplazamiento asociadas a la permitividad

del medio, donde  $\mathbf{D} = \epsilon_0 \epsilon_r \mathbf{E}$ . La inclusión de este término es relevante a 50 kHz para capturar cualquier comportamiento reactivo del sistema, aunque en soluciones salinas de alta conductividad el componente óhmico es el predominante. El campo eléctrico  $\mathbf{E}$  se relaciona con el potencial escalar mediante:

$$\mathbf{E} = -\nabla V \quad (18)$$

La precisión del gemelo digital depende de la correcta asignación de las propiedad eléctricas de los materiales. Las propiedades eléctricas asignadas a los materiales en el modelo COMSOL se basan en el montaje experimental y son las siguientes:


- Medio basal: En nuestro caso agua salinizada, se configuró con una conductividad de  $\sigma = 1.8 \text{ S/m}$  y una permitividad relativa de  $\epsilon_r = 1$ . Estos valores representan un medio altamente conductor, similar a los fluidos fisiológicos, permitiendo una propagación de corriente estable.
- Electrodo de cobre: Los 16 electrodos se modelaron con las propiedades de corriente del cobre puro, es decir, una conductividad de  $\sigma = 5.96 \times 10^7 \text{ S/m}$  y una permitividad relativa de  $\epsilon_r = 1$ . Su alta conductividad asegura que actúen como superficies equipotenciales, minimizando las pérdidas de energía en el electrodo.
- Inclusiones: Para los objetos de prueba insertados en el medio conductor, se asignaron propiedades variables durante la generación de la base de datos, con el fin de abarcar diferentes escenarios de contraste eléctrico.

### 4.3.3 Protocolo de estimulación y condiciones de borde

Para garantizar la coherencia entre el sistema físico y el entorno simulado, el protocolo de estimulación implementado en el gemelo digital replica la lógica de adquisición del dispositivo TIE. Se emplea un sistema de inyección y medición adyacente basada en una variante del método Sheffield. Este sistema puede verse a detalle en la Figura 4.4.

La configuración espacial de los electrodos en COMSOL se alineó con la disposición física del fantoma, designando al electrodo superior central como el electrodo 1 y continuando la numeración de electrodos en sentido horario con los 15 restantes.

En el entorno de simulación, se configuró un estudio temporal para replicar la dinámica de la señal



**Fig. 4.4:** Representación de la secuencia de adquisición en el dispositivo TIE. a) Primer patrón: inyección por el par (1, 2) y captura secuencial de diferenciales de voltaje (ej.  $V_{3-4}$ ,  $V_{5-4}$ , etc.). b) Segundo patrón: inyección por el par (3, 2) y medición en los electrodos libres (ej.  $V_{5-4}$ ,  $V_{5-6}$ , etc.).

sinusoidal de excitación a una frecuencia de 50 kHz. Las condiciones de contorno para el primer patrón de estimulación se definieron de la siguiente manera:

- Terminal de corriente: Para el electrodo 1, se aplicó una fuente de corriente dependiente del tiempo, definida como  $I(t) = 0.001 \cdot \sin(2\pi \cdot 50000 \cdot t)$ . Esta función asegura que el gemelo digital considere la fase y amplitud de la señal inyectada como en el dispositivo TIE.
- Tierra: El electrodo 2 se estableció como el nodo de referencia de potencial cero (0 V).
- Potencial flotante: Los electrodos restantes (3 a 16) se configuraron con la condición de potencial flotante. El uso de esta condición es fundamental, ya que permite que cada electrodo actúe como una superficie equipotencial de alta conductividad sin inyectar corriente al sistema, emulando fielmente el comportamiento de los electrodos de cobre en contacto con el medio conductor.

Esta configuración de condiciones de borde permite extraer las diferencias de potencial necesarias para construir los vectores de voltaje que servirán para el entrenamiento de modelos de reconstrucción, manteniendo la coherencia entre los datos sintéticos y los adquiridos experimentalmente.

Previo a seguir al siguiente paso, se compararon mediciones realizadas con el sistema de adquisición TIE físico con mediciones realizadas con el sistema simulado. Este consiste en mediciones con el fantoma pulmonar homogéneo, es decir, sin objetos en su interior. Con estas mediciones se calculó coeficientes de correlación de Pearson y regresión lineal, para visualizar que tan parecidos son estos dos sistemas.

#### 4.3.4 Generación automatizada de la base de datos

La eficacia de los modelos de *deep learning* en TIE dependen críticamente de la diversidad y calidad de la base de datos de entrenamiento. Debido a la dificultad práctica de obtener grandes cantidades de datos experimentales etiquetadas, se implementó un flujo de trabajo automatizado para generar una base de datos sintética que capture una amplia gama de casos de prueba.

La generación de datos se realizó integrando MATLAB con COMSOL a través de la herramienta *Livelink for MATLAB*. Esta integración permitió controlar la simulación en COMSOL a partir de funciones en MATLAB, pudiendo variar parámetros clave de los objetos de prueba y ejecutar múltiples simulaciones de manera automatizada.

Para asegurar que las redes neuronales aprendan a generalizar diferentes escenarios, se definieron ciclos de simulación que variaban sistemáticamente los siguientes parámetros:

- Forma del objeto: Se utilizaron tres geometrías fundamentales para representar diferentes estructuras internas. Estos fueron círculos, triángulos y cuadrados.
- Movimiento: Los objetos fueron desplazados en una malla de coordenadas  $(x, y)$  que cubre casi la totalidad del área interna de fantoma, utilizando pasos de desplazamiento, tanto horizontales como verticales, de 2 cm para asegurar una cobertura espacial adecuada.
- Tamaño: Se aplicó un factor de escala variable para simular objetos de diferentes tamaños, abarcando desde un largo/diámetro inicial de 3 cm hasta un máximo de 10 cm, pasando por 8 incrementos intermedios.
- Conductividad: Se asignaron valores de conductividad ( $\sigma$ ) en un rango amplio, permitiendo que el modelo reconozca tanto inclusiones aislantes como altamente conductoras. Los rangos fueron  $[10^{-3}, 10^{-2}, 10^1, 10^3, 10^6, 10^9]$  S/m

En resumen, los posibles diferentes escenarios varían según lo mostrado en la Tabla 4.1, considerando que el movimiento, tanto en el eje x como en el y es de 2 cm. Con estas posibles combinaciones, por cada

Parámetro	Cantidad
Formas	3 (Círculo, cuadrado y triángulo)
Tamaños	8 (3, 4, 5, 6, 7, 8, 9 y 10 cm)
Conductividades	6 ( $10^{-3}$ , $10^{-2}$ , $10^1$ , $10^3$ , $10^6$ , $10^9$ S/m)
Total de posibilidades por posición	$3 \times 8 \times 6 = 144$ combinaciones

**Tabla 4.1:** Cantidad de parámetros posibles para la simulación del fantoma. Combinando cada una de todas las posibles parámetros obtenemos 144 combinaciones por posición.

posición en que se encuentre la medición, esta tiene 144 combinaciones posibles. Por lo tanto, lo que determinará realmente la cantidad de datos es la cantidad de posiciones y si esta figura colisiona o no con los bordes del fantoma simulado.

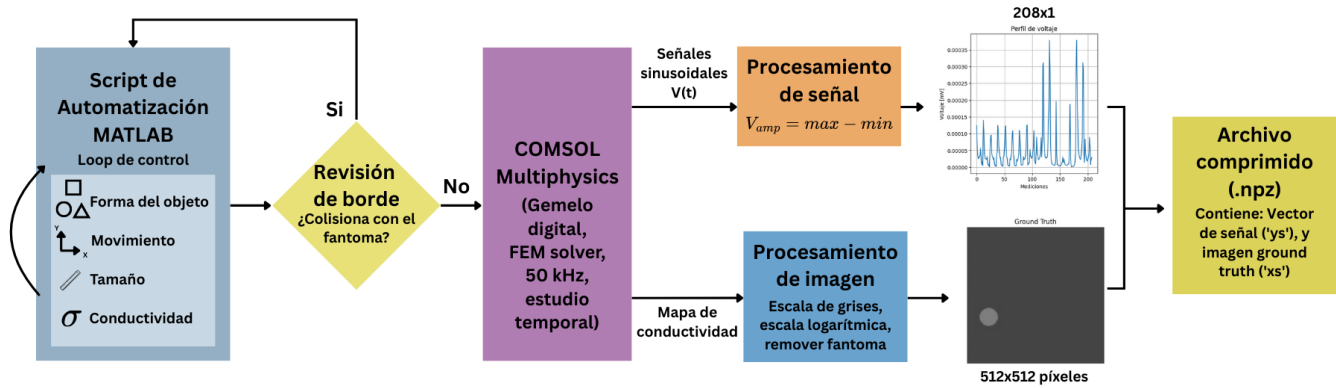
Como se comentó, un aspecto crítico del proceso es la validación de la posición de la figura respecto a la frontera del dominio. El algoritmo de control automatizado evalúa en cada iteración si la inclusión proyectada colisiona con las paredes del fantoma antes de ejecutar el *solver*. Si la suma de la posición y el tamaño del objeto excede los límites definidos, el ciclo se interrumpe y se procede a la siguiente escenario, garantizando que todos los datos generados correspondan a mediciones físicamente posibles.

Para el procesamiento de las señales de los resultados de las simulaciones, dado que el gemelo digital opera con un estudio temporal a 50 kHz, los resultados consisten en señales sinusoidales de voltaje  $V(t)$ . Para transformar estas señales en los vectores de entrada requeridos por las redes neuronales, se realizó un preprocesamiento para extraer la amplitud en cada canal.

La amplitud *peak to peak* de cada una de las mediciones se calculó mediante la diferencia entre los valores extremos de un ciclo de señal:

$$V_{amp} = \max(V(t)) - \min(V(t)) \quad (19)$$

Finalmente, las amplitudes obtenidas de las 13 mediciones por cada uno de los 16 patrones de inyección se concatenan para formar el vector de  $208 \times 1$  correspondiente a cada simulación. Este vector se vincula con un mapa de conductividad de  $512 \times 512$  píxeles, constituyendo el par de datos para el entrenamiento supervisado. Esta imagen para optimizar el aprendizaje de las redes neuronales y simplificarles la tarea se aplicaron dos transformaciones adicionales: primero, debido al amplio rango de valores de conductividad, la intensidad de los píxeles se representa en escala de grises logarítmica. Esta permite que el modelo sea sensible tanto a cambios en objetos aislantes como en conductores. Segundo, con el



**Fig. 4.5:** Diagrama de flujo del proceso de generación automatizada de la base de datos sintética. Se ilustra la interacción entre el script de control en MATLAB, la validación geométrica en COMSOL y el post-procesamiento dual de señales e imágenes.

fin de reducir la complejidad, la carga computacional, y centrar la atención a la reconstrucción del objeto de interés, se eliminó la representación visual de la frontera de fantoma. La imagen resultante contiene únicamente el objeto de prueba sobre el fondo neutro, simplificando la extracción de características relevantes por parte de la arquitectura de las redes.

Para optimizar el manejo y almacenamiento de la información, cada par de datos (entrada y etiqueta) se comprime y almacena en archivos de formato *.npz*. Este formato permite agrupar estructuras de datos en un solo archivo, facilitando la carga eficiente de los datos desde Python.

Todo este proceso automatizado se ilustra en el diagrama de flujo de la Figura 4.5, que resume la interacción entre MATLAB y COMSOL, así como las etapas de preprocesamiento y almacenamiento de datos.

## 4.4 Arquitectura de redes neuronales

El objetivo central de esta parte de estudio es la implementación de modelos de *deep learning* capaces de reconstruir imágenes de conductividad a partir de los datos de voltaje obtenidos mediante la simulación en COMSOL. El desarrollo, entrenamiento y evaluación de estas arquitecturas se llevó a cabo utilizando el *framework* PyTorch. Para el procesamiento, se utilizó un computador equipado con un procesador Intel Core i7-13700KF de 13<sup>a</sup> generación y una GPU NVIDIA RTX 4090 con 24 GB de VRAM, lo que permitió manejar eficientemente los tiempos de entrenamiento y la optimización de los modelos.

Para este propósito, se seleccionaron y adaptaron arquitecturas de redes neuronales convolucionales

(CNN y U-Net) y de *vision transformer* (KAN-ViT), reconocidas por su eficacia en tareas de reconstrucción de imágenes en TIE. Para asegurar la convergencia y capacidad de la generalización de los modelos, se adoptó cinco estrategias para todos los modelos:

- Antes de ingresar a la red, los vectores de voltaje de  $208 \times 1$  fueron procesados mediante una estandarización estadística utilizando la clase *StandardScaler*. Esta técnica transforma cada característica para que posea una media de 0 y una desviación estándar de 1, eliminando las diferencias de escala entre los distintos diferenciales de voltaje medidos en la periferia. Este paso es fundamental para estabilizar el proceso de optimización, asegurando que todas las entradas contribuyan de manera equitativa al cálculo de los gradientes durante el entrenamiento.
- El dataset total se dividió en una proporción de 60 % para entrenamiento, 20 % para validación y 20 % para prueba. Debido a que las inclusiones triangulares presentaron una menor tasa de éxito en la simulación por colisiones con los bordes del fantoma, se aplicó aumento de datos (*data augmentation*) únicamente a esta clase dentro del conjunto de entrenamiento. La técnica consistió en la inversión en el eje Y (*flip*) tanto del vector de voltajes de entrada como de su correspondiente imagen de conductividad. Esta estrategia permitió duplicar la representatividad de los triángulos en el entrenamiento sin incurrir en *data leakage*, garantizando que el modelo fuera probado ante variaciones geométricas que no fueron vistas durante el entrenamiento.
- Reducción de dimensión de los datos de entrada de  $512 \times 512$  a  $60 \times 60$  píxeles, minimizando la carga computacional y facilitando el aprendizaje de los modelos.
- Para la optimización de los hiperparámetros de la red, en lugar de una selección manual por ensayo y error, se utilizó un *framework* Optuna para realizar una búsqueda bayesiana de los hiperparámetros óptimos para cada una de las tres arquitecturas. Este proceso permitió ajustar de una manera eficiente variables como la tasa de aprendizaje, el *batch size*, y la profundidad de los filtros, logrando maximizar las métricas de rendimiento.
- Para prevenir el sobreajuste o *overfitting*, se implementó *early stopping* como técnica de regulación. Este método monitorea la pérdida en el conjunto de validación y detiene el entrenamiento si no se observa una mejora significativa tras un número determinado de épocas (paciencia o *patience*), asegurando que el modelo conserve su capacidad de generalización.

#### 4.4.1 Convolutional Neural Network (CNN)

La red recibe un vector de entrada  $1 \times 208$ . A través de un proyector lineal de dos capas, el vector se expande primero a 512 neuronas y luego a un tensor de 28,800 elementos. Mediante una operación de *reshape*, este tensor se convierte en un volumen de características inicial de  $128 \times 15 \times 15$ .

Para alcanzar la resolución final de  $60 \times 60$ , la red utiliza bloques de sobremuestreo (*upsampling*) bilineal que expanden la resolución espacial progresivamente ( $15 \rightarrow 30 \rightarrow 60$ ). Cada etapa de expansión es seguida por un bloque convolucional que refina la estructura de la inclusión detectada.

Cada bloque convolucional integra capas de convolución de  $3 \times 3$ , normalización por lotes (*Batch Normalization*) para estabilizar el gradiente, y funciones de activación ReLU. La capa final consiste en una convolución de  $1 \times 1$  con activación Sigmoide, que colapsa los canales en una imagen de conductividad normalizada de un solo canal.

El entrenamiento se realizó minimizando la función de pérdida del MSE mediante el optimizador Adam. Mediante Optuna, se estableció su tasa de aprendizaje de , *batch size* y una profundidad de filtros (*base filters*). La regulación por *early stopping* se configuró con una paciencia de 8 épocas durante la etapa de transferencia de aprendizaje, garantizando un ajuste preciso a los datos reales sin comprometer la estabilidad del modelo. En la Figura 4.6 se presenta un diagrama de bloques de la arquitectura optimizada de la CNN.

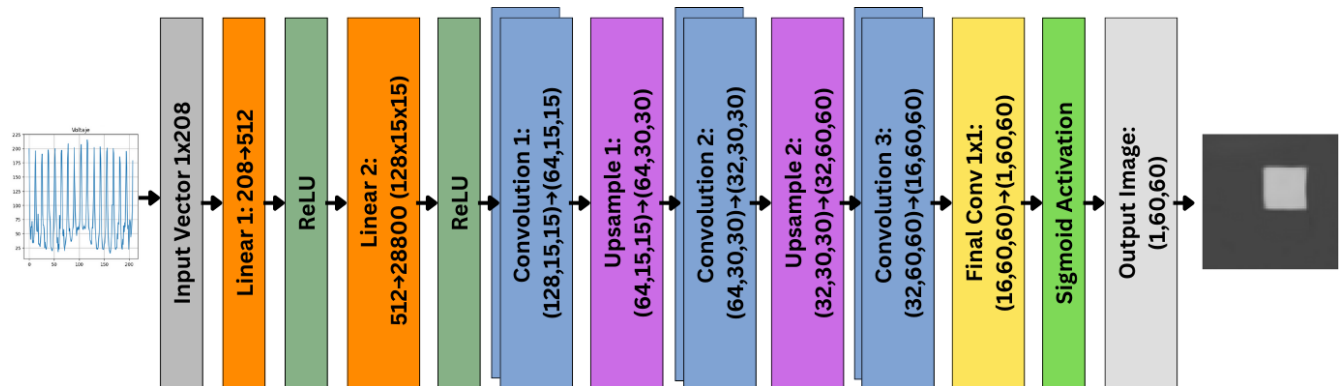


Fig. 4.6: Diagrama de bloques de la arquitectura CNN optimizada.

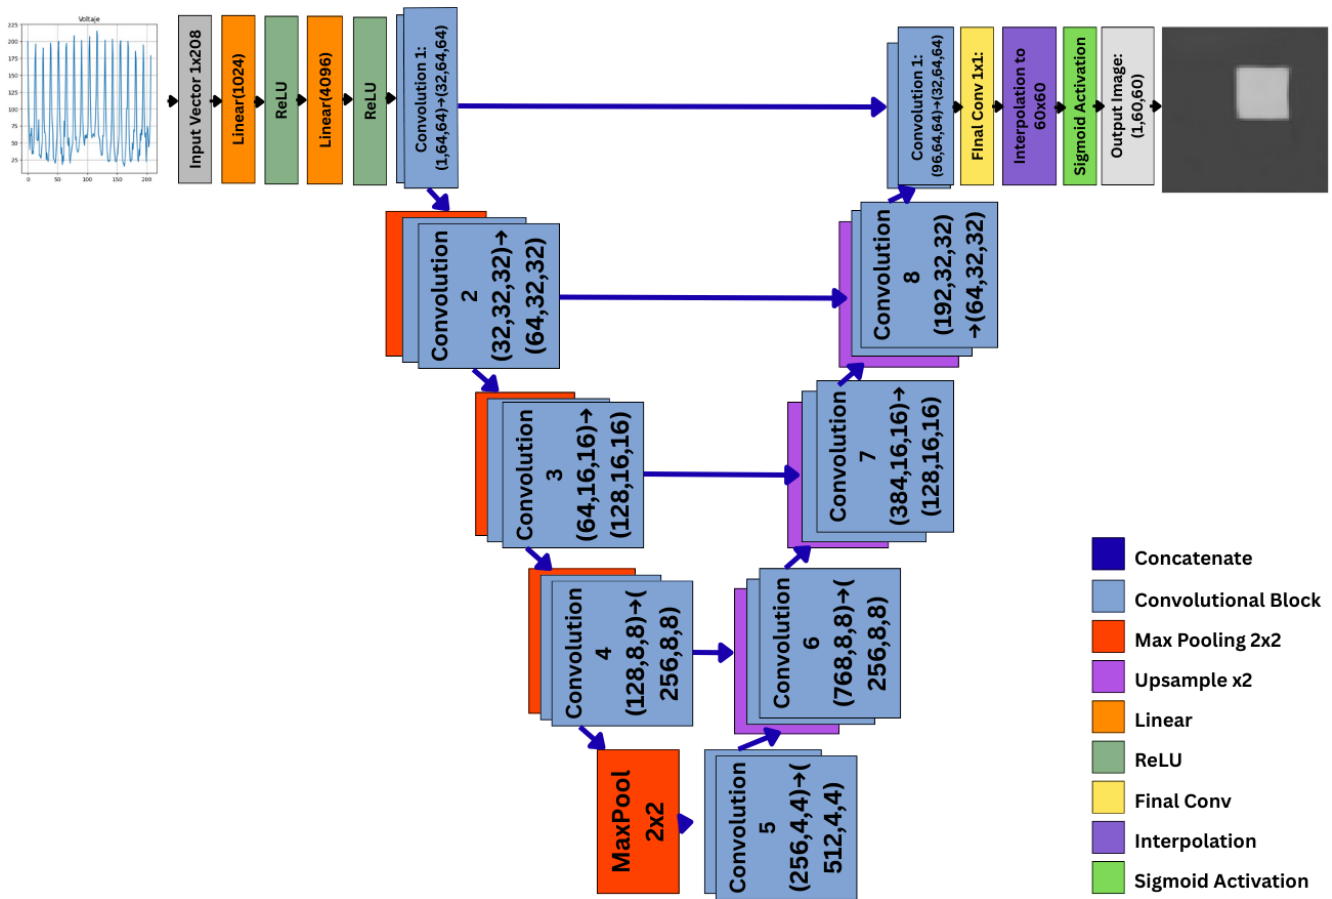
#### 4.4.2 U-Net

La implementación de la arquitectura U-Net para la reconstrucción de imágenes en TIE se fundamenta en su capacidad para combinar información abstracta con detalles espaciales de alta resolución. Al igual que en las demás arquitecturas evaluadas, se estandarizó la resolución del *ground truth* a  $60 \times 60$  píxeles, una decisión estratégica destinada a reducir la carga computacional y el número de parámetros entrenables sin sacrificar la identificación morfológica de las inclusiones. La configuración de los hiperparámetros críticos se realizó mediante una optimización bayesiana con el *framework* Optuna, lo que permitió determinar una tasa de aprendizaje óptima, un *batch size* una base de filtros para los bloques convolucionales iniciales. Al igual que en la CNN, la función de pérdida empleada para esta arquitectura fue el MSE, implementada mediante la clase *nn.MSELoss()* de Pytorch.

El procesamiento de los datos se inicia en un bloque de proyección lineal que transforma el vector de voltajes de entrada de  $208 \times 1$  en una representación matricial de  $1 \times 64 \times 64$ , la cual sirve de entrada para el camino de contracción o codificador. Este codificador está estructurado mediante bloques de doble convolución, compuestos por dos capas convolucionales de  $3 \times 3$ , normalización por lotes (*batch normalization*) y activaciones ReLU que estabilizan el aprendizaje y gestionan la no linealidad del problema inverso. A través de etapas sucesivas de *max pooling* de  $2 \times 2$ , la red reduce la resolución espacial mientras incrementa la profundidad de los canales de características hasta alcanzar los 1024 filtros en el nivel más profundo, permitiendo extraer patrones complejos de la distribución de conductividad.

La recuperación de la resolución original se lleva a cabo en el camino de expansión o decodificador, el cual emplea bloques de *upsampling* bilineal. El aspecto fundamental de esta etapa es la integración de conexiones de salto o *skip connections*, representadas por la concatenación directa de los mapas de características provenientes del codificador con las capas de expansión. Esta arquitectura permite que la red recupere información espacial detallada que suele perderse durante la reducción de escala, facilitando una definición precisa de los bordes y la geometría de los objetos reconstruidos. Al finalizar el proceso de expansión, una capa de interpolación bilineal ajusta la salida interna de  $64 \times 64$  a la resolución objetivo de  $60 \times 60$ , aplicando una activación Sigmoide para normalizar los valores de los píxeles en el rango de conductividad esperado.

Para asegurar la robustez del modelo y su capacidad de generalización ante datos reales, se implementó una estrategia de regulación basada en *early stopping* con una paciencia de 8 épocas durante el entrenamiento. Este mecanismo supervisa la pérdida en el conjunto de validación y detiene el entrenamiento de forma automática cuando no se detectan mejoras significativas, evitando el sobreajuste de la red a las fluctuaciones específicas del conjunto de entrenamiento y garantizando una reconstrucción fiel a la



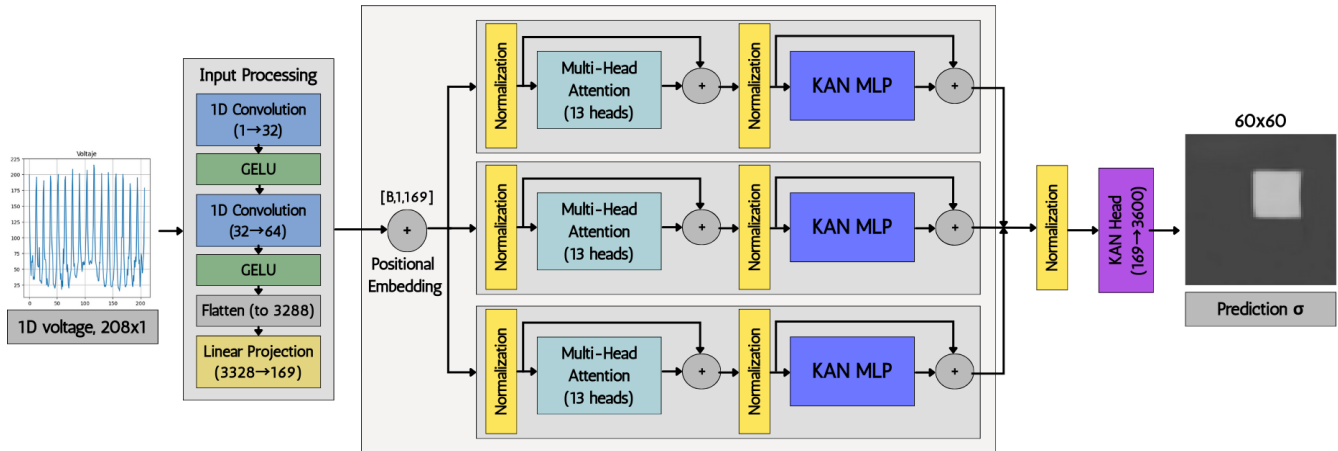
**Fig. 4.7:** Diagrama de bloques de la arquitectura U-Net implementada para la reconstrucción de imágenes. Las flechas azules horizontales ilustran las conexiones de salto que permiten preservar la resolución espacial al vincular el codificador con el decodificador.

física del sistema. La Figura 4.7 muestra un diagrama de bloques de la arquitectura U-Net implementada para la reconstrucción de imágenes.

#### 4.4.3 Kolmogorov-Arnold Visual Transformer (KAN-ViT)

La arquitectura Kolmogorov-Arnold Visual Transformer (KAN-ViT) representa la evolución más avanzada en este estudio para la resolución del problema inverso en TIE. A diferencia de las redes puramente convolucionales, esta arquitectura integra la capacidad de modelado global de los Vision Transformers (ViT) con la eficiencia matemática de las Kolmogorov-Arnold Networks (KAN), permitiendo capturar relaciones no lineales complejas entre las mediciones periféricas y la conductividad interna.

El procesamiento comienza con un bloque denominado *Convolutional Stem*, que actúa como el ex-



**Fig. 4.8:** Diagrama de bloques de la arquitectura KAN-ViT implementada. Se destaca el flujo desde el Convolutional Stem hasta los bloques de atención que integran capas KAN con funciones de activación aprendibles para la reconstrucción de imágenes de  $60 \times 60$ .

tractor de características inicial. En lugar de parches de imagen tradicionales, este bloque procesa el vector de voltajes de  $208 \times 1$  mediante dos capas de convolución 1D para detectar patrones locales entre electrodos adyacentes, proyectando finalmente los datos a un espacio de embedding de 169 dimensiones. Esta representación latente se introduce en una serie de bloques de Transformer, donde la profundidad de la red (número de capas) y el número de cabezas de atención se optimizaron mediante Optuna, explorando rangos de 2 a 6 capas y hasta 13 cabezas de atención para maximizar la correlación estructural de la reconstrucción.

La innovación disruptiva de este modelo es la sustitución de las capas densas (MLP) tradicionales por bloques KAN. Mientras que un MLP usa funciones de activación fijas en los nodos, las capas KAN emplean funciones de activación aprendibles (basadas en B-splines) en las conexiones o aristas de la red. En la implementación, se configuró un grid size de 6 y un denominador de spline de 0.28, permitiendo que la red ajuste la forma de la función de activación durante el entrenamiento. Esto optimiza drásticamente el número de parámetros necesarios para representar la física del problema, logrando que el modelo aprenda la morfología de los objetos de forma más eficiente que las redes convencionales.

Para el aprendizaje, se implementó una función de pérdida híbrida que combina tres componentes críticos: el error absoluto (L1) para la magnitud, la *Pearson Loss* para maximizar la correlación lineal entre la predicción y el Ground Truth, y una pérdida de Variación Total (TV Loss) con un peso de hasta 0.01 para suavizar la imagen y reducir el ruido de fondo. El entrenamiento se reguló con *early stopping* (con una paciencia ajustada según la fase de entrenamiento) y el optimizador AdamW, garantizando que la red de 3.600 neuronas de salida genere imágenes de  $60 \times 60$  píxeles con una alta fidelidad geométrica.

#### 4.4.4 Evaluación de métricas de rendimiento

Para validar el rendimiento de las redes neuronales frente al *ground truth* simulado, se seleccionaron cuatro métricas de rendimiento estándar en el campo de la reconstrucción de imágenes por TIE usando *deep learning*. La implementación de estas métricas se apoyó principalmente en la librería Torchmetrics, la cual proporciona implementaciones optimizadas y estandarizadas para el ecosistema de PyTorch.

Las métricas empleadas y sus fuentes de cálculo se resumen a continuación:

- Error Cuadrático Medio (MSE): Utilizado tanto como función de pérdida como métrica de evaluación, su cálculo se realizó mediante la función *F.mse\_loss* de la librería *torch.nn.functional*.
- Índice de Similitud Estructural (SSIM): Permite evaluar la fidelidad de la estructura geométrica de las inclusiones reconstruidas. Se implementó a través de la función *torchmetrics.functional.structural\_similarity\_index\_measure*.
- Coeficiente de Correlación (CC): Calculado mediante la fórmula de correlación de Pearson implementada con operaciones fundamentales de PyTorch (*torch.sum*, *torch.sqrt*), midiendo la similitud lineal entre la predicción y el valor real.
- Error Relativo de Imagen (RIE): Implementado mediante el cálculo de normas L2 con *torch.norm* en PyTorch, proporcionando una medida del error relativo en la magnitud de la conductividad reconstruida.

Con la definición de estas métricas, se concluye la descripción de la arquitectura de las redes neuronales, estableciendo el marco de evaluación que se utilizará en el capítulo de resultados para comparar la eficacia de la CNN, la U-Net y el KAN-ViT tanto en simulaciones como en datos experimentales.

### 4.5 Sistema de adquisición TIE

En esta sección se describe el sistema de adquisición del dispositivo TIE utilizado para este estudio. Se empleó un sistema de tomografía por impedancia eléctrica portable y de bajo costo, cuyo diseño busca democratizar la tecnología TIE para aplicaciones médicas de monitoreo continuo. Este *hardware* proporciona adquiere datos TIE necesarios para luego realizar procesos de *fine-tuning* y evaluar el desempeño de las arquitecturas de redes neuronales implementadas ante la variabilidad del mundo real.

### 4.5.1 Instrumentación

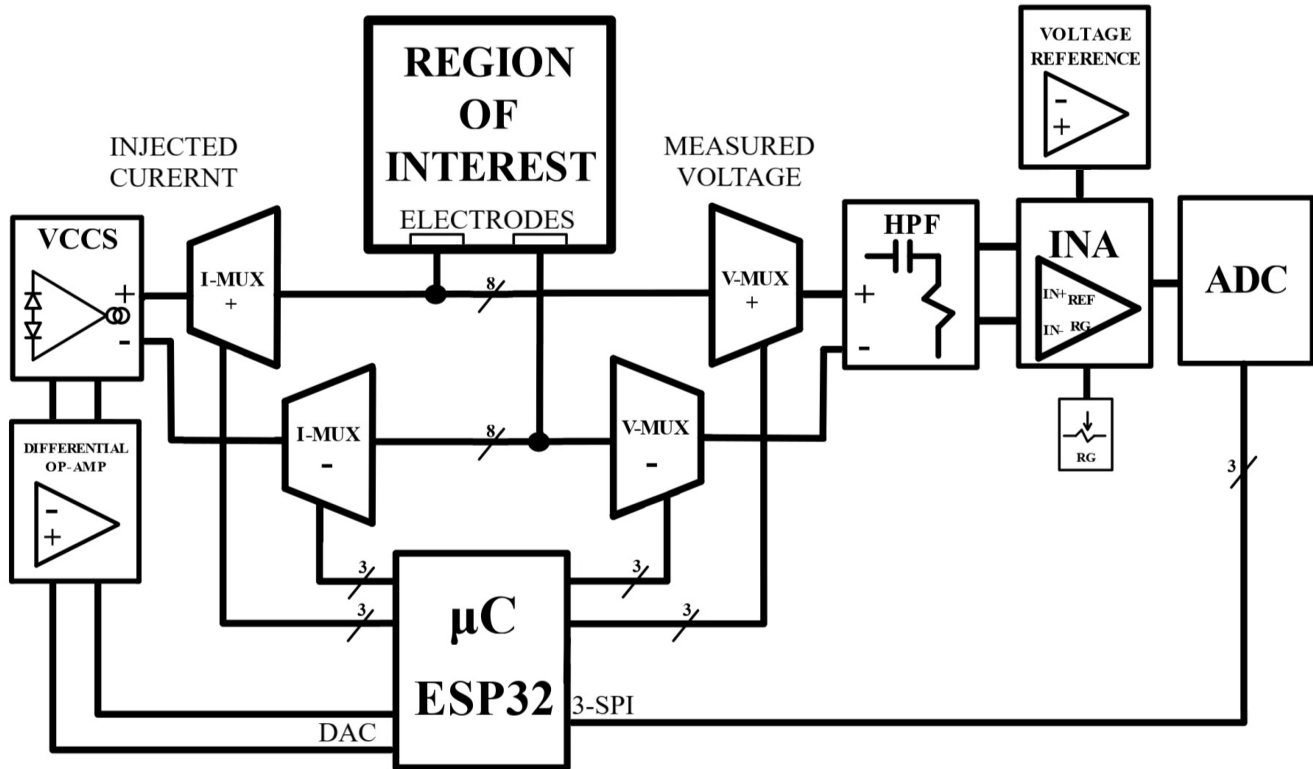
El dispositivo se basa en una arquitectura de 16 electrodos y se organiza en torno a un núcleo de procesamiento digital y una etapa analógica de acondicionamiento de señales.

- **Unidad de Control y Síntesis de Señal:** El núcleo del sistema es un módulo ESP32-PICO-D4 (ESP32-PICO-KIT v4), seleccionado por su reducido tamaño y capacidades de conectividad Bluetooth y WiFi . A diferencia de otros sistemas que requieren generadores de señales externos, este dispositivo utiliza el bloque funcional del convertidor DAC interno del ESP32 junto con su generador de ondas de coseno integrado. Esta configuración permite sintetizar de forma autónoma una señal sinusoidal de 50 kHz con una amplitud de 3.3 Vpp y un offset de 1.65 V, la cual es posteriormente atenuada mediante un circuito diferencial para excitar la fuente de corriente.
- **Fuente de Corriente y Conmutación:** Para la estimulación del tejido se implementó una Fuente de Corriente Controlada por Voltaje (VCCS) basada en el Amplificador de Transconductancia Operacional (OTA) LM137007. Este circuito genera una corriente de estimulación de 1 mA a 50 kHz con una alta impedancia de salida (1.4 MΩ), garantizando la estabilidad de la inyección ante variaciones en la carga. La distribución de esta corriente hacia los 16 electrodos se gestiona mediante multiplexores analógicos CD4051, los cuales son controlados directamente por las salidas digitales del microcontrolador.
- **Etapa de Lectura y Conversión Análoga-Digital:** Los voltajes diferenciales resultantes en la periferia son capturados por un amplificador de instrumentación INA128, caracterizado por su alto rechazo al modo común (CMRR de 125 dB). Para la digitalización, se integró un módulo Digilent PmodAD1, el cual cuenta con un ADC de 12 bits comunicado vía SPI con el microcontrolador. La señal se captura a una velocidad de muestreo de 350 kS/s, tomando 64 muestras consecutivas por cada canal para asegurar una estimación estable de la amplitud mediante promediado digital.

En la Figura 4.9 se presenta un diagrama de bloques del dispositivo TIE, ilustrando la conexión entre los diferentes módulos esenciales explicados anteriormente.

### 4.5.2 Protocolo de adquisición

El dispositivo opera bajo el protocolo de estimulación y medida adyacente, conocido como método Sheffield, al igual que se simuló anteriormente en COMSOL para simular este dispositivo, manteniendo



**Fig. 4.9:** Diagrama de bloques del sistema de adquisición TIE utilizado en este estudio [2].

la coherencia entre los datos obtenidos con este dispositivo y los generados sintéticamente.

Este ciclo de adquisición, ilustrado previamente en la Figura 4.4, consta de 16 patrones de inyección adyacentes. Para cada uno de estos patrones, se realizan 13 mediciones de voltajes diferenciales en los electrodos que no transportan corriente, resultando en un vector de 208 mediciones por cada cuadro o frame de imagen. El sistema alcanza una tasa de adquisición de 2 fps, otorgando un tiempo de estabilización de 2 ms entre conmutaciones de los multiplexores para garantizar la fidelidad de la señal muestreada.

### 4.5.3 Diferencia de dominio

El éxito de la reconstrucción mediante algoritmos de *deep learning* en condiciones de operación real depende críticamente de la identificación y mitigación del desplazamiento de dominio o *domain shift*, fenómeno que describe la discrepancia entre la distribución de los datos sintéticos ideales y las señales experimentales capturadas por el *hardware*.

En este estudio, el factor determinante de esta discrepancia es la variabilidad en la impedancia de contacto electrodo y el medio conductor, la cual presenta un comportamiento altamente no lineal y


heterogéneo que el modelo de elementos finitos de COMSOL no puede replicar con exactitud. Esta problemática se ve intensificada por la naturaleza artesanal de la construcción del fantoma físico: dado que los electrodos de cobre fueron fabricados a mano y las soldaduras de conexión presentan irregularidades intrínsecas al proceso manual, es imposible garantizar una uniformidad absoluta en las superficies de contacto y en las resistencias de unión entre los 16 canales. Estas diferencias individuales en el montaje físico provocan caídas de potencial y desfases variables en la periferia del dominio, introduciendo un “ruido estructural” en los vectores de voltaje de 208 mediciones que no está presente en las simulaciones perfectas. A esta fuente de error se suman factores secundarios como el ruido térmico de la etapa analógica, la precisión del ADC del módulo ESP32-PICO-D4 y las simplificaciones geométricas propias del modelado en dos dimensiones. En consecuencia, la caracterización de estas imperfecciones físicas justifica la implementación de técnicas de transferencia de aprendizaje para que los modelos CNN, U-Net y KAN-ViT logren compensar las asimetrías del *hardware* real y realizar reconstrucciones morfológicamente precisas.

## 4.6 Adaptación de dominio mediante Transfer Learning

La transición de modelos entrenados en entornos sintéticos hacia aplicaciones en el mundo real conlleva el desafío del desplazamiento de dominio, donde las discrepancias en el ruido y la física del sistema pueden degradar el rendimiento de la reconstrucción. Para mitigar este efecto, se implementó una estrategia de aprendizaje por transferencia (*transfer learning*), utilizando el conocimiento previo obtenido en las simulaciones de COMSOL como base para el ajuste de los modelos ante datos experimentales.

### 4.6.1 Adquisición y digitalización de datos reales

La recolección de datos reales se llevó a cabo utilizando el fantoma físico conectado al dispositivo de adquisición descrito en la sección anterior. Para garantizar la coherencia visual con el conjunto de datos sintéticos, se diseñó un montaje experimental con una cámara dispuesta de forma cenital, capturando fotografías del plano superior del fantoma bajo un ángulo constante. Se utilizaron cuatro tipos de inclusiones con propiedades eléctricas distintas: dos cilindros (uno conductor de metal y uno aislante de vidrio) y dos figuras impresas en filamento PLA, correspondientes a un paralelepípedo y una estructura de prisma triangular. La conductividad utilizada en el medio conductor fue realizada para igualar la realizada en simulación, es decir, 1.8 S/m. Para lograr esta conductividad se mezclaron 3 litros de agua con 3.45 g de sal. En la Figura 4.10 se puede ver el setup completo de toma de muestras, con la toma de




**Fig. 4.10:** Setup de adquisición de señales de voltaje con dispositivo TIE en fantoma torácico. En el fantoma se encuentra el equivalente a un círculo aislante (botella de vidrio). Celular tomando fotografías para la futura creación de etiquetas digitales.

fotografía y la adquisición de señales.

El proceso de adquisición se estructuró para capturar la variabilidad intrínseca del *hardware* mediante un protocolo de activación manual. Por cada disposición física de los objetos, se capturó una única fotografía de referencia. La obtención de señales de voltaje se realizó de forma asíncrona: primero, se activaba el *hardware* por un ciclo de operación fijo de 60 segundos; posteriormente, el inicio de la captura de datos se gatilla manualmente mediante un botón en el dispositivo. Debido a que el instante de inicio de la grabación dependía del tiempo de respuesta de presión del botón, la cantidad de *frames* recolectados presentó una variabilidad inherente entre experimentos, obteniendo una media de 40 cuadros por toma. Posteriormente, a todas las señales capturadas en una misma sesión se les adjudicó la misma imagen digitalizada.

Esta estrategia de vincular múltiples señales a una misma referencia visual se implementó por tres



**Fig. 4.11:** Inclusiones impresas en PLA para distintas configuraciones. Prisma triangular y paralelepípedo

razones técnicas:

- Variabilidad de la señal: Las mediciones de voltaje presentan fluctuaciones debido al ruido y las variaciones del sistema de adquisición durante el tiempo de muestreo.
- Robustez del modelo: Exponer la red a distintas variantes ruidosas de una misma distribución de conductividad incentiva el aprendizaje de características robustas, permitiendo que el modelo ignore fluctuaciones falsas del *hardware*.
- Aumento de datos para *fine-tuning*: Esta metodología permitió expandir los 150 experimentos físicos a un dataset de más de 7.000 datos totales, proporcionando el volumen necesario para una convergencia estable en el proceso de *fine-tuning*.

Es importante destacar, que dada la baja densidad del filamento PLA utilizado en las inclusiones de estas mediciones (prisma triangular y el paralelepípedo), se presentó el desafío técnico de la flotabilidad de las figuras dentro de medio conductor. Para garantizar la inmovilidad de los objetos durante la captura de las señales de voltaje, se diseñó un protocolo de estabilización mediante un peso encima de las figuras. No obstante, la presencia de este peso superior sobre las inclusiones generaba una interrupción visual, impidiendo el registro fotográfico necesario para la posterior digitalización del *ground truth*. De todas maneras, en la Figura 4.11 se pueden apreciar estas dos figuras hechas con PLA, prisma triangular y paralelepípedo.

Para resolver esta limitación, se implementó un sistema de plantillas de referencia completamente planas. Antes de cada experimento, se fabricó una lámina delgada con la geometría exacta de la base de

objeto. El procedimiento de captura se estructuró en dos fases: Primero, la fase de medición de voltajes, donde se posicionaba a plantilla en el fondo del fantoma, situando sobre ella el objeto y el peso para asegurar la inmovilidad de la figura. En este estado, se procedió a la captura de los cuadros de señal eléctrica. Segundo, una vez ya finalizada la adquisición, se retira cuidadosamente el objeto, dejando el peso encima de la plantilla manteniendo esta en su posición original. En esta etapa se realizó la fotografía para la posterior digitalización.

Este protocolo de dos fases también ofreció una ventaja crítica respecto a la precisión de la digitalización, ya que elimina el error de parelaje. Debido a la altura de los objeto y la posición fija de la cámara superior, la captura directa del objeto introducía distorsiones de perspectiva que desplazaban visualmente la ubicación real de la base respecto a los electrodos. Al capturar únicamente la plantilla base con el peso, la cual se encuentra en el mismo plano que el fondo del fantoma, se garantiza una correspondencia espacial exacta para la etiqueta digitalizada, eliminando proyecciones falsas derivadas del volumen del objeto.

## 4.6.2 Proceso de Fine-tuning

Tras la consolidación del dataset experimental, se aplicó la estandarización utilizando el mismo tipo de escalador utilizado previamente, pero esta vez solo con los datos reales. Para la fase de *fine-tuning*, se implementó una estrategia de Validación Cruzada por Grupos (*Group K-Fold Cross-Validation*) con  $K = 5$  particiones.

A diferencia de una partición aleatoria convencional, esta técnica es esencial debido a la naturaleza de los datos reales, donde múltiples cuadros de señal comparten una misma imagen de referencia. El uso de *Group K-Fold* garantiza que:

- **Prevención de Data Leakage:** Todos los cuadros pertenecientes a una misma toma física (un experimento completo de 60 segundos) se mantienen en un mismo bloque, ya sea de entrenamiento o de validación. Esto evita que el modelo sea evaluado con señales ruidosas de una disposición física que ya “conoció” durante el entrenamiento.
- **Robustez Estadística:** El modelo se entrena y valida 5 veces de forma independiente, rotando los grupos de experimentos. Esto asegura que las métricas de rendimiento reportadas (SSIM, CC, MSE, RIE) no dependan de una partición fortuita de los datos, sino que reflejen la capacidad real de generalización ante nuevas disposiciones físicas en el fantoma.

Para la evaluación final, se reservó un conjunto de prueba independiente (20 % de los datos totales) que nunca participó en ninguna de las iteraciones de la validación cruzada. El entrenamiento se realizó manteniendo las mismas estrategias de optimización y regulación definidas previamente:

- **Transferencia de Pesos:** Los modelos cargaron los pesos obtenidos tras el entrenamiento con los datos de COMSOL, permitiendo que las redes partieran de un conocimiento físico sólido antes de ajustarse a las no-idealidades del dispositivo.
- **Consistencia en la Optimización:** Se preservaron las funciones de pérdida originales para garantizar que cada arquitectura refinara su aprendizaje bajo los mismos criterios de error con los que fue realizada anteriormente. De este modo, para CNN y U-Net se utilizó el MSE, mientras que para el modelo KAN-ViT se mantuvo el uso de la función de pérdida híbrida. Esta estabilidad, sumada al criterio de *early stopping* con una paciencia de 8 épocas, permitió compensar el ruido del *hardware* y las variaciones en las soldaduras de los electrodos sin comprometer la base teórica aprendida en la simulación.

### 4.6.3 Análisis estadístico de resultados

Para garantizar la validez científica de la comparación entre las arquitecturas propuestas (CNN, U-Net y KAN-ViT) y asegurar que las diferencias observadas en el desempeño no sean producto del azar, se diseñó un protocolo de análisis estadístico inferencial. Este análisis se aplicó al conjunto de datos de datos experimentales (reales), dado que son el resultado final de todo el proceso.

Este análisis se evaluará para cada métrica de rendimiento (CC, SSIM, MSE, RIE) de forma independiente. Debido a que los datos no presentan una distribución normal, se optó por el uso de estadística no paramétrica.

El procedimiento estadístico se estructuró en tres niveles:

- **Prueba de Friedman (Omnibus):** Se utilizó como test de hipótesis global para determinar si existen diferencias significativas entre las medianas de los tres grupos (arquitecturas). Esta prueba es el equivalente no paramétrico del ANOVA de medidas repetidas y permite identificar si al menos un modelo difiere de los demás con un nivel de significancia  $\alpha = 0.05$ .
- **Pruebas Post-Hoc de Wilcoxon:** Ante el hallazgo de diferencias significativas en la prueba de Friedman, se realizaron comparaciones por pares mediante el test de rangos con signo de Wilcoxon. Esta

prueba evalúa la magnitud de la diferencia entre dos modelos específicos aplicados a las mismas muestras.

- Corrección de Bonferroni: Para mitigar el riesgo de error tipo I (falsos positivos) derivado de las comparaciones múltiples, se aplicó la corrección de Bonferroni. El umbral de significancia original ( $\alpha = 0.05$ ) se ajustó dividiéndolo por el número de comparaciones (3), estableciendo un nuevo valor crítico de  $p < 0.0167$  para declarar significancia.

Complementariamente a la significancia estadística ( $p$ -valor), se calculó el tamaño del efecto ( $r$ ) para cada comparación. Mientras que el  $p$ -valor indica si existe una diferencia, el valor de  $r$  cuantifica la relevancia práctica de dicha diferencia, clasificándose según los criterios de Cohen en:

- Pequeño:  $0.1 \leq r < 0.3$
- Mediano:  $0.3 \leq r < 0.5$
- Grande:  $r \geq 0.5$

Este análisis integral permite no solo identificar el modelo con mejor desempeño, sino también evaluar la robustez y la reproducibilidad de cada arquitectura frente a la brecha de dominio.

## 4.7 Integración del sistema de inferencia en tiempo real

El objetivo final del sistema es la reconstrucción de imágenes de conductividad de forma continua y síncrona con la captura de datos. Para ello, se diseñó un entorno de ejecución que integra la adquisición desde el dispositivo TIE con el procesamiento de reconstrucción de imagen, minimizando la latencia para permitir una visualización en tiempo real.

### 4.7.1 Arquitectura de comunicación y flujo de datos

El sistema de tiempo real se basa en una arquitectura de comunicación que coordina la sincronización entre el *hardware* de adquisición y el código de inferencia. Este flujo se divide en tres niveles: el control de *hardware* en el microcontrolador, la transmisión de datos al entorno de procesamiento, y el procesamiento de inferencia y visualización.

En el sistema de adquisición, el microcontrolador ESP32 actúa como el nodo central del bus SPI, configurando a una frecuencia de reloj de 3 MHz. Esta alta velocidad es necesaria para minimizar el tiempo de transferencia. Para cada una de las mediciones del protocolo Sheffield, el firmware realiza una captura de 64 muestras consecutivas. Estas muestras se almacenan temporalmente en un arreglo de tipo *word*.

La lógica de control gestiona los selectores de los multiplexores (pines 23, 22, 21 para inyección positiva y 27, 33, 32 para negativa, entre otros). Se asegura un tiempo de establecimiento para que la señal analógica se estabilice antes de cada ráfaga de conversión, garantizando que el vector de 208 voltajes sea representativo del estado de conductividad del medio.

Para el protocolo de serialización y empaquetamiento de datos, la transmisión de datos hacia el entorno de procesamiento se realiza mediante un puerto serie. Dado que el ADC entrega valores de 12 bits, cada medición se empaqueta en 2 bytes para preservar la precisión. Un cuadro completo de datos consisten en un flujo de 26.624 bytes (208 mediciones x 2 bytes x 64 *samples*). Y para evitar que se descalen los frames, el sistema utiliza una lógica de inicio de cuadro que asegura que el script de Python comience la lectura en el primer patrón de inyección. La eficiencia del envío serial es vital para mantener la tasa de cuadros por segundo requerida en nuestro caso.

En el entorno de procesamiento e inferencia, el script de Python implementa un bucle continuo encargado de reconstruir la información original. El flujo de bytes recibidos mediante operaciones de desplazamiento de bits para reconstruir el valor decimal de cada medición es:

$$V_{final} = (\text{byte}_{high} \ll 8) | \text{byte}_{low} \quad (20)$$

Este proceso se repite hasta completar el vector de entrada de 208 elementos.

## 4.7.2 Pre-procesamiento dinámico y reconstrucción de imagen

Una vez se obtiene el vector con las 208 mediciones de voltaje, este vector es sometido a un *pipeline* de procesamiento diseñado para estabilizar la entrada y ejecutar la reconstrucción mediante los modelos anteriormente construidos.

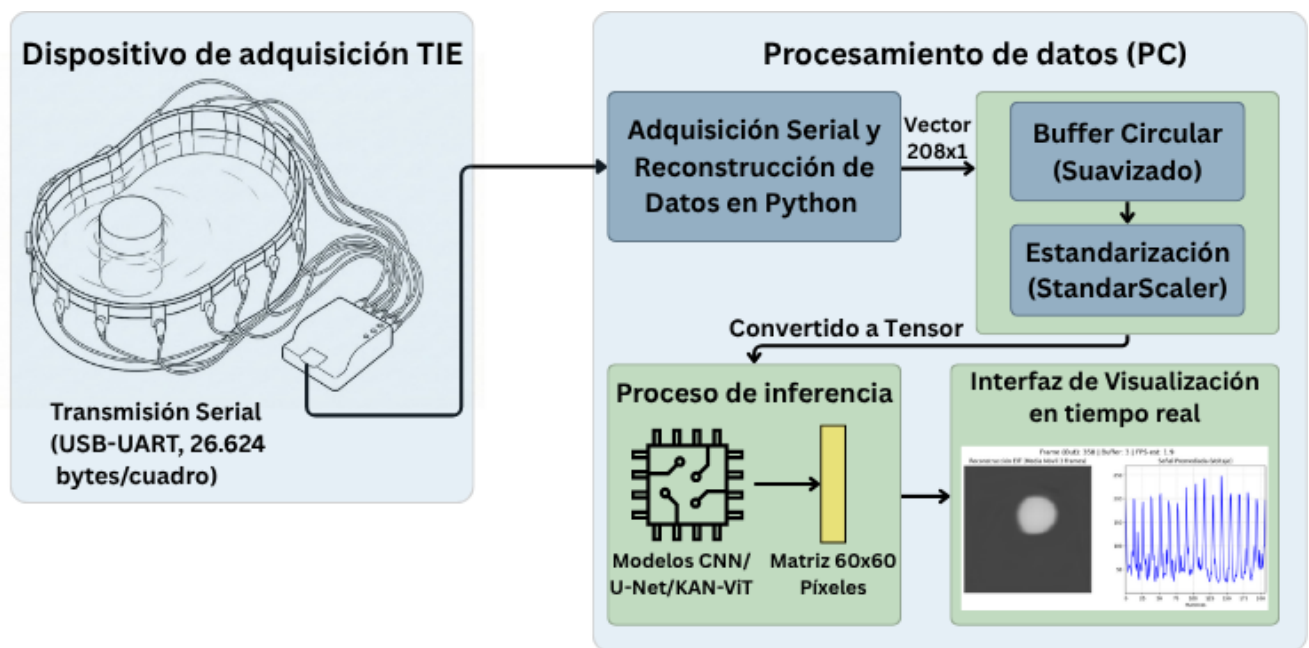
Dada la naturaleza ruidosa del entorno experimental, el vector de entrada se procesa mediante una técnica de suavizado temporal. Se implementó un *buffer* circular de tamaño dinámico que almacena los

cuadros de señales más recientes. Antes de la inferencia, se calcula la media punto a punto de este *buffer*, actuando como un filtro de media móvil que elimina ruidos de alta frecuencia sin introducir una latencia significativa en la visualización. Hay que tener en consideración que a medida que es más grande esta ventana, mayor es la estabilidad de la señal, pero se pierde la aplicación dinámica del sistema. Por lo que luego de probar distintos tamaños de ventanas, se optó por una de 3 *frames*.

El vector suavizado se normaliza utilizando el *StandardScaler* previamente creado con los datos reales. Al aplicar esta transformación, se asegura que la señal del experimento se encuentre en el mismo espacio de características que los datos con los que se entrenó en *fine-tuning*. Posteriormente, el vector se convierte en un tensor de PyTorch y se introduce en el modelo de red neuronal seleccionado.

Después de elegida la red neuronal, entre CNN, U-Net y KAN-ViT, la arquitectura procesa el tensor normalizado, generando una matriz de conductividad de  $60 \times 60$  píxeles, la cual se despliega dinámicamente mediante una rutina de actualización visual. Además, el sistema calcula continuamente la tasa de cuadros por segundo midiendo el tiempo transcurrido entre la recepción del primer byte y la actualización del gráfico. Para evitar cuellos de botella, la visualización se desacopla del proceso de lectura serie, permitiendo que el sistema procese un cuadro mientras recibe los datos del siguiente.

En la Figura 4.12 se puede observar el *pipeline* completo del sistema completo desde la adquisición de las señales, hasta la reconstrucción y visualización en tiempo real de los mapas de conductividad y su señal.



**Fig. 4.12:** Arquitectura del sistema de inferencia integrada. El proceso describe desde la adquisición síncrona en dispositivo TIE hasta el filtro de mediana con el buffer circular y la visualización final del mapa de conductividad.

## Capítulo 5 Resultados

---

### 5.1 Introducción

En este capítulo se presentan y analizan los resultados obtenidos tras el entrenamiento, validación y despliegue de las tres arquitecturas de *deep learning* propuestas para la reconstrucción de imágenes de TIE: CNN, U-Net y KAN-ViT. La evaluación se divide en dos fases críticas para validar la robustez del sistema: primero, una evaluación en el dominio sintético utilizando el dataset generado mediante COMSOL Multiphysics, lo que permite establecer el techo de rendimiento teórico de los modelos en condiciones ideales.


Posteriormente, se detallan los resultados de la transferencia de aprendizaje (*fine-tuning*) hacia el dominio real, empleando los datos recolectados experimentalmente mediante el fantoma torácico y el sistema de adquisición TIE. Para cuantificar la calidad de las reconstrucciones, se utilizan métricas estandarizadas de procesamiento de imágenes, tales como el Índice de Similitud Estructural (SSIM), el Coeficiente de Correlación (CC), el Error Cuadrático Medio (MSE) y el Error de Imagen Relativo (RIE). Finalmente, se analiza el desempeño del sistema en tiempo real, evaluando la tasa de cuadros por segundo y la capacidad de generalización ante inclusiones no vistas durante el entrenamiento.

### 5.2 Fantoma físico y modelado en COMSOL


La Figura 5.1 muestra el fantoma físico utilizado para la recolección de datos experimentales. El tanque con forma pulmonar fue manufacturado mediante impresión 3D utilizando la impresora Creality K1 Max con PLA, donde la impresión tuvo una duración total de 19 horas. En este fantoma además se integran los 16 electrodos de cobre confeccionados que conforman la interfaz de las mediciones. Este diseño asegura una disposición consistente con el modelo computacional.

En contraparte, en la Figura 5.2 se observa el comportamiento del modelo de elementos finitos en COMSOL para el primer patrón de inyección adyacente. Las líneas de corriente y la distribución de color del potencial eléctrica confirman que las condiciones de borde y la física del problema inverso fueron modeladas correctamente, sirviendo como base para la generación del dataset simulado.

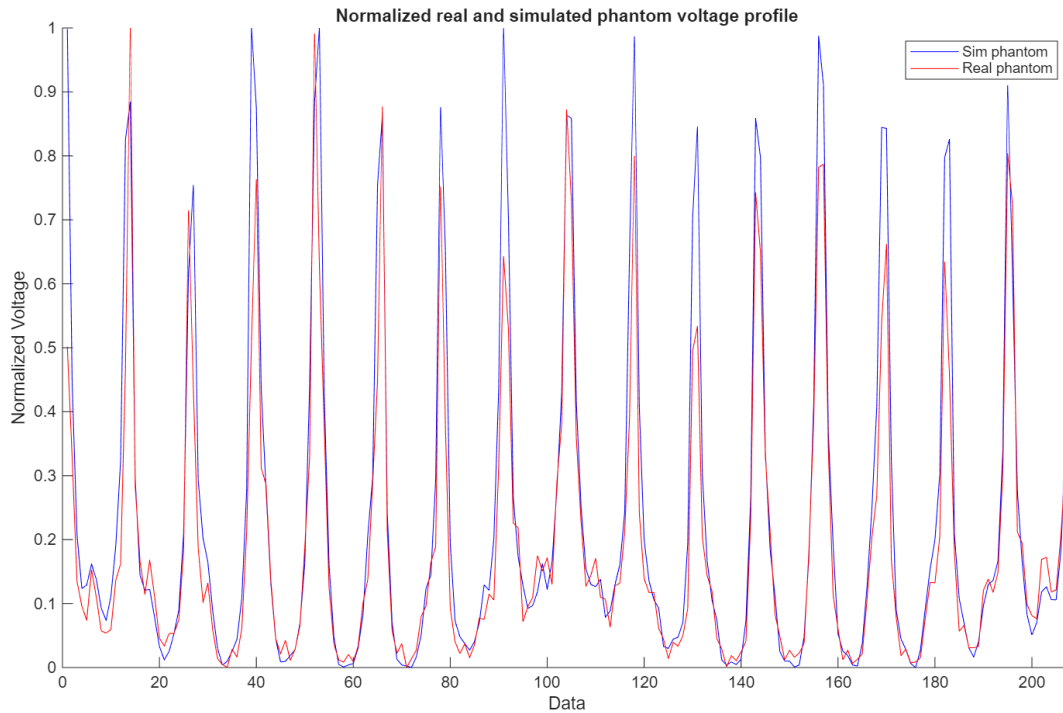
Para garantizar que los datos simulados utilizados para el entrenamiento de redes neuronales sean



**Fig. 5.1:** Fotografía del fantoma físico impreso en 3D con los 16 electrodos de cobre conectados al sistema de adquisición.



**Fig. 5.2:** Simulación en COMSOL mostrando la distribución del potencial eléctrico y las líneas de densidad de corriente para el primer par de inyección adyacente.




**Fig. 5.3:** Comparación directa entre el vector de 208 voltajes simulado en COMSOL (azul) y el promedio de 60 frames experimentales (naranja) normalizados, mostrando una alta correspondencia visual.

representativos de la realidad física, se realizó un análisis comparativo entre las señales de voltaje. Se seleccionó como estado de referencia al tanque homogéneo y se extrajo un *frame* del gemelo digital en COMSOL.

Para la contraparte física, se realizó una adquisición continua de aproximadamente 30 segundos con el dispositivo TIE, capturando alrededor de 60 cuadros. Estos cuadros fueron promediados temporalmente para mitigar el ruido de alta frecuencia y obtener una señal representativa estable de la respuesta del *hardware*.

La Figura 5.3 presenta la superposición de los 208 puntos de medición normalizados del modelo COMSOL frente al promedio experimental. Se observa visualmente una alta coherencia en los *peaks* de la señal, donde el modelo simulado captura con precisión la tendencia de los voltajes medidos por el dispositivo real.

Para cuantificar esta similitud, se calculó el coeficiente de correlación de Pearson entre ambos vectores, obteniendo un valor de  $r = 0.96$ . Este resultado indica una correlación lineal muy fuerte, validando la precisión del gemelo digital. Adicionalmente, se realizó un análisis de regresión lineal en escala logarítmica, visible en la Figura 5.4, para evaluar la correspondencia en distintos órdenes de magnitud.




**Fig. 5.4:** Regresión lineal en escala logarítmica entre los datos simulados y experimentales, evidenciando una fuerte correlación ( $r = 0.96$ ) y una baja dispersión respecto a la identidad.

El agrupamiento estrecho de los datos en torno a la recta de identidad confirma que la simulación es un predictor robusto del comportamiento físico, justificando su uso para el entrenamiento de las redes neuronales.

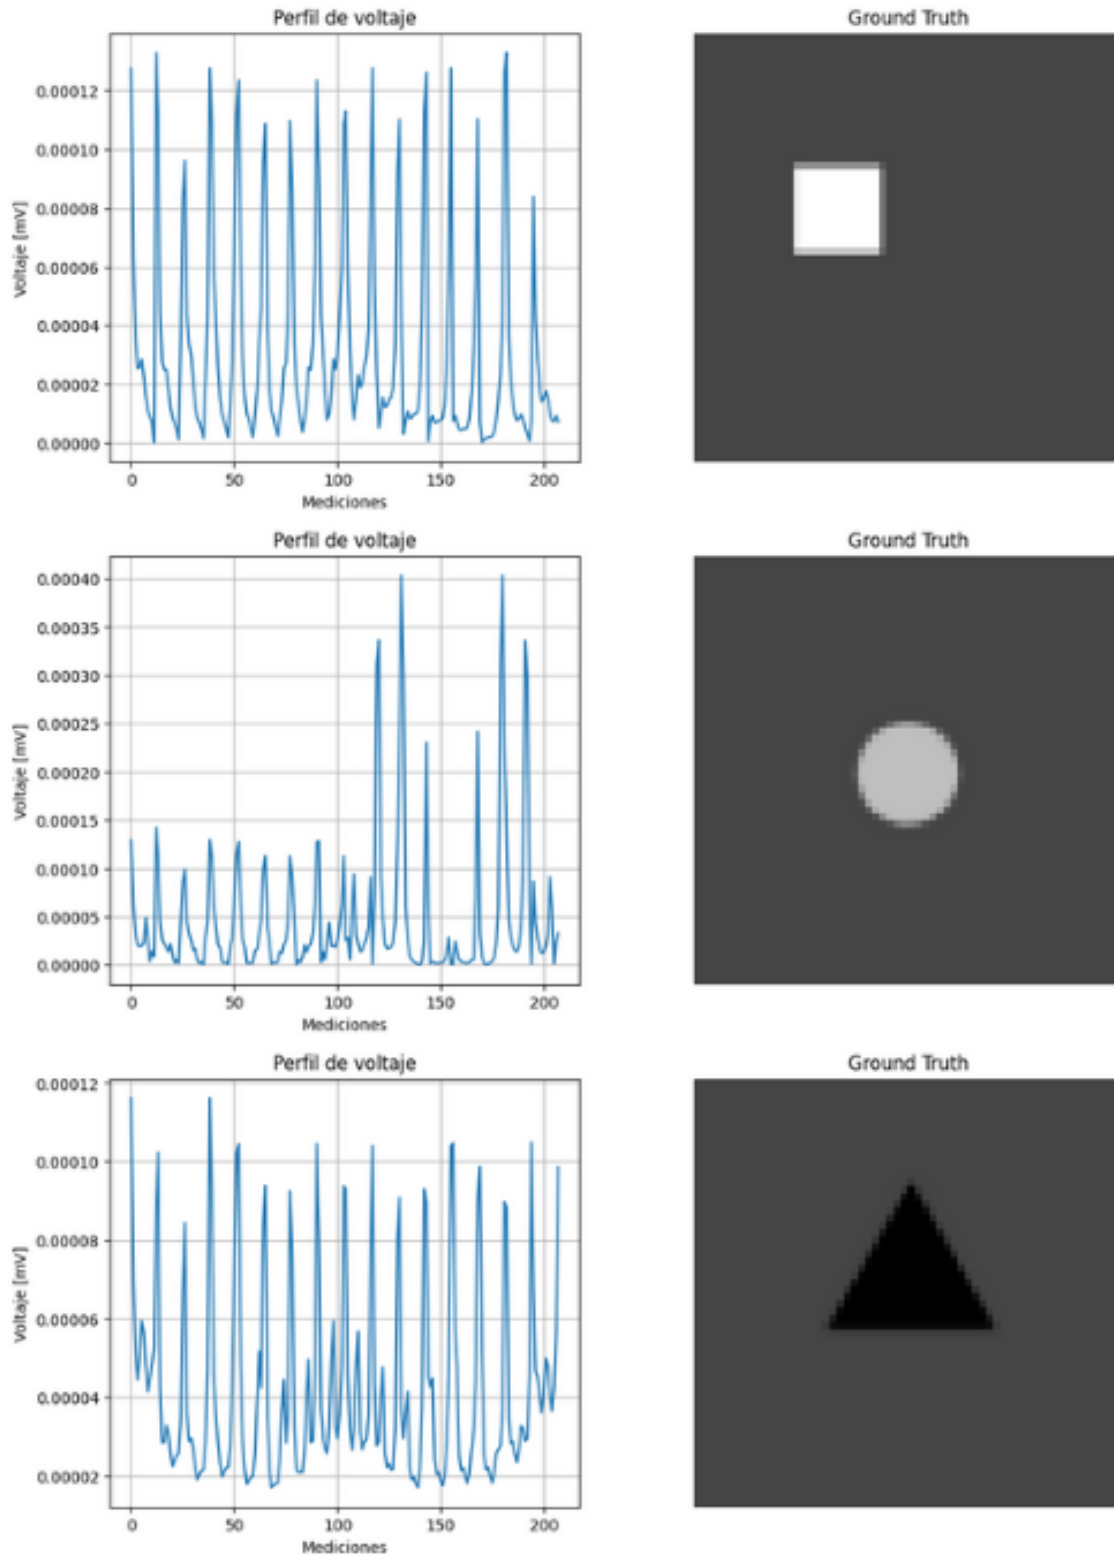
### 5.3 Generación del dataset simulado

Se generó un total de 7.992 muestras, donde cada muestra consiste en un vector de voltaje de  $208 \times 1$  y su correspondiente mapa de conductividad de  $512 \times 512$  píxeles, que fue redimensionado a  $60 \times 60$  píxeles. Como parte del pre-procesamiento de las etiquetas, se eliminó la información del fondo y de los bordes del fantoma, manteniendo únicamente el área de interés donde ocurren las variaciones de conductividad. Esta simplificación permite que la red neuronal concentre sus recursos computacionales en la forma y posición de las inclusiones, como se observa en la Figura 5.5.




**Fig. 5.5:** Comparativa entre la imagen original de la simulación de 512x512 píxeles y la versión procesada sin fondo de 60x60 píxeles, utilizada para simplificar el aprendizaje de las redes neuronales.

El proceso de simulación automatizado tomó 531,602 segundos (147.67 horas o 6.15 días) horas de ejecución continua, considerando los tiempos de convergencia del *solver* de elementos finitos, los ciclos con distintos parámetros y la exportación de resultados. Debido a la naturaleza de la colocación de objetos en la simulación, las inclusiones triangulares presentaron una mayor tasa de error por colisiones con los bordes del fantoma, resultando en una distribución ligeramente desbalanceada antes del procesamiento. Por lo que terminado el proceso automático de simulación de datos se obtuvieron 3,288 círculos, 3,288 cuadrados y 1,416 muestras de triángulos. Algunos ejemplos pueden verse en la Figura 5.6.



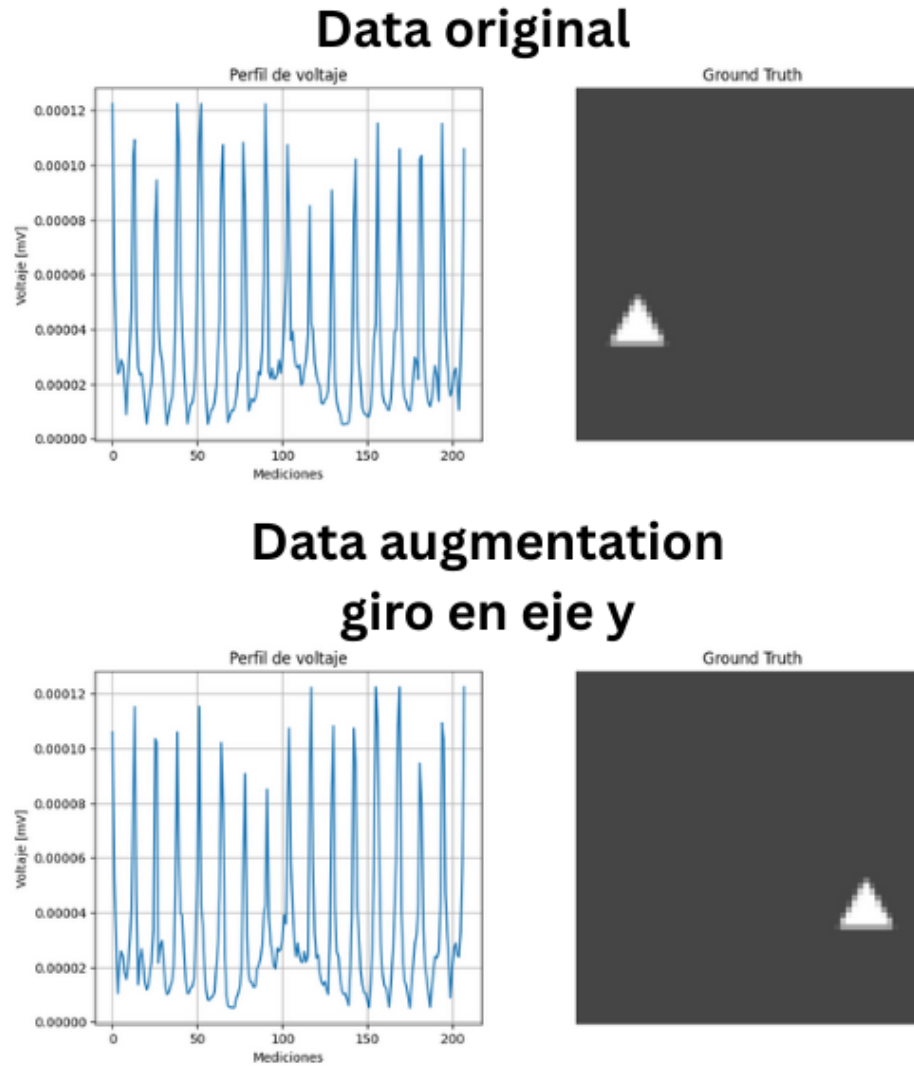
**Fig. 5.6:** Ejemplos de inclusiones generadas con distintos tamaños, posiciones y geometrías (círculo, cuadrado y triángulo) dentro del dominio del fantoma.

Un aspecto crítico en la representación visual del *ground truth* es la escala de colores: aunque se definió el negro (0) para la menor conductividad y el blanco (1) para la mayor, se implementó una escala logarítmica para el mapeo de los valores. Dado que las conductividades simuladas variaron en órdenes de magnitud ( $10^{-3}$ ,  $10^{-2}$ ,  $10^1$ ,  $10^3$ ,  $10^6$  y  $10^9$  S/m), una representación lineal hubiese hecho que no se notara la diferencia entre algunas conductividades, impidiendo la visualización de los contrastes entre los materiales. La Figura 5.7 muestra cómo estas seis magnitudes son mapeadas visualmente bajo el criterio logarítmico.



**Fig. 5.7:** Representación de las seis conductividades simuladas utilizando una escala logarítmica para preservar el contraste visual entre órdenes de magnitud extremos.

Para el proceso de entrenamiento, el dataset original se dividió en una proporción de 60 % para entrenamiento, 20 % para validación y 20 % para test. Teniendo en cuenta el desbalance de clases de triángulos con círculo y cuadrado, esta división se hace de manera estratificada. Con el fin de corregir el desbalance de la clase triangular y robustecer el aprendizaje, se aplicó *data augmentation* mediante la inversión en el eje Y (*flip*) exclusivamente a los triángulos dentro del conjunto de entrenamiento. Se puede ver un ejemplo de este aumento de datos en la Figura 5.8. Tras esta operación, los la cantidad de datos queda distribuida como se ve en la Tabla 5.1.



**Fig. 5.8:** Ejemplo de aumento de datos aplicado a una inclusión triangular, invirtiendo tanto la imagen de conductividad como el vector de voltajes asociado.

Figura	Entrenamiento	Validación	Test
Cuadrado	1.968	660	660
Círculo	1.970	659	659
Triángulo	1.700	283	283
Total	5.638	1.97	1.602

**Tabla 5.1:** Distribución final de las muestras por clase en los conjuntos de entrenamiento, validación y prueba, incluyendo el aumento de datos aplicado a la clase triangular.

Esta distribución final garantiza que el modelo sea evaluado con datos no observados ni transformados, mientras que el aumento selectivo en el entrenamiento permite que las arquitecturas aprendan a identificar las tres geometrías con la misma precisión, compensando la asimetría inicial de la simulación.

## 5.4 Evaluación de las arquitecturas con datos simulados

Tras la generación y partición del dataset simulado, se procedió al entrenamiento y optimización de las tres arquitecturas propuestas: CNN, U-Net, KAN-ViT. Con el fin de garantizar que cada modelo operara en su punto óptimo de rendimiento, realizó una búsqueda bayesiana de hiperparámetros mediante la librería Optuna, ejecutando 50 trials en cada arquitectura.

Como paso previo indispensable para asegurar la estabilidad del entrenamiento, todos los vectores de voltaje ( $208 \times 1$ ) fueron procesados mediante una estandarización estadística (Z-score). Esta normalización centró los datos en media cero y varianza unitaria, permitiendo que las funciones de activación operaran en sus regiones de mayor sensibilidad y evitando la saturación de los gradientes.

El proceso de optimización permitió identificar las configuraciones que minimizan el error de reconstrucción. El entrenamiento fue llevado a cabo en una GPU NVIDIA RTX 4090, implementado un criterio de *Early Stopping* con una paciencia de 8 épocas en cada arquitectura para así prevenir el sobreajuste.


### Convolutional Neural Network (CNN)

La CNN fue diseñada para extraer características espaciales locales de los vectores de voltaje. Se utilizó la función de pérdida MSE Loss para penalizar las diferencias píxel a píxel respecto al *ground truth*.

Se determinó un *learning rate* de  $7.33 \times 10^{-4}$  y un *batch size* de 16. La arquitectura incluyó filtros convolucionales con profundidad de 64. El entrenamiento convergió en la época 46, con un tiempo total de entrenamiento de 23 minutos y 38 segundos. Los resultados obtenidos por esa red neuronal pueden verse en Tabla 5.2 y en la Figura 5.9 se puede apreciar un gráfica de la función de pérdida para ver como esta red convolucional aprende.

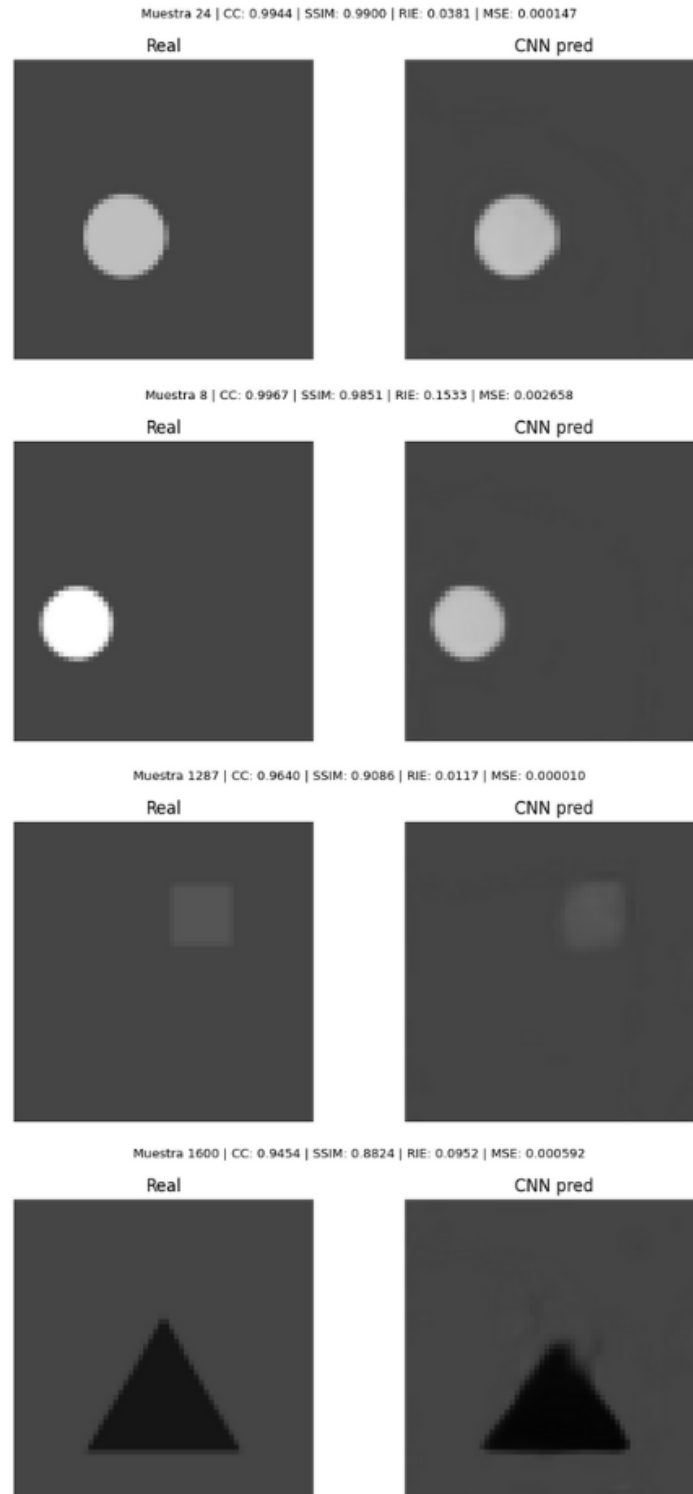
Métricas	CNN
MSE	$0.001039 \pm 0.001804$
RIE	$0.0792 \pm 0.0663$
SSIM	$0.9681 \pm 0.0263$
CC	$0.9602 \pm 0.0800$

**Tabla 5.2:** Resultados de métricas calculadas para CNN utilizando datos simulados en COMSOL.



**Fig. 5.9:** Curvas de aprendizaje del modelo CNN. El panel izquierdo muestra la evolución de la función de pérdida (MSE).

Finalmente, en la Figura 5.10 se puede ver alguna de las reconstrucciones del conjunto de test que hace esta red neuronal convolucional.



**Fig. 5.10:** Resultados de la reconstrucción de imágenes de conductividad utilizando la red CNN en el conjunto de test. Cada panel muestra la comparación entre el *Ground Truth* simulado y la salida del modelo, incluyendo las métricas de SSIM, CC y MSE obtenidas para cada caso particular.


## U-Net

La U-Net aprovecha las conexiones residuales (*skip connections*) para preservar la información de alta resolución durante la reconstrucción, utilizando también MSE Loss como función de pérdida.

Se determinó un *learning rate* de  $9.00 \times 10^{-4}$  y un *batch size* de 32. La arquitectura incluyó filtros convolucionales con profundidad de 64. El entrenamiento convergió en la época 33, con un tiempo total de entrenamiento de 39 minutos y 2 segundos. Los resultados obtenidos por esa red neuronal pueden verse en Tabla 5.3 y en la Figura 5.11 se puede apreciar una gráfica de su función de pérdida.


Métricas	U-Net
MSE	$0.001306 \pm 0.002191$
RIE	$0.0923 \pm 0.0677$
SSIM	$0.9551 \pm 0.0378$
CC	$0.9269 \pm 0.1350$

**Tabla 5.3:** Resultados de métricas calculadas para U-Net utilizando datos simulados en COMSOL.



**Fig. 5.11:** Curvas de aprendizaje del modelo U-Net. El panel izquierdo muestra la evolución de la función de pérdida (MSE).

En la siguiente Figura 5.12 se aprecian unos ejemplos de reconstrucción realizados por a red U-Net en el conjunto de test. Esta muestra diversos ejemplos, con mediciones de distintos objetos.



**Fig. 5.12:** Resultados de la reconstrucción de imágenes de conductividad utilizando la red U-Net en el conjunto de test. Cada panel muestra la comparación entre el *Ground Truth* simulado y la salida del modelo, incluyendo las métricas de SSIM, CC y MSE obtenidas para cada caso particular.


## KAN-ViT

La configuración final del modelo KAN-ViT, obtenida tras la optimización bayesiana, refleja una arquitectura diseñada para capturar relaciones espaciales complejas mediante la integración de redes de Kolmogorov-Arnold dentro de una estructura de Transformer. La red utiliza una etapa convolucional inicial para extraer patrones locales de los 208 voltajes de entrada, proyectándolos a un espacio latente de 169 dimensiones. El núcleo del modelo consiste en 4 bloques de profundidad con 13 cabezales de atención cada uno, donde las capas tradicionales de MLP han sido reemplazadas por capas KAN con un factor de expansión de 3.62. Estas capas KAN emplean una grilla de 8 intervalos para sus funciones B-spline, permitiendo una adaptación altamente no lineal de las señales. Finalmente, el proceso de aprendizaje se rige por una función de pérdida híbrida con un peso de 0.37 para la correlación de Pearson ( $\alpha_{pearson}$ ) y una regularización de Variación Total ( $tv\_weight$ ) de  $2.5 \times 10^{-6}$ , lo que garantiza que la reconstrucción final de  $60 \times 60$  píxeles (3600 clases) mantenga tanto la fidelidad estructural como la suavidad visual necesaria para mitigar artefactos de ruido. Finalmente, se utilizó un *learning rate* de  $1.18 \times 10^{-3}$  junto a un *batch size* de 32.

Con estos hiperparámetros se logró obtener los resultados mostrados en la Tabla 5.4. Además, en la Figura 5.13 se observan las curvas de aprendizaje de esta red neuronal. Como se observa, este proceso tomó 156 épocas, proceso el cual se llevó a cabo en 1 hora con 23 minutos y 13 segundos.

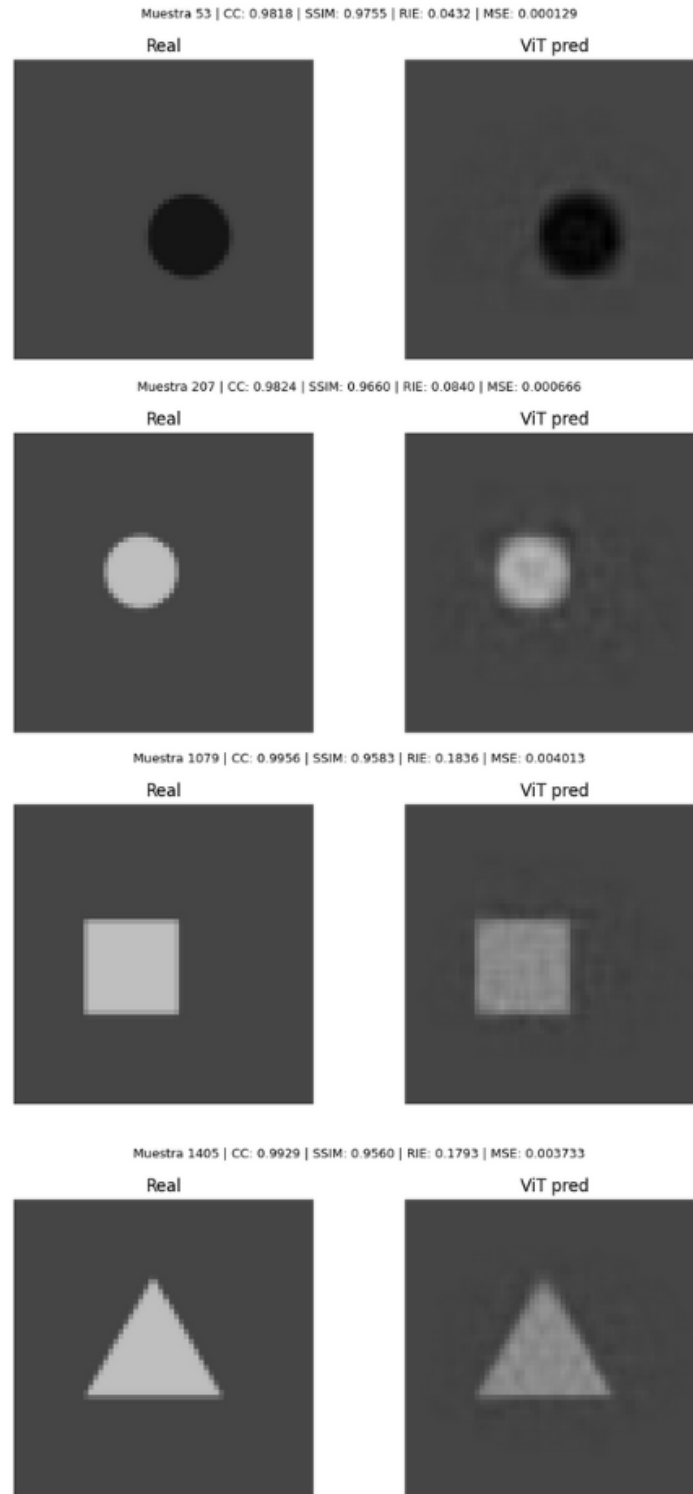
Métricas	KAN-ViT
MSE	$0.002102 \pm 0.003839$
RIE	$0.1167 \pm 0.0818$
SSIM	$0.9716 \pm 0.0266$
CC	$0.9654 \pm 0.0622$

**Tabla 5.4:** Resultados de métricas calculadas para KAN-ViT utilizando datos simulados en COMSOL.



**Fig. 5.13:** Curvas de aprendizaje del modelo KAN-ViT. El panel izquierdo muestra la evolución de la función de pérdida (MSE).

En la siguiente Figura 5.14 se aprecian unos ejemplos de reconstrucción realizados por la red KAN-ViT en el conjunto de test. Esta muestra diversos ejemplos, con mediciones de distintos objetos.



**Fig. 5.14:** Resultados de la reconstrucción de imágenes de conductividad utilizando la red KAN-ViT en el conjunto de test. Cada panel muestra la comparación entre el *Ground Truth* simulado y la salida del modelo, incluyendo las métricas de SSIM, CC y MSE obtenidas para cada caso particular.

## Comparación

Con el fin de establecer un punto de referencia robusto para evaluar el desempeño de las arquitecturas propuestas, se compararon sus reconstrucciones frente a dos algoritmos clásicos de reconstrucción en TIE. Se implementó el método iterativo Gauss-Newton (GN), y la regularización de Tikhonov (TR).

La Figura 5.15 presenta un cuadro comparativo donde se contrasta el *Ground Truth* simulado con las reconstrucciones obtenidas por estos métodos tradicionales y las tres redes neuronales.

Por otra parte, para validar y comparar cualitativamente las tres distintas red, la Tabla 5.5 resume el desempeño promedio de estas sobre el conjunto de test.

### 5.5 Toma de muestras y resultados del fine-tuning


Esta sección documenta la transición del modelo desde el dominio simulado al *hardware* real, detallando el proceso de adquisición de datos y el rendimiento de las arquitecturas tras el *fine-tuning*.

#### Adquisición y digitalización de datos reales

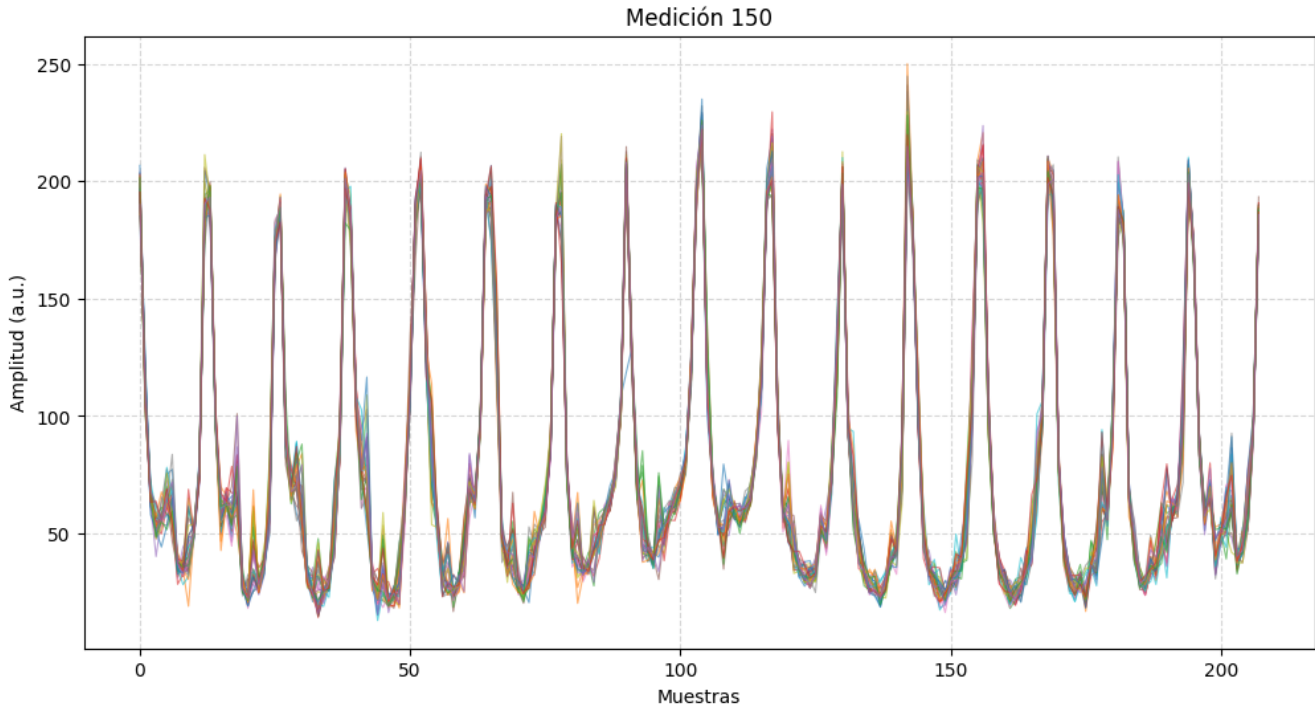
La adquisición de datos reales permitió capturar la diferencia existente entre lo simulado y la realidad. Como resultado de este proceso, se obtuvo un dataset compuesto por señales con una variabilidad temporal marcada. La Figura 5.16 muestra una medición representativa de una toma, donde se superpones 35 cuadros de señal para una misma posición del objeto. Se observa que, a pesar de el patrón de voltaje ser consistente con la medición física, existe ruido intrínseco que justifica el tratamiento de cada cuadro como una muestra independiente para generar un aprendizaje más robusto en nuestras arquitecturas.

Métricas	CNN	U-Net	KAN-ViT
MSE	$0.001039 \pm 0.001804$	$0.001306 \pm 0.002191$	$0.002102 \pm 0.003839$
RIE	$0.0792 \pm 0.0663$	$0.0923 \pm 0.0677$	$0.1167 \pm 0.0818$
SSIM	$0.9681 \pm 0.0263$	$0.9551 \pm 0.0378$	$0.9716 \pm 0.0266$
CC	$0.9602 \pm 0.0800$	$0.9269 \pm 0.1350$	$0.9654 \pm 0.0622$

**Tabla 5.5:** Resumen de métricas de desempeño promedio (SSIM, CC, MSE, RIE) obtenidas por los modelos CNN, U-Net y KAN-ViT con datos simulados en COMSOL.



**Fig. 5.15:** Las columnas muestran el *Ground Truth*, las soluciones clásicas (Gauss-Newton y Regularización de Tikhonov), y las predicciones de las redes neuronales (CNN, U-Net y KAN-ViT), de tres casos distintos, cada uno con un objeto y conductividad distinta.




**Fig. 5.16:** Superposición de 35 señales de voltaje capturadas para una misma configuración de objeto. La dispersión evidencia el ruido del sistema de adquisición.

Para la generación de las etiquetas digitales (*ground truth*), se optó por un protocolo de procesamiento digital manual. Este proceso consistió en el encuadre y alineación de las fotografías utilizando herramientas de edición gráfica, tomando como referencia visual la disposición de los electrodos en las simulaciones de COMSOL. Este método aseguró que la posición y escala de los objetos reales coincidiera exactamente con la grilla de reconstrucción de  $60 \times 60$  píxeles. Como se ilustra en la Figura 5.17, las figuras fueron segmentadas manualmente siguiendo un criterio binario: los elementos aislantes (vidrio y PLA) se representaron con el color negro (conductividad mínima), mientras que el cilindro metálico se asignó al color blanco (conductividad máxima).

## Composición del dataset y rendimiento del Fine-tuning

Tras la toma de muestras, el dataset con datos del fantoma quedó conformado por un total de 7.115 archivos *.npz* que contienen la imagen digitalizada junto a su señal correspondiente, a partir de 150 configuraciones distintas. De estos datos, el detalle de cada uno puede verse en la Tabla 5.6.

Como se aprecia en tabla anterior, los clases se encuentran desbalanceadas por lo que es necesario



**Fig. 5.17:** Etapas de procesamiento para datos reales, de izquierda a derecha: fotografía original, ajuste geométrico manual por superposición de referencias y segmentación final con mapeo de conductividades, para los 4 objetos medidos.

Figuras	Cantidad
Círculo aislante	2.764
Círculo conductor	2.615
Cuadrado	884
Triángulo	852

**Tabla 5.6:** Detalle de cantidad de muestras obtenidas por cada objeto en el fantoma.

tener en cuenta esto al momento de la división de conjuntos de entrenamiento, validación y test. Para mitigar este problema, se sigue el siguiente protocolo para las tres arquitecturas, haciendo la división de datos de la siguiente forma:

En primer lugar, se reserva un 20 % del dataset como conjunto de test utilizando la técnica de *Stratified Group K-Fold*. Esta elección se realiza por dos razones: la estratificación asegura que todas las clases (círculo conductor, círculo aislante, triángulo y cuadrado) estén representadas proporcionalmente en el test, mientras que el agrupamiento por grupos garantiza que todos los *frames* pertenecientes a una misma medición de 60 segundos se mantengan en el mismo bloque, evitando el *data leakage*. Esto impide que el modelo sea evaluado en datos que ya conoce previamente.

Con el 80 % restante de los datos se implementó una validación cruzada de 5 conjuntos, utilizando nuevamente un esquema estratificado y por grupos. Para gestionar el severo desbalanceo entre las clases, se aplicó una estrategia de doble balanceo de pesos mediante un *WeightedRandomSampler* en el cargador de datos de entrenamiento.

Este balanceo calcula el peso final de cada muestra como el producto de dos factores:

- **Peso por Clase:** Inversamente proporcional a la frecuencia de la figura geométrica, lo que obliga a la red a prestar más atención a las muestras de cuadrados y triángulos.
- **Peso por Grupo:** Inversamente proporcional a la cantidad de frames generados en cada experimento individual, compensando así las variaciones de duración en la toma de muestras manual descrita anteriormente.

El entrenamiento para las tres arquitecturas compartió una base común de hiperparámetros de *fine-tuning*: Se cargan los pesos óptimos obtenidos en la etapa de entrenamiento con el dominio simulado, para luego utilizar el algoritmo Adam con una tasa de aprendizaje (*learning rate*) baja de  $5 \times 10^{-5}$

Métricas	CNN	U-Net	KAN-ViT
MSE	$0.003041 \pm 0.004772$	$0.001257 \pm 0.001697$	$0.007925 \pm 0.004097$
RIE	$0.1584 \pm 0.1067$	$0.1131 \pm 0.0555$	$0.2660 \pm 0.0817$
SSIM	$0.9267 \pm 0.0349$	$0.9453 \pm 0.0311$	$0.8662 \pm 0.0422$
CC	$0.7818 \pm 0.3614$	$0.8785 \pm 0.2293$	$0.5612 \pm 0.3354$

**Tabla 5.7:** Desempeño promedio de los modelos entrenados tras el proceso de *fine-tuning* sobre el conjunto de prueba real.

y un *batch size* de 32. Además durante cada época las señales fueron sometidas a un ruido gaussiano aditivo para mejorar la robustez ante las perturbaciones eléctricas. Finalmente se aplicó *early stopping* con una paciencia de 8 épocas sobre la pérdida de validación para detener el proceso antes de que ocurra *overfitting*.


Tras completar los 5 entrenamientos por *folds* para cada red, se evaluó el desempeño promedio sobre el conjunto de prueba. En la Tabla 5.7 se muestra un resumen de las métricas finales de las tres arquitecturas.

Para completar el análisis, en la Figura 5.18 se comparan visualmente distintas reconstrucciones con cuatro objetos experimentales. En esta se contrasta el *ground truth* digitalizado frente a los resultados obtenidos por los métodos clásicos de Gauss-Newton y regularización de Tikhonov, y las tres arquitecturas de redes neuronales tras el proceso de *fine-tuning* con datos reales del fantoma.

## Análisis estadístico de resultados

Para validar la superioridad de los modelos en cada métrica, se aplicó primero, una prueba global de Friedman (Omnibus) para detectar diferencias generales, seguida de pruebas de Wilcoxon con corrección de Bonferroni para comparaciones por pares, ajustando el umbral de significancia ( $\alpha$ ) a 0.0167.

Para el análisis de métricas de correlación y similitud estructural (CC y SSIM), el análisis estadístico confirma una jerarquía de rendimiento muy robusta. Para el CC, la prueba de Friedman (2003.13,  $p \approx 0$ ) indica diferencias altamente significativas. Las pruebas post-hoc revelan que U-Net supera a CNN con un efecto mediano ( $r = 0.41$ ) y a VKAN con un efecto grande ( $r = 0.57$ ). Mientras que para SSIM, se presentan los resultados más sólidos estadísticamente ( $Friedman = 2402.11$ ). Todas las comparaciones arrojaron un tamaño del efecto grande ( $r > 0.54$ ), consolidando a U-Net como el modelo con mejor preservación estructural, seguido por CNN y finalmente VKAN.



**Fig. 5.18:** Comparativa visual de reconstrucción para cuatro objetos experimentales (circulo conductor, circulo aislante, cuadrado y triangulo). Las filas muestran, de arriba hacia abajo: la imagen original, el *Ground Truth*, los métodos clásicos (Gauss-Newton y Tikhonov) y las predicciones de las redes neuronales (CNN, U-Net y KAN-ViT).

En las métricas de error (MSE y RIE), la tendencia estadística se mantiene, favoreciendo a U-Net según los criterios de detectados en los datos. Para RIE, RIE (Relative Image Error): Se encontró una diferencia global significativa ( $Friedman = 2022.70$ ). Estadísticamente, U-Net es superior a VKAN con una magnitud de efecto grande ( $r = 0.59$ ), mientras que la diferencia entre CNN y VKAN es de magnitud mediana ( $r = 0.46$ ). Por otra parte, para MSE, los resultados replican el comportamiento de RIE ( $Friedman = 2022.70$ ). La comparativa U-Net vs VKAN muestra la mayor disparidad estadística ( $r = 0.58$ ), confirmando que las diferencias de error entre modelos no son casuales sino sistemáticas.

El análisis estadístico mediante la prueba de Friedman confirmó diferencias altamente significativas ( $p < 0.001$ ) en todas las métricas evaluadas. Las pruebas post-hoc de Wilcoxon, aplicando la corrección de Bonferroni ( $\alpha = 0.0167$ ), ratificaron que todas las comparaciones entre pares de modelos son estadísticamente significativas. Además, las magnitudes de los tamaños del efecto ( $r$ ) se situaron mayoritariamente en rangos medianos y grandes, lo que demuestra la robustez y relevancia práctica de las diferencias encontradas.


## 5.6 Evaluación del sistema de tiempo real

La validación final del sistema consistió en la ejecución integrada de los modelos optimizados en un entorno de visualización dinámica, utilizando el fantoma físico y el dispositivo de adquisición TIE. Esta etapa permite corroborar la capacidad del sistema para responder a cambios en la distribución de conductividad con una latencia mínima.

El *hardware* de adquisición fue diseñado para operar a una tasa nominal de 2 cuadros por segundo. Durante las pruebas de estrés con la interfaz de inferencia activa, se registró una tasa de procesamiento promedio de 1.94 fps para las tres arquitecturas.

Si bien existe un leve retraso percibido en la actualización visual, este es despreciable para aplicaciones de monitoreo pulmonar, donde la frecuencia respiratoria humana estándar se sitúa muy por debajo de los 2 Hz. La estabilidad de la transmisión serie a 921,600 baudios permitió mantener esta cadencia de forma ininterrumpida durante sesiones de prueba prolongadas de más de 30 minutos.

La implementación de un *buffer* de ventana deslizante con un tamaño de 3 frames resultó fundamental para la calidad de la imagen en tiempo real. Experimentalmente, se observó que este suavizado temporal elimina los artefactos causados por ruidos transitorios en el sistema, proporcionando una transición suave cuando los objetos son desplazados dentro del fantoma y mejorando visualmente la calidad de las



**Fig. 5.19:** Interfaz de adquisición e inferencia en tiempo real. Reconstrucción utilizando U-Net.

imágenes. En la Figura 5.19 se muestra una captura de la interfaz durante una prueba dinámica.

Además, durante las pruebas dinámicas se captó la capacidad del sistema para reconstruir simultáneamente múltiples inclusiones dentro del fantoma, a pesar de que el entrenamiento con datos reales se realizó mayoritariamente con objetos individuales, esto debido al principio de superposición y la capacidad de generalización de las arquitecturas.

## Capítulo 6 Discusión y Conclusiones

---

### 6.1 Introducción

Este capítulo tiene como objetivo realizar un análisis crítico de los resultados obtenidos durante el desarrollo de la investigación, contrastando el desempeño de las arquitecturas de *deep learning* en los dominios simulado y experimental. A través de la discusión, se busca interpretar cómo las decisiones metodológicas, desde la creación del gemelo digital hasta la implementación del *fine-tuning*, permitieron superar las limitaciones intrínsecas del hardware portable. Finalmente, se presentan las conclusiones generales del trabajo, validando el cumplimiento de los objetivos y la hipótesis planteada, para cerrar con una propuesta de líneas de investigación futuras que permitan escalar este sistema hacia aplicaciones clínicas reales.

### 6.2 Discusión

#### Fantoma físico

La fabricación del fantoma torácico cumplió con los requisitos estructurales, logrando que no existiera derrames ni infiltraciones durante largos periodos de tiempo. No obstante, el análisis de los componentes de este y las señales obtenidas presentan inconvenientes. Aunque los electrodos de cobre fabricados a mano permitieron una adquisición fidedigna de los voltajes, estos son altamente corrosivos en medios salinos pudiendo producir alteraciones en las mediciones a lo largo del tiempo. Esto sugiere que para un futuro es recomendable el uso de materiales más duraderos en el tiempo, a la vez que altamente conductores.

La validación del modelo simulado frente al fantoma físico arrojó resultados altamente positivos. La obtención de un coeficiente de correlación de 0.96 entre ambos muestra que este sistema simulado en COMSOL emula correctamente la distribución de potencial en el dominio físico. Esta alta correlación se ve reforzada por el análisis de regresión lineal en escala logarítmica, donde la agrupación de los datos en torno a la línea de identidad valida la linealidad del sistema de adquisición y la precisión de la digitalización del fantoma.

A pesar de esta alta correlación, es necesario discutir la naturaleza de las discrepancias entre señales. El sistema no es inmune a las no-idealidades, destacando ruido electrónico proveniente tanto del *hardware* TIE como de las soldaduras manuales en los electrodos de cobre. En el contexto de la TIE, esto es importante debido a que estas variaciones mínimas de señal de voltaje pueden ser interpretadas por algoritmos como cambios significativos en la conductividad interna.

Por lo tanto, la capacidad de las redes neuronales para generar reconstrucciones coherentes a partir de señales reales ruidosas, destacan la robustez de las arquitecturas implementadas frente a métodos de reconstrucción clásicos.

## Generación de dataset simulado

La fase de simulación en COMSOL permitió construir un dataset de 7.992 configuraciones distintas, estableciendo una base sólida para el *deep learning*. No obstante, este proceso revela importantes compromisos entre la fidelidad física, costo computacional y la representatividad clínica.

Si bien el rendimiento de las arquitecturas propuestas suele escalar proporcionalmente a la cantidad de datos, el tiempo de generación de estos en COMSOL impuso una limitante. Con un tiempo de cómputo de aproximadamente un minuto por muestra, la expansión del dataset hacia una mayor diversidad de posiciones, tamaños, conductividades y formas se vio restringida.

Sin embargo, el volumen alcanzado fue suficiente para encontrar la convergencia de los modelos. Se destaca la alta tasa de colisiones de los objetos con los bordes del fantoma simulado para la figura triangular, introduciendo un desbalanceo de clases. La decisión de hacer *data augmentation* para esta clase en específico fue fundamental logrando que se equilibrara el dataset.

Un punto importante de discusión es la elección de las conductividades simuladas. Aunque los valores seleccionados abarcan un espectro más amplio que el reportado en tejidos torácicos humanos (inferiores a 1 S/m), esta decisión se justifica desde la perspectiva del *deep learning*.

Al entrenar modelos en un rango extendido, se fuerza a la red a identificar características con contrastes extremos. Si bien esto se aleja de la precisión fisiológica, otorga una mayor capacidad de detección de anomalías en el dominio real.

La elección de reducir el tamaño desde  $512 \times 512$  a  $60 \times 60$  representa una mejora frente a trabajos previos en la literatura. Mientras que en implementaciones recientes de arquitecturas de KAN-ViT

operan con resoluciones de  $40 \times 40$ , el incremento escogido permite una definición superior. Además, esta disminución de dimensionalidad permitió un entrenamiento eficiente en términos computacionales, facilitando la convergencia de los modelos.

## Evaluación de redes neuronales

La arquitectura de CNN demostró una eficiencia sobresaliente en el dominio simulado, consolidándose como el modelo con mayor precisión en términos de error absoluto. Con un MSE de 0.001039 y el RIE más bajo (0.0792), la CNN demostró una capacidad superior para minimizar la discrepancia píxel a píxel en condiciones ideales. Su alto coeficiente de correlación de 0.9602 y un SSIM de 0.9681 sugieren que, a pesar de su relativa sencillez estructural, la red logra capturar la linealidad de las perturbaciones sintéticas de manera exitosa. Estos resultados indican que, en condiciones ideales, los filtros convolucionales estándar son suficientes para mapear la relación entre las señales de voltaje y la distribución de conductividad interna.

Por su parte, la arquitectura U-Net presentó un desempeño sólido y equilibrado, aunque ligeramente inferior en términos numéricos comparado con la CNN. Al registrar un MSE de 0.001306 y un RIE de 0.0923, se observa un pequeño incremento en el error relativo, lo que se refleja en un SSIM de 0.9551 y un CC de 0.9269. A pesar de esta leve caída métrica, el análisis visual en simulación confirma que la U-Net es extremadamente eficaz preservando la estructura espacial de los objetos. Se discute que sus conexiones de salto cumplen una función crítica al mitigar la pérdida de información durante la etapa de compresión, permitiendo que la red reconstruya bordes definidos incluso si el error píxel a píxel es levemente superior. Este comportamiento sugiere que la U-Net prioriza la coherencia morfológica global sobre la precisión absoluta de la amplitud de conductividad.

El modelo KAN-ViT introdujo una aproximación distinta al problema mediante el uso de funciones de activación B-spline y mecanismos de atención. En el dominio simulado, esta red alcanzó el CC más alto con un 0.9654 y un SSIM de 0.9716, demostrando una sensibilidad excepcional a la estructura global de la imagen. Sin embargo, su RIE de 0.1167 resultó ser el más elevado de las tres arquitecturas, lo que indica que, si bien la red identifica correctamente la forma y ubicación de las figuras, presenta una mayor dificultad para calibrar la magnitud exacta de la conductividad en comparación con los modelos puramente convolucionales. La superioridad en la correlación lineal del KAN-ViT valida su capacidad para modelar la no-linealidad de la TIE, aunque su mayor error relativo sugiere que el Vision Transformer requiere un volumen de datos o épocas de entrenamiento superiores para igualar la eficiencia de las CNN en este entorno sintético.

En términos generales, el análisis comparativo en simulación permite concluir que las tres redes neuronales son herramientas potentes para la reconstrucción tomográfica, logrando todas un SSIM superior a 0.95. La consistencia entre el MSE y el RIE en todas las redes confirma que no existen sesgos significativos en la magnitud de las imágenes reconstruidas bajo condiciones ideales. Mientras que la CNN lidera en fidelidad píxel a píxel (bajo MSE y RIE), la U-Net y el KAN-ViT ofrecen ventajas estructurales y de modelado no lineal que resultan prometedoras. Este alto desempeño simulado justifica el uso de la grilla de  $60 \times 60$ , demostrando que la resolución elegida es suficiente para representar fielmente las geometrías de prueba y que cualquier degradación posterior en el dominio real será producto de la brecha de dominio entre simulación y fantoma, y no de una limitación de las arquitecturas propuestas.

Finalmente, el análisis de eficiencia computacional revela una distinción clara entre las arquitecturas evaluadas. Mientras que la CNN y la U-Net presentan un bajo costo computacional, lo que facilita un entrenamiento ágil y una convergencia eficiente con recursos limitados, el modelo KAN-ViT exige una inversión temporal y de cómputo significativamente mayor. Esta demanda superior durante el entrenamiento se atribuye a la optimización de las funciones B-spline y a la complejidad intrínseca de los mecanismos de atención global. No obstante, es fundamental destacar que esta disparidad se limita principalmente a la fase de aprendizaje; una vez entrenadas, las tres redes operan con latencias de inferencia de aproximadamente 15 ms. Esto garantiza que, a pesar de las diferencias en el costo de entrenamiento, ninguna de las arquitecturas compromete la capacidad de respuesta del sistema en tiempo real, permitiendo que la elección del modelo se base primordialmente en su robustez y fidelidad estructural.

## **Toma de muestras reales y composición del dataset**

La etapa de adquisición de datos reales resultó en la captura de 150 configuraciones experimentales en el fantoma, abarcando diversas inclusiones con distintos contrastes de conductividad y posiciones. Una decisión clave en este proceso fue el tratamiento de los aproximadamente 40 cuadros obtenidos por cada configuración como muestras independientes con una misma imagen, alcanzando un volumen total de 7.115 muestras. Se discute que esta estrategia no solo aumentó el tamaño del dataset, sino que permitió a las redes neuronales aprender de la variabilidad temporal y ruido intrínseco del *hardware* TIE. Al exponer a los modelos a estas fluctuaciones reales, se fomentó un aprendizaje robusto que capacita al sistema para discriminar la información de las figuras a las de perturbaciones eléctricas aleatorias.

El severo desbalance de clases observado, donde las muestras de cuadros y triángulos fueron significativamente menores, representó un desafío para la convergencia del modelo. Para evitar este sesgo, se implementó un esquema de doble balanceo de pesos mediante *WeightedRandomSampler*, lo que garanti-

zó que todas las geometrías tuvieran la misma relevancia durante el entrenamiento. Eso lleva a evitar que las redes presenten predisposiciones hacia figuras circulares. Asimismo, el uso de una validación cruzada por grupos aseguró que el proceso de evaluación fuera el correcto, manteniendo todos los cuadros de una misma medición dentro de un bloque único, evitando el *data leakage*.

Respecto a la generación de las etiquetas digitales, la digitalización manual de las fotografías fue un paso esencial para cerrar la brecha entre la observación física y la reconstrucción. Se discute que el uso de plantillas de referencia permitió corregir de manera efectiva los errores de proyección y perspectiva que poseía la toma fotográfica cenital. Este proceso de alineación geométrica aseguró que el *ground truth* fuera una representación fiel de la disposición de los electrodos en el fantoma.

Finalmente, la implementación del entrenamiento mediante *K-Fold* proporcionó una validación rigurosa de los resultados. Esta metodología permite afirmar que el rendimiento reportado para las arquitecturas no es producto de una partición de datos favorable, sino de un aprendizaje consistente a través de diferentes subconjuntos de datos reales. En conjunto, estas decisiones metodológicas, desde el manejo del ruido hasta el balanceo de clase, constituyen la base técnica que permitió el despliegue exitoso de los modelos de *deep learning* en un dispositivo portátil, superando las limitaciones de sensibilidad típicas de los sistemas de tomografía por impedancia eléctrica de bajo costo.

## Rendimiento del Fine-tuning

La transición de los modelos desde el entorno ideal de la simulación hacia la adquisición de datos en el fantoma físico constituye el núcleo de la validación de esta tesis. Al observar los resultados tras el proceso de *fine-tuning*, es evidente que la brecha de dominio impone una degradación en las métricas respecto a los resultados con datos simulados. Sin embargo, las arquitecturas de *deep learning* demuestran una mejora notable respecto a los métodos clásicos.

El análisis individual revela que la U-Net es la arquitectura más robusta para operar con el *hardware* TIE utilizado, alcanzando un SSIM de 0.9453 y un CC de 0.8785. Estos valores, sumados al MSE más bajo del grupo, de 0.001257, confirman que la capacidad de esta red para preservar la estructura espacial mediante sus conexiones de salto es sumamente importante ante señales ruidosas. En las imágenes reconstruidas, la U-Net destaca por definir bordes con más nitidez que las otras redes, reduciendo drásticamente los artefactos de fondo y manteniendo la fidelidad en la forma de cuadrados, círculos y triángulos.

Por otro lado, la CNN se consolida como una alternativa equilibrada y altamente fiable. Aunque sus

métricas son notablemente inferiores a la U-Net, con un SSIM de 0.9267 y un CC de 0.7818, su desempeño en datos reales es notablemente estable. Se discute que la simplicidad de la CNN actúa como un regularizador implícito; al poseer menos parámetros y una estructura menos compleja que los *transformers*, la red evita el sobreajuste al ruido de alta frecuencia presente en los 208 voltajes capturados por el dispositivo TIE. Visualmente, las reconstrucciones de la CNN presentan un ligero suavizado en los bordes de los objetos, pero mantienen una localización precisa del centro de masa de las figuras, lo que la posiciona como una arquitectura eficiente y rápida para aplicaciones donde la precisión absoluta de los bordes es no tan importante como la detección de la presencia del objeto.

En contraste, el modelo KAN-ViT presentó los desafíos más significativos durante la fase de adaptación al mundo real. A pesar de su excelente rendimiento en simulación, en el dominio real su CC cayó a 0.5612 y su RIE aumentó a 0.2660, siendo el error más alto. Este fenómeno sugiere que la flexibilidad de las funciones de activación B-spline y la atención global del *Vision Transformer* podrían estar induciendo una sensibilidad excesiva a las no-idealidades del *hardware*. Sin embargo, se espera que si se entrena con una mayor cantidad de datos, mejore sustancialmente su rendimiento. En la evaluación visual, el KAN-ViT tiende a generar imágenes más difusas y con una mayor presencia de ruido de reconstrucción en zonas de conductividad homogénea. Además, se aprecia que presenta más de una figura de forma difusa y solapada. Esto indica que, para el estado actual del *hardware* reportable TIE, las representaciones locales basadas en convoluciones (CNN y U-Net) ofrecen una mayor robustez que los mecanismos de atención global, los cuales parecen requerir señales de entrada con una relación señal-ruido más elevada para desplegar su máximo potencial.

Al realizar una comparativa general entre las tres redes y los métodos clásicos de reconstrucción, se observa que el *deep learning* redefine el límite de lo que es posible obtener con instrumentación de bajo costo. Mientras que los algoritmos tradicionales presentan dificultades para separar la inclusión del ruido del sistema, las redes neuronales operan como filtros inteligentes que han asimilado la física del problema inverso. La superioridad de la U-Net en todas las métricas la señala como la arquitectura ideal para el tiempo real. La capacidad de estas redes para generalizar y mantener altos índices de similitud estructural, valida la metodología de *transfer learning* y establece un precedente sólido para el desarrollo de sistemas de monitoreo pulmonar accesibles y de alta calidad.

## **Análisis estadístico**

Los resultados permiten concluir con un nivel de confianza superior al 98.3 % (post-ajuste de Bonferroni) que la elección de la arquitectura tiene un impacto determinante en la calidad de la reconstrucción

de imágenes de EIT. La consistencia de la prueba de Friedman con  $p < 0.001$  y los tamaños del efecto mayoritariamente grandes ( $r > 0.5$ ) demuestran que la superioridad de U-Net no es un fenómeno aislado de una métrica en particular, sino una mejora sistémica tanto en precisión estructural como en la reducción del error cuadrático. Este rigor estadístico valida que el modelo es capaz de generalizar y superar de manera robusta a las arquitecturas CNN convencional y VKAN en el contexto de este estudio.

En definitiva, la convergencia de p-valores extremadamente bajos y tamaños de efecto sustanciales permite rechazar de forma categórica la hipótesis nula de igualdad entre modelos. Se establece así una jerarquía de rendimiento liderada por U-Net, cuya ventaja competitiva está respaldada por una solidez estadística que garantiza la reproducibilidad de estos hallazgos en la tarea de reconstrucción de imágenes de EIT.

## Reconstrucción en tiempo real

La evaluación del sistema en un entorno completo, con una ejecución continua, procesamiento e inferencia conectado al fantoma a través del *hardware* permitió validar toda la integridad de este trabajo. El hallazgo más significativo en términos de rendimiento fue una tasa de procesamiento estable de 1.94 fps, cifra que se encuentre levemente por debajo de límite del *hardware* (2 fps). Este resultado permite discutir que la carga computacional de las redes neuronales, incluyendo el preprocesamiento y la inferencia, es aproximadamente 15 ms por cuadro. Esta latencia es prácticamente imperceptible para el usuario y demuestra que el verdadero cuello de botella no reside en la complejidad de las arquitecturas, sino en la tasa de muestreo y transmisión de los datos. Esto sugiere que el software es escalable y podría operar a frecuencias de muestreo más altas si se implementara un *hardware* con más ancho de banda.

En cuanto a la calidad visual de la reconstrucción dinámica, la implementación del *buffer* de ventana deslizante resultó ser una decisión fundamental. Se observa que este filtrado temporal actúa como un estabilizador ante el ruido presente, eliminando artefactos que degradarían la interpretación de las reconstrucciones. Si bien el uso de un *buffer* introduce un retardo de fase mínimo, se discute que este es aceptable, imperceptible e incluso necesario en este caso de estudio.

Finalmente, se evalúa la viabilidad del sistema para el monitoreo pulmonar real. Considerando que la frecuencia respiratoria en reposo es de aproximadamente 0.2 a 0.3 Hz, una tasa de 1.94 fps es teóricamente suficiente para capturar la dinámica de ventilación sin pérdida de información crítica según el teorema de Nyquist. No obstante, se discute que para detectar eventos fisiológicos rápidos o para su uso en pacientes pediátricos con frecuencias respiratorias elevadas, sería necesario optimizar la etapa de

adquisición.

### 6.3 Conclusiones

Tras el desarrollo, implementación y validación del sistema de reconstrucción propuesto en este trabajo, es posible afirmar que se valida la hipótesis de investigación, demostrando que es posible reconstruir imágenes en tiempo real utilizando algoritmos de *deep learning* a partir de las señales de un dispositivo portable de tomografía por impedancia eléctrica. La integración de redes neuronales permitió procesar los voltajes capturados por el *hardware* TIE portable y transformarlos en imágenes reconstruidas coherentes con una latencia de procesamiento mínima, confirmando la viabilidad del uso de inteligencia artificial como reconstructor de imágenes.

Se logró generar un sistema funcional capaz de visualizar la distribución de conductividad en un fantoma físico en tiempo real. Esto se aprecia en una tasa de procesamiento de 1.94 fps, asegurando una respuesta dinámica adecuada. Este logro representa un avance significativo, que demuestra que la complejidad computacional de modelos como U-Net o KAN-ViT no es un impedimento para su despliegue en entornos de ejecución continua e inmediata.

Se consolidó exitosamente una base de datos de entrenamiento, con 7.992 muestras simuladas adquiridas mediante COMSOL en el gemelo digital del fantoma torácico, que permitieron realizar un proceso de *transfer learning* efectivo. Esto demostró ser esencial para superar la brecha entre lo simulado ideal y las perturbaciones del mundo real.

El entrenamiento y *fine-tuning* de las tres arquitecturas evaluadas permitió identificar a la U-Net como la solución más robusta para el mundo real. Su capacidad para preservar la estructura espacial mediante conexiones de salto resultó superior a la CNN y al KAN-ViT al enfrentarse al ruido intrínseco del *hardware*, logrando un SSIM de 0.9453 en condiciones experimentales reales.

Incluso incluyendo filtrados temporales, que eliminan parte del ruido haciendo una reconstrucción de más precisión, la visualización en tiempo real no se ve afectada. La validación en términos de precisión y velocidad confirmó que el sistema posee la capacidad de reconstruir imágenes de fantoma torácico en tiempo real.

En conclusión, el éxito de este sistema representa un avance significativo entre el *hardware* TIE portable y de bajo costo, y la inteligencia artificial aplicada a la salud. Este trabajo demuestra que es posible obtener imágenes de alta calidad sin depender de equipamiento clínico de alto costo, validando

una metodología que une la precisión del modelado simulado con el aprendizaje del *deep learning* ante entornos ruidosos. En consecuencia, esta tesis no solo cierra una brecha técnica en la reconstrucción de señales TIE, sino que abre un nuevo el camino para el desarrollo de dispositivos accesibles que permitan un monitoreo respiratorio continuo, preventivo y precisos.

## 6.4 Trabajo a futuro

Como trabajo a futuro se proponen los siguientes conceptos:

- Se debe indagar en las otras dos formas pulmonares que posee EIDORS como modelo FEM, y cual sería la mejor generalización torácica.
- La fabricación de electrodos con otros materiales, evitando que sean corrosivos a la salinidad del medio.
- Encontrar una forma más segura de conectar el broche al electrodo, evitando una soldadura manual, cerciorando que todos queden idénticos.
- Rediseñar el modelo 3D impreso, para que posea encajes donde poner los electrodos. Con ello se lograría que los electrodos se ubiquen de manera equidistante de manera rigurosa.
- Aumentar el tamaño del dataset de datos sintéticos, abarcando más parámetro y nuevos, como podría ser figuras irregulares, rotaciones o posicionar más de una figura por medición.
- Crear un dataset simulado con conductividades similares a las fisiológicas humanas.
- Optimizar el código de adquisición automática de la base de datos sintética, para lograr mediciones en menos tiempo.
- Programar nuevas arquitecturas, que combinen el uso de U-Net con métodos más sofisticados como KAN-ViT o imágenes por difusión.
- Medir el desempeño de las arquitecturas a medida que se aumenta la calidad de las imágenes.
- Probar distintas cantidades de dataset con el fin de encontrar la cantidad mínima en el que la arquitectura converge.
- Adquirir una base de datos más grande de datos reales, con distintas figuras y conductividades conocidas.

- Tomar mediciones más largas, para así obtener más datos de la misma configuración con el fin de robustecer las arquitecturas.
- Automatizar la digitalización de las fotografías.
- Cambiar el protocolo de transmisión de datos, para poder enviar datos a una mayor velocidad ya sea vía Bluetooth o WiFi.
- Optimizar el proceso de preprocesamiento e inferencia, tratando de disminuir el pequeño retraso existente.
- Mejorar el *hardware* de adquisición, cambiando frecuencia de ADC para lograr una velocidad de adquisición más rápida.
- Implementar una aplicación móvil para la visualización de las reconstrucciones con redes neuronales utilizando el *hardware* TIE.

A modo de conclusión, esta tesis presenta con éxito los primeros resultados de reconstrucción mediante *deep learning* para el dispositivo TIE diseñado en laboratorio. Se ha validado la hipótesis de trabajo al implementar un sistema capaz de operar en tiempo real bajo un protocolo controlado. La naturaleza modular de esta investigación permite que el sistema sea modificable en cada una de sus etapas, lo que abre una amplia cantidad de posibilidades para futuras mejoras en la calidad de imagen y el rendimiento del *hardware*, consolidando una base sólida para la continuidad de esta línea de investigación

Destacar que el llevar a cabo esta investigación fue un proceso riguroso de aprendizaje, desde el uso del software COMSOL (en el que se tenía total desconocimiento), hasta la implementación de una arquitectura novedosa y no abarcada en dispositivos TIE portátiles en fantasmas (KAN-ViT). En un futuro, si el proyecto avanza trabajando en las ideas que se proponen para mejorar el sistema, este proyecto podría llegar a ser una contribución no solamente académica, sino un bien para la sociedad.

Se espera que este trabajo sea el comienzo de la prueba con bases de datos de sujetos reales, para lograr una reconstrucción con redes neuronales utilizando las técnicas de *fine-tuning* implementadas en esta tesis, para así reducir la brecha entre el entorno simulado y la realidad. Esto con la finalidad de en un futuro próximo poder reconstruir en tiempo real mediciones pulmonares en sujetos con algoritmos de *deep learning*.

## Capítulo 7 Referencias

---

- [1] F. Alvarado, “Sistema de tomografía por impedancia eléctrica como prueba de función pulmonar ambulatoria,” Tesis de Magíster en Ciencias de la Ingeniería con mención en Ingeniería Eléctrica, Universidad de Concepción, Concepción, Chile, 2024, departamento de Ingeniería Eléctrica. Facultad de Ingeniería.
- [2] F. Alvarado-Arriagada, B. Fernández-Arroyo, S. Rebolledo, and E. J. Pino, “Development and validation of a portable eit system for real-time respiratory monitoring,” *Sensors*, vol. 24, no. 20, 2024. [Online]. Available: <https://www.mdpi.com/1424-8220/24/20/6642>
- [3] F. Alvarado, B. Fernández, S. Rebolledo, and E. J. Pino, “Portable eit system validation with a fem model-based resistance phantom,” in *2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2024, pp. 1–4.
- [4] S. Mansouri, Y. Alharbi, F. Haddad, S. Chabcoub, A. Alshrouf, and A. A. Abdelghany, “Electrical impedance tomography – recent applications and developments,” *Journal of Electrical Bioimpedance*, vol. 12, no. 1, p. 50–62, Jan. 2021. [Online]. Available: <http://dx.doi.org/10.2478/joeb-2021-0007>
- [5] Ø. G. Martinsen and S. Grimnes, *Bioimpedance and Bioelectricity Basics*, 4th ed. London, UK: Academic Press, 2024.
- [6] A. F. Pacela, “Impedance pneumography—a survey of instrumentation techniques,” *Medical and Biological Engineering*, vol. 4, no. 1, p. 1–15, Jan. 1966. [Online]. Available: <http://dx.doi.org/10.1007/BF02474783>
- [7] A. Grenvik, S. Ballou, E. McGinley, J. E. Millen, W. L. Cooley, and P. Safar, “Impedance pneumography,” *Chest*, vol. 62, no. 4, p. 439–443, Oct. 1972. [Online]. Available: <http://dx.doi.org/10.1378/chest.62.4.439>
- [8] J. J. Freundlich and J. C. Erickson, “Electrical impedance pneumography for simple nonrestrictive continuous monitoring of respiratory rate, rhythm and tidal volume for surgical patients,” *Chest*, vol. 65, no. 2, p. 181–184, Feb. 1974. [Online]. Available: <http://dx.doi.org/10.1378/chest.65.2.181>
- [9] R. P. Henderson and J. G. Webster, “An impedance camera for spatially specific measurements of the thorax,” *IEEE Transactions on Biomedical Engineering*, vol. BME-25, no. 3, p. 250–254, May 1978. [Online]. Available: <http://dx.doi.org/10.1109/TBME.1978.326329>

- [10] B. H. Brown and A. D. Seagar, "The sheffield data collection system," *Clinical Physics and Physiological Measurement*, vol. 8, no. 4A, p. 91–97, Nov. 1987. [Online]. Available: <http://dx.doi.org/10.1088/0143-0815/8/4A/012>
- [11] Z. Cui, X. Liu, H. Qu, and H. Wang, "Technical principles and clinical applications of electrical impedance tomography in pulmonary monitoring," *Sensors*, vol. 24, no. 14, p. 4539, Jul. 2024. [Online]. Available: <http://dx.doi.org/10.3390/s24144539>
- [12] C. Putensen, B. Hentze, S. Muenster, and T. Muders, "Electrical impedance tomography for cardio-pulmonary monitoring," *Journal of Clinical Medicine*, vol. 8, no. 8, p. 1176, Aug. 2019. [Online]. Available: <http://dx.doi.org/10.3390/jcm8081176>
- [13] S. A. Dipa, M. M. Pramanik, M. Rabbani, and M. A. Kadir, "Effects of temperature on electrical impedance of biological tissues: ex-vivo measurements," *Journal of Electrical Bioimpedance*, vol. 15, no. 1, p. 116–124, Jan. 2024. [Online]. Available: <http://dx.doi.org/10.2478/joeb-2024-0013>
- [14] A. Adler and A. Boyle, "Electrical impedance tomography: Tissue properties to image measures," *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 11, pp. 2494–2504, 2017.
- [15] C. Gabriel, S. Gabriel, and E. Corthout, "The dielectric properties of biological tissues: I. literature survey," *Physics in Medicine and Biology*, vol. 41, no. 11, p. 2231–2249, Nov. 1996. [Online]. Available: <http://dx.doi.org/10.1088/0031-9155/41/11/001>
- [16] J. K. Seo, J. Lee, S. W. Kim, H. Zribi, and E. J. Woo, "Frequency-difference electrical impedance tomography (fdeit): algorithm development and feasibility study," *Physiological Measurement*, vol. 29, no. 8, p. 929–944, Jul. 2008. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/29/8/006>
- [17] L. Bogdanowicz, O. Fidaner, D. Ceres, A. Grycuk, M. Guidetti, and D. Demos, "The cole relaxation frequency as a parameter to identify cancer in lung tissue: Preliminary animal and ex vivo patient studies," *JMIR Biomedical Engineering*, vol. 7, no. 1, p. e35346, Feb. 2022. [Online]. Available: <http://dx.doi.org/10.2196/35346>
- [18] Y. Shi, Z. Yang, F. Xie, S. Ren, and S. Xu, "The research progress of electrical impedance tomography for lung monitoring," *Frontiers in Bioengineering and Biotechnology*, vol. 9, Oct. 2021. [Online]. Available: <http://dx.doi.org/10.3389/fbioe.2021.726652>

- [19] W. Li, J. Xia, G. Zhang, H. Ma, B. Liu, L. Yang, Y. Zhou, X. Dong, F. Fu, and X. Shi, "Fast high-precision electrical impedance tomography system for real-time perfusion imaging," *IEEE Access*, vol. 7, p. 61570–61580, 2019. [Online]. Available: <http://dx.doi.org/10.1109/ACCESS.2019.2902975>
- [20] Y. Xu, Z. Yan, B. Han, and F. Dong, "An fpga-based multifrequency eit system with reference signal measurement," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, p. 1–10, 2021. [Online]. Available: <http://dx.doi.org/10.1109/TIM.2020.3031158>
- [21] F. Pennati, A. Angelucci, L. Morelli, S. Bardini, E. Barzanti, F. Cavallini, A. Conelli, G. Di Federico, C. Paganelli, and A. Aliverti, "Electrical impedance tomography: From the traditional design to the novel frontier of wearables," *Sensors*, vol. 23, no. 3, p. 1182, Jan. 2023. [Online]. Available: <http://dx.doi.org/10.3390/s23031182>
- [22] International Electrotechnical Commission, "Iec 60601-1-11:2015 - medical electrical equipment - part 1-11: General requirements for basic safety and essential performance - collateral standard: Requirements for medical electrical equipment and medical electrical systems used in the home healthcare environment," <https://webstore.iec.ch/en/publication/59650>, 2015, accessed: 4 de enero de 2026.
- [23] Y. Wu, F. F. Hanzae, D. Jiang, R. H. Bayford, and A. Demosthenous, "Electrical impedance tomography for biomedical applications: Circuits and systems review," *IEEE Open Journal of Circuits and Systems*, vol. 2, p. 380–397, 2021. [Online]. Available: <http://dx.doi.org/10.1109/OJCAS.2021.3075302>
- [24] M. Takhti and K. Odame, "Structured design methodology to achieve a high snr electrical impedance tomography," *IEEE Transactions on Biomedical Circuits and Systems*, vol. 13, no. 2, p. 364–375, Apr. 2019. [Online]. Available: <http://dx.doi.org/10.1109/TBCAS.2019.2894157>
- [25] N. Tarabi, H. Mousazadeh, A. Jafari, J. Taghizadeh-Tameh, and A. Kiapey, "Experimental evaluation of some current injection-voltage reading patterns in electrical impedance tomography (eit) and comparison to simulation results - case study: Large scales," *Flow Measurement and Instrumentation*, vol. 83, p. 102087, Mar. 2022. [Online]. Available: <http://dx.doi.org/10.1016/j.flowmeasinst.2021.102087>
- [26] G. Xu, H. Wu, Y. Li, S. Yang, and W. Yan, "Solving the three-dimensional eit forward problem using finite element method," in *The 26th Annual International Conference of the*

- IEEE Engineering in Medicine and Biology Society*, ser. IEMBS-04, vol. 3. IEEE, 2004, p. 1907–1910. [Online]. Available: <http://dx.doi.org/10.1109/IEMBS.2004.1403565>
- [27] V. Sarode, S. Patkar, and A. N. Cheeran, “Comparison of 2-d algorithms in elt based image reconstruction,” *International Journal of Computer Applications*, vol. 69, no. 8, p. 6–11, May 2013. [Online]. Available: <http://dx.doi.org/10.5120/11860-7642>
- [28] K. Astala, M. Lassas, and L. Paivarinta, “Calderon’s inverse problem for anisotropic conductivity in the plane,” 2004. [Online]. Available: <https://arxiv.org/abs/math/0401410>
- [29] N. Hyvönen, “Complete electrode model of electrical impedance tomography: Approximation properties and characterization of inclusions,” *SIAM Journal on Applied Mathematics*, vol. 64, no. 3, p. 902–931, Jan. 2004. [Online]. Available: <http://dx.doi.org/10.1137/S0036139903423303>
- [30] E. Demidenko, A. Borsic, Y. Wan, R. J. Halter, and A. Hartov, “Statistical estimation of eit electrode contact impedance using a magic toeplitz matrix,” *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 8, p. 2194–2201, Aug. 2011. [Online]. Available: <http://dx.doi.org/10.1109/TBME.2011.2125790>
- [31] M. G. Crabb, “Convergence study of 2d forward problem of electrical impedance tomography with high-order finite elements,” *Inverse Problems in Science and Engineering*, vol. 25, no. 10, p. 1397–1422, Nov. 2016. [Online]. Available: <http://dx.doi.org/10.1080/17415977.2016.1255739>
- [32] J. Padilha Leitzke and H. Zangl, “A review on electrical impedance tomography spectroscopy,” *Sensors*, vol. 20, no. 18, p. 5160, Sep. 2020. [Online]. Available: <http://dx.doi.org/10.3390/s20185160>
- [33] Z. Zhou, G. S. dos Santos, T. Dowrick, J. Avery, Z. Sun, H. Xu, and D. S. Holder, “Comparison of total variation algorithms for electrical impedance tomography,” *Physiological Measurement*, vol. 36, no. 6, p. 1193–1209, May 2015. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/36/6/1193>
- [34] K. Knudsen, M. Lassas, J. L. Mueller, and S. Siltanen, “Regularized d-bar method for the inverse conductivity problem,” *Inverse Problems and Imaging*, vol. 3, no. 4, p. 599–624, 2009. [Online]. Available: <http://dx.doi.org/10.3934/ipi.2009.3.599>
- [35] B. M. Graham and A. Adler, “Objective selection of hyperparameter for eit,” *Physiological Measurement*, vol. 27, no. 5, p. S65–S79, Apr. 2006. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/27/5/S06>

- [36] I. Frerichs, M. B. P. Amato, A. H. van Kaam, D. G. Tingay, Z. Zhao, B. Grychtol, M. Bodenstern, H. Gagnon, S. H. Böhm, E. Teschner, O. Stenqvist, T. Mauri, V. Torsani, L. Camporota, A. Schibler, G. K. Wolf, D. Gommers, S. Leonhardt, and A. Adler, “Chest electrical impedance tomography examination, data analysis, terminology, clinical use and recommendations: consensus statement of the translational eit development study group,” *Thorax*, vol. 72, no. 1, p. 83–93, Sep. 2016. [Online]. Available: <http://dx.doi.org/10.1136/thoraxjnl-2016-208357>
- [37] V. Kolehmainen, M. Vauhkonen, P. A. Karjalainen, and J. P. Kaipio, “Assessment of errors in static electrical impedance tomography with adjacent and trigonometric current patterns,” *Physiological Measurement*, vol. 18, no. 4, p. 289–303, Nov. 1997. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/18/4/003>
- [38] K. Ain, D. Kurniadi, Suprijanto, O. Santoso, and A. Wibowo, “Forward problem solution as the operator of filtered and back projection matrix to reconstruct the various method of data collection and the object element model in electrical impedance tomography,” in *AIP Conference Proceedings*, vol. 1656. AIP Publishing LLC, 2015, p. 060010. [Online]. Available: <http://dx.doi.org/10.1063/1.4917141>
- [39] Y. Shi, X. He, M. Wang, B. Yang, F. Fu, and X. Kong, “Reconstruction of conductivity distribution with electrical impedance tomography based on hybrid regularization method,” *Journal of Medical Imaging*, vol. 8, no. 03, Jun. 2021. [Online]. Available: <http://dx.doi.org/10.1117/1.JMI.8.3.033503>
- [40] B. Brazey, Y. Haddab, and N. Zemiti, “Robust imaging using electrical impedance tomography: review of current tools,” *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 478, no. 2258, Feb. 2022. [Online]. Available: <http://dx.doi.org/10.1098/rspa.2021.0713>
- [41] D. C. Barber, B. H. Brown, and I. L. Freeston, *Imaging Spatial Distributions of Resistivity Using Applied Potential Tomography — APT*. Springer Netherlands, 1984, p. 446–462. [Online]. Available: [http://dx.doi.org/10.1007/978-94-009-6045-9\\_26](http://dx.doi.org/10.1007/978-94-009-6045-9_26)
- [42] W. WANG, J. CAI, and L. YANG, “Electrical impedance tomography image reconstruction using iterative lavrentiev and l-curve-based regularization algorithm,” *Journal of Electromagnetic Analysis and Applications*, vol. 02, no. 01, p. 45–50, 2010. [Online]. Available: <http://dx.doi.org/10.4236/jemaa.2010.21007>
- [43] M. Cheney, D. Isaacson, J. C. Newell, S. Simske, and J. Goble, “Noser: An algorithm for solving the inverse conductivity problem,” *International Journal of Imaging Systems and Technology*, vol. 2, no. 2, p. 66–75, Jun. 1990. [Online]. Available: <http://dx.doi.org/10.1002/ima.1850020203>

- [44] D. C. Barber and A. D. Seagar, "Fast reconstruction of resistance images," *Clinical Physics and Physiological Measurement*, vol. 8, no. 4A, p. 47–54, Nov. 1987. [Online]. Available: <http://dx.doi.org/10.1088/0143-0815/8/4A/006>
- [45] M. R. Islam and M. A. Kiber, "Electrical impedance tomography imaging using gauss-newton algorithm," in *2014 International Conference on Informatics, Electronics and Vision (ICIEV)*. IEEE, May 2014, p. 1–4. [Online]. Available: <http://dx.doi.org/10.1109/ICIEV.2014.6850719>
- [46] A. Borsic, B. Graham, A. Adler, and W. Lionheart, "In vivo impedance imaging with total variation regularization," *IEEE Transactions on Medical Imaging*, vol. 29, no. 1, p. 44–54, Jan. 2010. [Online]. Available: <http://dx.doi.org/10.1109/TMI.2009.2022540>
- [47] Q. T. Nguyen Diep, M. Q. Cao Dinh, A. T. Tran, H. N. Huynh, C. T. S. Ching, and T. N. Tran, "Evaluation of frequency-based image reconstruction algorithms in electrical impedance tomography: A phantom study," in *10th International Conference on the Development of Biomedical Engineering in Vietnam*, V. T. Vo, T.-H. Nguyen, B. L. Vong, T. T. H. Pham, and N. H. Doan, Eds. Cham: Springer Nature Switzerland, 2025, pp. 437–446.
- [48] J. L. Mueller and S. Siltanen, *Linear and Nonlinear Inverse Problems with Practical Applications*. Society for Industrial and Applied Mathematics, Oct. 2012. [Online]. Available: <http://dx.doi.org/10.1137/1.9781611972344>
- [49] D. Isaacson, J. Mueller, J. Newell, and S. Siltanen, "Reconstructions of chest phantoms by the d-bar method for electrical impedance tomography," *IEEE Transactions on Medical Imaging*, vol. 23, no. 7, p. 821–828, Jul. 2004. [Online]. Available: <http://dx.doi.org/10.1109/TMI.2004.827482>
- [50] A. Adler, J. H. Arnold, R. Bayford, A. Borsic, B. Brown, P. Dixon, T. J. C. Faes, I. Frerichs, H. Gagnon, Y. Gärber, B. Grychtol, G. Hahn, W. R. B. Lionheart, A. Malik, R. P. Patterson, J. Stocks, A. Tizzard, N. Weiler, and G. K. Wolf, "Greit: a unified approach to 2d linear eit reconstruction of lung images," *Physiological Measurement*, vol. 30, no. 6, p. S35–S55, Jun. 2009. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/30/6/S03>
- [51] S. Heinrich, H. Schiffmann, A. Frerichs, A. Klockgether-Radke, and I. Frerichs, "Body and head position effects on regional lung ventilation in infants: an electrical impedance tomography study," *Intensive Care Medicine*, vol. 32, no. 9, p. 1392–1398, Jun. 2006. [Online]. Available: <http://dx.doi.org/10.1007/s00134-006-0252-0>

- [52] A. Adler and W. R. B. Lionheart, "Uses and abuses of eiders: an extensible software base for eit," *Physiological Measurement*, vol. 27, no. 5, p. S25–S42, Apr. 2006. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/27/5/S03>
- [53] B. Liu, B. Yang, C. Xu, J. Xia, M. Dai, Z. Ji, F. You, X. Dong, X. Shi, and F. Fu, "pyeit: A python based framework for electrical impedance tomography," *SoftwareX*, vol. 7, pp. 304–308, 2018.
- [54] Z. Wang, A. Bovik, H. Sheikh, and E. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600–612, 2004.
- [55] S. Shi, R. Kang, and P. Liatsis, "A conditional diffusion model for electrical impedance tomography image reconstruction," *IEEE Transactions on Instrumentation and Measurement*, vol. 74, p. 1–16, 2025. [Online]. Available: <http://dx.doi.org/10.1109/TIM.2025.3550245>
- [56] S.-Y. Qu, M. Dai, S. Wu, Z.-R. Lv, X.-Y. Ti, and F. Fu, "System introduction and evaluation of the first chinese chest eit device for icu applications," *Scientific Reports*, vol. 11, no. 1, Sep. 2021. [Online]. Available: <http://dx.doi.org/10.1038/s41598-021-98793-0>
- [57] S. Hong, K. Lee, U. Ha, H. Kim, Y. Lee, Y. Kim, and H.-J. Yoo, "A 4.9 mW -sensitivity mobile electrical impedance tomography ic for early breast-cancer detection system," *IEEE Journal of Solid-State Circuits*, vol. 50, no. 1, p. 245–257, Jan. 2015. [Online]. Available: <http://dx.doi.org/10.1109/JSSC.2014.2355835>
- [58] X.-Y. Ke, W. Hou, Q. Huang, X. Hou, X.-Y. Bao, W.-X. Kong, C.-X. Li, Y.-Q. Qiu, S.-Y. Hu, and L.-H. Dong, "Advances in electrical impedance tomography-based brain imaging," *Military Medical Research*, vol. 9, no. 1, Feb. 2022. [Online]. Available: <http://dx.doi.org/10.1186/s40779-022-00370-7>
- [59] K. Sakai, P. N. Darma, P. A. Sejati, R. Wicaksono, H. Hayashi, and M. Takei, "Gastric functional monitoring by gastric electrical impedance tomography (geit) suit with dual-step fuzzy clustering," *Scientific Reports*, vol. 13, no. 1, Jan. 2023. [Online]. Available: <http://dx.doi.org/10.1038/s41598-022-27060-7>
- [60] H. Li, L. Cao, C. Xu, B. Yang, M. Dai, X. Shi, X. Dong, and F. Fu, "Evaluating and reducing the influence of scalp dehydration in the monitoring of intracranial dehydration using electrical impedance tomography," *IEEE Access*, vol. 8, p. 105047–105054, 2020. [Online]. Available: <http://dx.doi.org/10.1109/ACCESS.2020.2996028>

- [61] M. Xu, H. He, and Y. Long, “Lung perfusion assessment by bedside electrical impedance tomography in critically ill patients,” *Frontiers in Physiology*, vol. 12, Oct. 2021. [Online]. Available: <http://dx.doi.org/10.3389/fphys.2021.748724>
- [62] I. Cappellini, L. Campagnola, and G. Consales, “Electrical impedance tomography, artificial intelligence, and variable ventilation: Transforming respiratory monitoring and treatment in critical care,” *Journal of Personalized Medicine*, vol. 14, no. 7, p. 677, Jun. 2024. [Online]. Available: <http://dx.doi.org/10.3390/jpm14070677>
- [63] J. Xu, L. Wang, L. Tong, H. Li, X. Wu, Y. Wang, L. Li, Y. Gong, J. Bi, J. Tao, K. Zhang, M. Li, H. Duan, M. Guan, H. Liang, Y. Wang, and Y. Song, “Novel three-dimensional electrical impedance tomography for noninvasive detection of lung perfusion,” *Journal of Thoracic Disease*, vol. 17, no. 7, p. 4837–4848, Jul. 2025. [Online]. Available: <http://dx.doi.org/10.21037/jtd-2025-275>
- [64] I. Frerichs, G. Hahn, T. Schröder, and G. Heilige, “Electrical impedance tomography in monitoring experimental lung injury,” *Intensive Care Medicine*, vol. 24, no. 8, p. 829–836, Aug. 1998. [Online]. Available: <http://dx.doi.org/10.1007/s001340050673>
- [65] T. Meier, H. Luepschen, J. Karsten, T. Leibecke, M. Großherr, H. Gehring, and S. Leonhardt, “Assessment of regional lung recruitment and derecruitment during a peep trial based on electrical impedance tomography,” *Intensive Care Medicine*, vol. 34, no. 3, p. 543–550, Jul. 2007. [Online]. Available: <http://dx.doi.org/10.1007/s00134-007-0786-9>
- [66] J. Schramel, C. Nagel, U. Auer, F. Palm, C. Aurich, and Y. Moens, “Distribution of ventilation in pregnant shetland ponies measured by electrical impedance tomography,” *Respiratory Physiology and Neurobiology*, vol. 180, no. 2–3, p. 258–262, Mar. 2012. [Online]. Available: <http://dx.doi.org/10.1016/j.resp.2011.11.018>
- [67] I. Frerichs, G. Hahn, and G. Hellige, “Gravity-dependent phenomena in lung ventilation determined by functional eit,” *Physiological Measurement*, vol. 17, no. 4A, p. A149–A157, Nov. 1996. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/17/4A/019>
- [68] T. Muders, H. Luepschen, J. Zinserling, S. Greschus, R. Fimmers, U. Guenther, M. Buchwald, D. Grigutsch, S. Leonhardt, C. Putensen, and H. Wrigge, “Tidal recruitment assessed by electrical impedance tomography and computed tomography in a porcine model of lung injury\*,” *Critical Care Medicine*, vol. 40, no. 3, p. 903–911, Mar. 2012. [Online]. Available: <http://dx.doi.org/10.1097/CCM.0b013e318236f452>

- [69] S. Pulletz, H. R. v. Genderingen, G. Schmitz, G. Zick, D. Schädler, J. Scholz, N. Weiler, and I. Frerichs, “Comparison of different methods to define regions of interest for evaluation of regional lung ventilation by eit,” *Physiological Measurement*, vol. 27, no. 5, p. S115–S127, Apr. 2006. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/27/5/S10>
- [70] T. Becher, B. Vogt, M. Kott, D. Schädler, N. Weiler, and I. Frerichs, “Functional regions of interest in electrical impedance tomography: A secondary analysis of two clinical studies,” *PLOS ONE*, vol. 11, no. 3, p. e0152267, Mar. 2016. [Online]. Available: <http://dx.doi.org/10.1371/journal.pone.0152267>
- [71] M. Lazebnik, D. Popovic, L. McCartney, C. B. Watkins, M. J. Lindstrom, J. Harter, S. Sewall, T. Ogilvie, A. Magliocco, T. M. Breslin, W. Temple, D. Mew, J. H. Booske, M. Okoniewski, and S. C. Hagness, “A large-scale study of the ultrawideband microwave dielectric properties of normal, benign and malignant breast tissues obtained from cancer surgeries,” *Physics in Medicine and Biology*, vol. 52, no. 20, p. 6093–6115, Oct. 2007. [Online]. Available: <http://dx.doi.org/10.1088/0031-9155/52/20/002>
- [72] B.-S. Lin, H.-R. Yu, Y.-T. Kuo, Y.-W. Liu, H.-Y. Chen, and B.-S. Lin, “Wearable electrical impedance tomography belt with dry electrodes,” *IEEE Transactions on Biomedical Engineering*, vol. 69, no. 2, p. 955–962, Feb. 2022. [Online]. Available: <http://dx.doi.org/10.1109/TBME.2021.3110527>
- [73] R. Tomasz, N. Pawel, V. Andres, W. Michal, O. Michal, and A. Przemyslaw, “Architecture of a mobile system for the analysis of biomedical signals based on electrical tomography,” in *2018 Applications of Electromagnetics in Modern Techniques and Medicine (PTZE)*. IEEE, Sep. 2018, p. 236–239. [Online]. Available: <http://dx.doi.org/10.1109/PTZE.2018.8503116>
- [74] C.-L. Hu, I.-C. Cheng, C.-H. Huang, Y.-T. Liao, W.-C. Lin, K.-J. Tsai, C.-H. Chi, C.-W. Chen, C.-H. Wu, I.-T. Lin, C.-J. Li, and C.-W. Lin, “Dry wearable textile electrodes for portable electrical impedance tomography,” *Sensors*, vol. 21, no. 20, p. 6789, Oct. 2021. [Online]. Available: <http://dx.doi.org/10.3390/s21206789>
- [75] F. Zouari, W. Y. Oon, D. Modak, W. H. Lee, W. C. Kwok, P. Cao, W.-N. Lee, T. C. C. Tam, E. C. Wong, and R. W. Chan, “Affordable, portable and self-administrable electrical impedance tomography enables global and regional lung function assessment,” *Scientific Reports*, vol. 12, no. 1, Nov. 2022. [Online]. Available: <http://dx.doi.org/10.1038/s41598-022-24330-2>
- [76] A. K. Al-Bashir, D. H. Al-Bataiha, M. Hafsa, M. A. Al-Abed, and O. Kanoun, “Electrical impedance tomography image reconstruction for lung monitoring based on ensemble learning

- algorithms1,” *Healthcare Technology Letters*, vol. 11, no. 5, p. 271–282, Apr. 2024. [Online]. Available: <http://dx.doi.org/10.1049/htl2.12085>
- [77] R. Guardo, C. Boulay, and M. Bertrand, “A neural network approach to image reconstruction in electrical impedance tomography,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society Volume 13: 1991*. IEEE, 1991, p. 14–15. [Online]. Available: <http://dx.doi.org/10.1109/IEMBS.1991.683818>
- [78] A. Adler and R. Guardo, “A neural network image reconstruction technique for electrical impedance tomography,” *IEEE Transactions on Medical Imaging*, vol. 13, no. 4, p. 594–600, 1994. [Online]. Available: <http://dx.doi.org/10.1109/42.363109>
- [79] T. Zhang, X. Tian, X. Liu, J. Ye, F. Fu, X. Shi, R. Liu, and C. Xu, “Advances of deep learning in electrical impedance tomography image reconstruction,” *Frontiers in Bioengineering and Biotechnology*, vol. 10, Dec. 2022. [Online]. Available: <http://dx.doi.org/10.3389/fbioe.2022.1019531>
- [80] A. Nejatali and I. Ciric, “An iterative algorithm for electrical impedance imaging using neural networks,” *IEEE Transactions on Magnetics*, vol. 34, no. 5, p. 2940–2943, 1998. [Online]. Available: <http://dx.doi.org/10.1109/20.717686>
- [81] E. Ratajewicz-Mikolajczak, G. Shirkoohi, and J. Sikora, “Two ann reconstruction methods for electrical impedance tomography,” *IEEE Transactions on Magnetics*, vol. 34, no. 5, p. 2964–2967, 1998. [Online]. Available: <http://dx.doi.org/10.1109/20.717692>
- [82] O. Mikhailova, W.-W. Dai, and J. Chee, “Pattern recognition based imaging in electrical impedance tomography,” in *Proceedings of 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, ser. IEMBS-96, vol. 2. IEEE, 1996, p. 762–763. [Online]. Available: <http://dx.doi.org/10.1109/IEMBS.1996.651964>
- [83] J. Lampinen, A. Vehtari, and K. Leinonen, “Application of bayesian neural network in electrical impedance tomography,” in *IJCNN’99. International Joint Conference on Neural Networks. Proceedings (Cat. No.99CH36339)*, ser. IJCNN-99, vol. 6. IEEE, 1999, p. 3942–3947. [Online]. Available: <http://dx.doi.org/10.1109/IJCNN.1999.830787>
- [84] P. Wang, L. Xie, and Y. Sun, “Application of pso algorithm and rbf neural network in electrical impedance tomography,” in *2009 9th International Conference on Electronic Measurement and Instruments*. IEEE, Aug. 2009, pp. 2–517–2–521. [Online]. Available: <http://dx.doi.org/10.1109/ICEMI.2009.5274525>

- [85] M. Michalikova, R. Abed, M. Prauzek, and J. Koziorek, "Image reconstruction in electrical impedance tomography using neural network," in *2014 Cairo International Biomedical Engineering Conference (CIBEC)*. IEEE, Dec. 2014, p. 39–42. [Online]. Available: <http://dx.doi.org/10.1109/CIBEC.2014.7020959>
- [86] M. Venclikova, J. Hlavica, M. Prauzek, and J. Koziorek, "Optimization of the radial basis function neural network spread factor for electrical impedance tomography image reconstruction," in *Proceedings of the 8th International Conference on Signal Processing Systems*, ser. ICSPS 2016. ACM, Nov. 2016, p. 26–30. [Online]. Available: <http://dx.doi.org/10.1145/3015166.3015183>
- [87] T. A. Khan and S. H. Ling, "Review on electrical impedance tomography: Artificial intelligence methods and its applications," *Algorithms*, vol. 12, no. 5, p. 88, Apr. 2019. [Online]. Available: <http://dx.doi.org/10.3390/a12050088>
- [88] S. Li, Q. Zhang, and G. Zheng, "Image reconstruction of electrical impedance tomography based on deep learning," in *2021 International Applied Computational Electromagnetics Society (ACES-China) Symposium*. IEEE, Jul. 2021, p. 1–2. [Online]. Available: <http://dx.doi.org/10.23919/ACES-China52398.2021.9581706>
- [89] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in Neural Information Processing Systems*, F. Pereira, C. Burges, L. Bottou, and K. Weinberger, Eds., vol. 25. Curran Associates, Inc., 2012. [Online]. Available: [https://proceedings.neurips.cc/paper\\_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf)
- [90] M. Ivanenko, W. T. Smolik, D. Wanta, M. Midura, P. Wróblewski, X. Hou, and X. Yan, "Image reconstruction using supervised learning in wearable electrical impedance tomography of the thorax," *Sensors*, vol. 23, no. 18, p. 7774, Sep. 2023. [Online]. Available: <http://dx.doi.org/10.3390/s23187774>
- [91] Y. Gao, Y. Lu, H. Li, B. Liu, Y. Li, M. Chen, G. Wang, and Y. Lian, "Eit-cdae: A 2-d electrical impedance tomography image reconstruction method based on auto encoder technique," in *2019 IEEE Biomedical Circuits and Systems Conference (BioCAS)*. IEEE, Oct. 2019, p. 1–4. [Online]. Available: <http://dx.doi.org/10.1109/BIOCAS.2019.8918979>
- [92] X. Li, R. Lu, Q. Wang, J. Wang, X. Duan, Y. Sun, X. Li, and Y. Zhou, "One-dimensional convolutional neural network (1d-cnn) image reconstruction for electrical impedance

- tomography,” *Review of Scientific Instruments*, vol. 91, no. 12, Dec. 2020. [Online]. Available: <http://dx.doi.org/10.1063/5.0025881>
- [93] C. Tan, S. Lv, F. Dong, and M. Takei, “Image reconstruction based on convolutional neural network for electrical resistance tomography,” *IEEE Sensors Journal*, vol. 19, no. 1, p. 196–204, Jan. 2019. [Online]. Available: <http://dx.doi.org/10.1109/JSEN.2018.2876411>
- [94] S. Martin and C. T. M. Choi, “A post-processing method for three-dimensional electrical impedance tomography,” *Scientific Reports*, vol. 7, no. 1, Aug. 2017. [Online]. Available: <http://dx.doi.org/10.1038/s41598-017-07727-2>
- [95] C. R. M. Dumdum, E. Ryan M. Aleluya, C. M. J. Galangque, S. H. Haim, and C. J. Salaan, “A hybrid reconstruction algorithm for web.eit: A difference electrical impedance tomography simulation system,” in *2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management ( HNICEM )*. IEEE, Nov. 2019, p. 1–6. [Online]. Available: <http://dx.doi.org/10.1109/HNICEM48295.2019.9073594>
- [96] P. Wang, H. Chen, G. Ma, R. Li, and X. Wang, “Deep learning scheme pspnet for electrical impedance tomography,” in *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2021*, D. Zonta, H. Huang, and Z. Su, Eds. SPIE, Mar. 2021. [Online]. Available: <http://dx.doi.org/10.1117/12.2582437>
- [97] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” 2017. [Online]. Available: <https://arxiv.org/abs/1704.04861>
- [98] H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, “Pyramid scene parsing network,” 2016. [Online]. Available: <https://arxiv.org/abs/1612.01105>
- [99] S. J. Hamilton, J. L. Mueller, and T. R. Santos, “Robust computation in 2d absolute eit (a-eit) using d-bar methods with the ‘exp’ approximation,” *Physiological Measurement*, vol. 39, no. 6, p. 064005, Jun. 2018. [Online]. Available: <http://dx.doi.org/10.1088/1361-6579/aac8b1>
- [100] Z. Liu, J. Wang, Q. Shan, and D. Liu, “Grapheit: Unsupervised graph neural networks for electrical impedance tomography,” *IEEE Transactions on Computational Imaging*, vol. 10, p. 1559–1570, 2024. [Online]. Available: <http://dx.doi.org/10.1109/TCI.2024.3485517>

- [101] A. Hauptmann, V. Kolehmainen, N. M. Mach, T. Savolainen, A. Seppänen, and S. Siltanen, “Open 2d electrical impedance tomography data archive,” 2017. [Online]. Available: <https://arxiv.org/abs/1704.01178>
- [102] D. Liu, J. Wang, Q. Shan, D. Smyl, J. Deng, and J. Du, “Deeplit: Deep image prior enabled electrical impedance tomography,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 45, no. 8, p. 9627–9638, Aug. 2023. [Online]. Available: <http://dx.doi.org/10.1109/TPAMI.2023.3240565>
- [103] T. N. Kipf and M. Welling, “Semi-supervised classification with graph convolutional networks,” 2016. [Online]. Available: <https://arxiv.org/abs/1609.02907>
- [104] P. Veličković, G. Cucurull, A. Casanova, A. Romero, P. Liò, and Y. Bengio, “Graph attention networks,” 2017. [Online]. Available: <https://arxiv.org/abs/1710.10903>
- [105] K. Xu, W. Hu, J. Leskovec, and S. Jegelka, “How powerful are graph neural networks?” 2018. [Online]. Available: <https://arxiv.org/abs/1810.00826>
- [106] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin, “Attention is all you need,” 2017. [Online]. Available: <https://arxiv.org/abs/1706.03762>
- [107] Z. Liu, Y. Lin, Y. Cao, H. Hu, Y. Wei, Z. Zhang, S. Lin, and B. Guo, “Swin transformer: Hierarchical vision transformer using shifted windows,” 2021. [Online]. Available: <https://arxiv.org/abs/2103.14030>
- [108] M. Räsänen, P. Kuusela, J. Jauhiainen, M. Arif, K. Scheel, T. Savolainen, and A. Seppänen, “Kuopio tomography challenge 2023 – electrical impedance tomography competition and open dataset,” *Applied Mathematics for Modern Challenges*, vol. 2, no. 2, p. 93–118, 2024. [Online]. Available: <http://dx.doi.org/10.3934/ammc.2024009>
- [109] Z. Liu, Y. Wang, S. Vaidya, F. Ruehle, J. Halverson, M. Soljačić, T. Y. Hou, and M. Tegmark, “Kan: Kolmogorov-arnold networks,” 2024. [Online]. Available: <https://arxiv.org/abs/2404.19756>
- [110] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit, and N. Houlsby, “An image is worth 16x16 words: Transformers for image recognition at scale,” 2020. [Online]. Available: <https://arxiv.org/abs/2010.11929>

- [111] I. Amin, S. Shi, H. AlMarzouqi, Z. Aung, W. Ahmed, and P. Liatsis, “Kolmogorov-arnold vision transformer for image reconstruction in lung electrical impedance tomography,” *IEEE Open Journal of the Computer Society*, vol. 6, p. 519–530, 2025. [Online]. Available: <http://dx.doi.org/10.1109/OJCS.2025.3559390>
- [112] A. D. M. Ibrahim, Z. Shang, and J.-E. Hong, “How resilient are kolmogorov–arnold networks in classification tasks? a robustness investigation,” *Applied Sciences*, vol. 14, no. 22, p. 10173, Nov. 2024. [Online]. Available: <http://dx.doi.org/10.3390/app142210173>
- [113] K. Clark, B. Vendt, K. Smith, J. Freymann, J. Kirby, P. Koppel, S. Moore, S. Phillips, D. Maffitt, M. Pringle, L. Tarbox, and F. Prior, “The cancer imaging archive (tcia): Maintaining and operating a public information repository,” *Journal of Digital Imaging*, vol. 26, no. 6, p. 1045–1057, Jul. 2013. [Online]. Available: <http://dx.doi.org/10.1007/s10278-013-9622-7>
- [114] *COMSOL Multiphysics® v. 6.2*, COMSOL AB, Stockholm, Sweden, 2024. [Online]. Available: <https://www.comsol.com>
- [115] S. Wang, D. Hu, M. Zhang, J. Qiu Lin, W. Chen, F. Giorgio-Serchi, L. Peng, Y. Li, and Y. Yang, “A digital twin of electrical tomography for quantitative multiphase flow imaging,” *Communications Engineering*, vol. 1, no. 1, Dec. 2022. [Online]. Available: <http://dx.doi.org/10.1038/s44172-022-00042-3>
- [116] Y. Li, Q. Zhu, and Z. Liu, “Deep learning for image reconstruction in electrical tomography: A review,” *IEEE Sensors Journal*, vol. 25, no. 9, pp. 14 522–14 538, 2025.
- [117] F. Zhuang, Z. Qi, K. Duan, D. Xi, Y. Zhu, H. Zhu, H. Xiong, and Q. He, “A comprehensive survey on transfer learning,” 2019. [Online]. Available: <https://arxiv.org/abs/1911.02685>
- [118] X. Chen, Z. Wang, X. Zhang, R. Fu, D. Wang, M. Zhang, and H. Wang, “Deep autoencoder imaging method for electrical impedance tomography,” *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1–15, 2021.
- [119] S. Ren, K. Sun, C. Tan, and F. Dong, “A two-stage deep learning method for robust shape reconstruction with electrical impedance tomography,” *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 7, pp. 4887–4897, 2020.
- [120] S. Wang, Y. Li, Z. Chen, M. Kong, and Y. Yang, “Digital twin-assisted 3-d electrical capacitance tomography for multiphase flow imaging,” *IEEE Transactions on Instrumentation and Measurement*, vol. 73, pp. 1–12, 2024.

- [121] H. Zhang, R. Cai, Y. Yang, and N. Li, “Unsupervised deep-learning-based error image prior (dleip) algorithm for lung electrical impedance tomography (eit),” *IEEE Internet of Things Journal*, vol. 12, no. 15, pp. 31 399–31 407, 2025.