



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

– **TELECOM** ESCUELA
TÉCNICA **VLC** SUPERIOR
DE INGENIERÍA DE
TELECOMUNICACIÓN

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería de
Telecomunicación

IMPLEMENTACIÓN DE REDES NEURONALES PARA LA
ESTIMACIÓN DE CARACTERÍSTICAS GEOMÉTRICAS
AURICULARES A PARTIR DE SEÑALES
ELECTROCARDIOGRÁFICAS DE SUPERFICIE

Trabajo Fin de Grado

Grado en Ingeniería de Tecnologías y Servicios de
Telecomunicación

AUTOR/A: González Ratón, Lucía

Tutor/a: Guillem Sánchez, María Salud

Cotutor/a externo: Molero Alabau, Rubén

Director/a Experimental: Cano Cabañero, Andrea

CURSO ACADÉMICO: 2023/2024



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

— **TELECOM** ESCUELA
TÉCNICA **VLC** SUPERIOR
DE INGENIERÍA DE
TELECOMUNICACIÓN

Escuela Técnica Superior de Ingeniería de Telecomunicación
Universitat Politècnica de València
Edificio 4D. Camino de Vera, s/n, 46022 Valencia
Tel. +34 96 387 71 90, ext. 77190
www.etsit.upv.es

VLC/
CAMPUS
VALENCIA, INTERNATIONAL
CAMPUS OF EXCELLENCE



Resumen

El desarrollo de redes neuronales se plantea como una solución innovadora para mejorar la estimación geométrica de las aurículas cardíacas a partir de señales electrocardiográficas de mapeo de superficie (BSPM), eliminando la necesidad de técnicas de imagen costosas como la resonancia magnética o la tomografía axial computarizada. Dado que los procedimientos actuales de imagen electrocardiográfica (ECGI) son caros y prolongados, esta metodología propone una alternativa más eficiente que permita estimar la posición del corazón de manera precisa y económica, optimizando el diagnóstico de patologías cardíacas auriculares.

Para ello, se ha recurrido a una base de datos compuesta por 16.800 simulaciones cardíacas con una amplia variabilidad en las propagaciones eléctricas (sinusales y ectópicas) y en las geometrías del corazón y torso, generadas a partir de un modelo estadístico de formas. Con los BSPM obtenidos, se entrenaron diversas arquitecturas de redes neuronales para extraer e identificar información relevante sobre la ubicación de las aurículas. Esta estrategia busca disminuir los errores en el ECGI, aumentando así la precisión diagnóstica y reduciendo la necesidad de procedimientos médicos invasivos y costosos.

Palabras clave: Electrocardiograma (ECG), Imágenes electrocardiográficas (ECGI), Señales electrocardiográficas de mapeo de superficie (BSPM), Aurículas cardíacas, Corazón, Geometría, Torso, Redes Neuronales Convolucionales (CNN), Inteligencia Artificial.



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

— **TELECOM** ESCUELA
TÉCNICA **VLC** SUPERIOR
DE INGENIERÍA DE
TELECOMUNICACIÓN

Resum

El desenvolupament de xarxes neuronals es planteja com una solució innovadora per a millorar l'estimació geomètrica de les aurícules cardíques a partir de senyals electrocardiogràfics de mapatge de superfície (BSPM), eliminant la necessitat de tècniques d'imatge costoses com la ressonància magnètica o la tomografia axial informatitzada. Atés que els procediments actuals d'imatge electrocardiogràfica (ECGI) són cars i prolongats, aquesta metodologia proposa una alternativa més eficient que permet estimar la posició del cor de manera precisa i econòmica, optimitzant el diagnòstic de patologies cardíques auriculars.

Per a això, s'ha utilitzat una base de dades composta per 16.800 simulacions cardíques amb una àmplia variabilitat en les propagacions elèctriques (sinusals i ectòpiques) i en les geometries del cor i tors, generades a partir d'un model estadístic de formes. Amb els BSPM obtinguts, es van entrenar diverses arquitectures de xarxes neuronals per a extraure i identificar informació rellevant sobre la ubicació de les aurícules. Aquesta estratègia busca disminuir els errors en el ECGI, augmentant així la precisió diagnòstica i reduint la necessitat de procediments mèdics invasius i costosos.



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

— **TELECOM** ESCUELA
TÉCNICA **VLC** SUPERIOR
DE INGENIERÍA DE
TELECOMUNICACIÓN



Abstract

The development of neural networks is proposed as an innovative solution to improve the geometric estimation of cardiac atria from surface mapping electrocardiographic signals (BSPM), removing the need for expensive imaging techniques such as magnetic resonance imaging or computed tomography. Given that current electrocardiographic imaging (ECGI) procedures are expensive and time-consuming, this methodology proposes a more efficient alternative to estimate the position of the heart accurately and economically, optimizing the diagnosis of atrial cardiac pathologies.

To this end, a database of 16,800 cardiac simulations with a wide variability in electrical propagations (sinus and ectopic) and in the geometries of the heart and torso, generated from a statistical shape model, has been used. With the BSPM obtained, different neural network architectures were trained to extract and identify relevant information about the location of the atria. This strategy aims to reduce ECGI errors, thereby increasing diagnostic accuracy and reducing the need for invasive and costly medical procedures.



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

— **TELECOM** ESCUELA
TÉCNICA **VLC** SUPERIOR
DE INGENIERÍA DE
TELECOMUNICACIÓN

RESUMEN EJECUTIVO

La memoria del TFG del Grado en Ingeniería de Tecnologías y Servicios de Telecomunicación debe desarrollar en el texto los siguientes conceptos, debidamente justificados y discutidos, centrados en el ámbito de la ingeniería de telecomunicación

CONCEPT (ABET)	CONCEPTO (traducción)	¿Cumple? (S/N)	¿Dónde? (páginas)
1. IDENTIFY:	1. IDENTIFICAR:		
1.1. Problem statement and opportunity	1.1. Planteamiento del problema y oportunidad	S	1
1.2. Constraints (standards, codes, needs, requirements & specifications)	1.2. Toma en consideración de los condicionantes (normas técnicas y regulación, necesidades, requisitos y especificaciones)	S	4-15
1.3. Setting of goals	1.3. Establecimiento de objetivos	S	16
2. FORMULATE:	2. FORMULAR:		
2.1. Creative solution generation (analysis)	2.1. Generación de soluciones creativas (análisis)	S	20-23
2.2. Evaluation of multiple solutions and decision-making (synthesis)	2.2. Evaluación de múltiples soluciones y toma de decisiones (síntesis)	S	24-35
3. SOLVE:	3. RESOLVER:		
3.1. Fulfilment of goals	3.1. Evaluación del cumplimiento de objetivos	S	36-37
3.2. Overall impact and significance (contributions and practical recommendations)	3.2. Evaluación del impacto global y alcance (contribuciones y recomendaciones prácticas)	S	37



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

— **TELECOM** ESCUELA
TÉCNICA **VLC** SUPERIOR
DE INGENIERÍA DE
TELECOMUNICACIÓN

Escuela Técnica Superior de Ingeniería de Telecomunicación
Universitat Politècnica de València
Edificio 4D. Camino de Vera, s/n, 46022 Valencia
Tel. +34 96 387 71 90, ext. 77190
www.etsit.upv.es

VLC/
CAMPUS
VALENCIA, INTERNATIONAL
CAMPUS OF EXCELLENCE



Índice de figuras

Figura 1. Anatomía del corazón (Quirónsalud, 2024).....	2
Figura 2. Estructura de la aurícula izquierda (Paradigmia).....	3
Figura 3. Estructura de la aurícula derecha (Cardiomedica).....	3
Figura 4. Señal de un ECG (Quora).....	4
Figura 5. Determinación de la frecuencia cardíaca a partir de un ECG (UNAM).....	5
Figura 6. Derivaciones bipolares y monopares (My EKG).....	6
Figura 7. Derivaciones precordiales.....	7
Figura 8. Chaleco para la obtención del BSPM (Corify).....	8
Figura 9. Análisis de señales BSPM utilizando modelos estadísticos y deterministas. (Hearts (Basel), 2021, Body Surface Potential Mapping: A Comprehensive Review, 2(4), 514–542).....	9
Figura 10. Neurona biológica (Xeridia).....	10
Figura 11. Esquema de neuronas biológicas y neuronas artificiales (Requena et al., Universidad de Murcia).....	10
Figura 12. Ejemplo de red neuronal (Matich, D. J. (2001). Redes neuronales: Conceptos básicos y aplicaciones. Universidad Tecnológica Nacional – FR Rosario.).....	11
Figura 13. Red neuronal convolucional (Shahriar, N. (2023, April 15). What is a convolutional neural network (CNN). LinkedIn).....	12
Figura 14. Representación de la función 'sigmoid' (OpenWebinars).....	13
Figura 15. Representación de la función 'relu' (OpenWebinars).....	13
Figura 16. Planos anatómicos (Estudiante Médico. (2017, noviembre 19). Planos anatómicos - Generalidades de anatomía. https://estudiantemedico.tumblr.com/post/167986512330/planos-anat%C3%B3micos-generalidades-de-anatomia).....	18
Figura 17. Definición del conjunto de datos.....	22
Figura 18. Esquema de la arquitectura empleada.....	24
Figura 19. Boxplot del MAE en simulaciones (Matlab).....	26
Figura 20. Boxplot del RMSE en simulaciones (Matlab).....	26
Figura 21. Boxplot del RMSE en simulaciones en cada eje (Matlab).....	27
Figura 22. Boxplot del MAE en simulaciones en cada eje (Matlab).....	27
Figura 23. Torso correspondiente al archivo 6_Torso.mat.....	28
Figura 24. Torso correspondiente al archivo 337_Torso.mat.....	28
Figura 25. Torso correspondiente al archivo 613_Torso.mat.....	28
Figura 26. Mayor MAE correspondiente al torso 872_Torso.mat.....	29
Figura 27. Mayor RMSE correspondiente al torso 872_Torso.mat.....	29
Figura 28. Predicción en el paciente 20220902_VENTRICLE.....	30
Figura 29. Predicción en el paciente ACAMP1023OU004CI230017.....	31
Figura 30. Predicción en el paciente ACAMP1023OU004CI230030.....	31



Figura 31. Predicción en el paciente ACAMP1023OU004CI230051.....	32
Figura 32. Predicción en el paciente ACAMP1023OU004CI230060.....	32
Figura 33. Boxplot del RMSE en pacientes	33
Figura 34. Boxplot del RMSE en pacientes en el eje X.....	33
Figura 35. Boxplot del RMSE en pacientes en el eje Y	33
Figura 36. Boxplot del RMSE en pacientes en el eje Z	34



Índice de tablas

Tabla 1. Especificaciones del hardware utilizado	20
Tabla 2. Modelos con la arquitectura ‘build_model_4’	25
Tabla 3. Modelos con la arquitectura ‘build_model_6’	25
Tabla 4. Resumen de errores obtenidos	34
Tabla 5. Resumen de errores obtenidos en cada eje	34



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

— **TELECOM** ESCUELA
TÉCNICA **VLC** SUPERIOR
DE INGENIERÍA DE
TELECOMUNICACIÓN

Escuela Técnica Superior de Ingeniería de Telecomunicación
Universitat Politècnica de València
Edificio 4D. Camino de Vera, s/n, 46022 Valencia
Tel. +34 96 387 71 90, ext. 77190
www.etsit.upv.es

VLC/
CAMPUS
VALENCIA, INTERNATIONAL
CAMPUS OF EXCELLENCE





Índice

Capítulo 1.	Introducción	1
1.1	Anatomía y fisiología del corazón	1
1.1.1	Aurícula izquierda	2
1.1.2	Aurícula derecha.....	3
1.2	Electrocardiograma (ECG)	4
1.2.1	Lectura de un electrocardiograma	4
1.2.2	Derivaciones de un electrocardiograma	5
1.3	Body surface potencial mapping (BSPM)	7
1.3.1	Métodos de análisis	8
1.4	Imagen electrocardiográfica (ECGI).....	9
1.5	Las redes neuronales	10
1.5.1	Redes neuronales convolucionales	11
1.5.2	Funciones de activación y su importancia.....	12
1.5.3	Uso de redes neuronales para nuestro BSPM.....	13
1.6	Estudios recientes en evaluación cardíaca	14
Capítulo 2.	Objetivos	16
Capítulo 3.	Metodología	17
3.1	Base de Datos.....	17
3.2	Software utilizado para realización del proyecto.....	19
3.3	Librerías	19
3.4	Hardware utilizado en el servidor Titan.....	20
3.5	Proceso de preparación para el entrenamiento de las redes	20
3.5.1	DataGenerator	21
3.5.2	ArquitecturasRed.....	21
3.5.2.1	Error absoluto medio (MAE).....	21
3.5.2.2	Raíz del error cuadrático medio (RMSE)	22
3.5.3	ReadData	22
3.6	Prueba para test.....	22
3.6.1	Test and Metrics BSPM.....	23
3.6.2	Test Patients	23
Capítulo 4.	Desarrollo y resultados del trabajo.....	24
4.1	Modelos entrenados	24
4.2	Resultados en simulaciones	25
4.3	Resultados en pacientes	29



4.4	Análisis de los errores obtenidos en simulaciones y en pacientes	34
Capítulo 5.	Conclusiones y propuesta de trabajo futuro	36
Capítulo 6.	Bibliografía	38



Capítulo 1. Introducción

En el campo de la Ingeniería de Telecomunicaciones, la convergencia con la investigación en salud ha dado lugar a un panorama de innovaciones, abriendo nuevas posibilidades para la detección precoz y el tratamiento de enfermedades cardíacas. Este contexto impulsa la relevancia del presente trabajo de fin de grado, que se centra en mejorar el proceso de estimación de la actividad eléctrica cardíaca mediante la utilización de imágenes electrocardiográficas (ECGI).

Actualmente, los sistemas de ECGI requieren técnicas de imagen costosas y prolongadas para obtener la geometría cardíaca del paciente, lo cual dificulta su accesibilidad y eficiencia en el diagnóstico de patologías auriculares. Motivada por esta problemática, este proyecto propone desarrollar y aplicar redes neuronales para estimar características geométricas auriculares a partir de señales electrocardiográficas de mapeo de superficie (BSPM), eliminando así la dependencia de las técnicas de imagen convencionales.

Además de facilitar y agilizar la caracterización de la posición del corazón, este estudio busca mejorar la precisión en el diagnóstico de patologías cardíacas auriculares. Dado que el proceso de ECGI es complejo y puede verse afectado por ruido, una estimación precisa de la geometría del corazón podría mejorar el diagnóstico y, en consecuencia, el tratamiento de estas enfermedades.

Este trabajo representa un avance significativo en el campo del diagnóstico no invasivo de patologías cardíacas auriculares, con el potencial de reducir la dependencia de procedimientos médicos invasivos y costosos, al tiempo que se mejora la rapidez y precisión en la detección de dichas patologías. La sinergia entre la ingeniería de telecomunicaciones y la biomedicina es esencial en este proceso, facilitando la convergencia de tecnologías innovadoras para el beneficio de la atención médica y la calidad de vida de los pacientes.

1.1 Anatomía y fisiología del corazón

El sistema circulatorio transporta la sangre en una sola dirección, proceso conocido como “circulación”. Las arterias llevan la sangre desde el corazón hacia el cuerpo, mientras que las venas la devuelven al corazón, incluyendo las venas pulmonares, que traen sangre oxigenada, y las venas cavas, que llevan sangre desoxigenada.

El corazón tiene cuatro cámaras: dos aurículas y dos ventrículos. Las aurículas reciben la sangre y la envían a los ventrículos, que se encargan de bombearla al resto del cuerpo. Las válvulas cardíacas, incluyendo las válvulas auriculoventriculares y semilunares, regulan el flujo sanguíneo y evitan el retroceso.

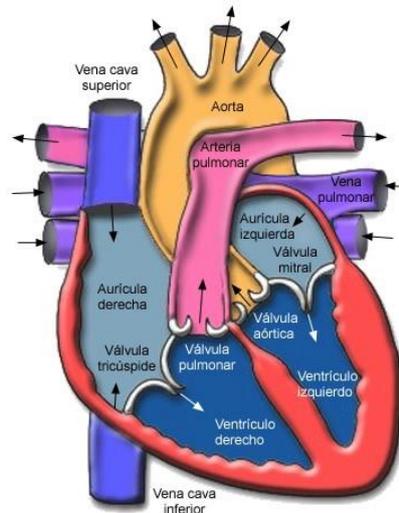


Figura 1. Anatomía del corazón (Quirónsalud, 2024)

1.1.1 Aurícula izquierda

La aurícula izquierda (AI) desempeña un papel crucial en la función global del sistema circulatorio, con un enfoque particular en la función diastólica del ventrículo izquierdo, siendo un biomarcador de este último. Funciona como reservorio, conducto y bomba, almacenando y transfiriendo sangre oxigenada desde las venas pulmonares al ventrículo izquierdo. Sin embargo, la fibrilación auricular puede afectar negativamente a la AI, aumentando el riesgo de coágulos y tromboembolismo.

A pesar de su forma redondeada, la AI presenta una estructura compleja con seis paredes:

- **Pared anterior:** aquí se encuentra el orificio auriculoventricular izquierdo, que conecta la AI con el ventrículo izquierdo. Además, el septum interauricular coloca la aurícula derecha adelante de la izquierda.
- **Pared posterior:** tiene una forma cuadrilátera, regular y lisa, con una disposición vertical que se curva ligeramente hacia atrás. En esta zona se encuentran los orificios de las venas pulmonares: dos a la derecha y dos a la izquierda, sin válvulas.
- **Pared interna o septal:** proyectada hacia delante y a la derecha, esta pared corresponde al tabique interauricular.
- **Pared externa o lateral izquierda:** aquí se localiza el orificio de la orejuela izquierda, que conduce a la propia orejuela izquierda. Esta cavidad alargada y curva se ubica arriba, adelante y a la izquierda de la aurícula izquierda.
- **Pared superior:** estrecha, redondeada y lisa, esta pared forma el techo de la AI. Se relaciona hacia adelante con la arteria aorta y el tronco pulmonar, separándose de ellos por el seno transversal del pericardio.
- **Pared inferior:** de forma cóncava y estrecha, esta pared conecta la pared posterior con el orificio auriculoventricular.

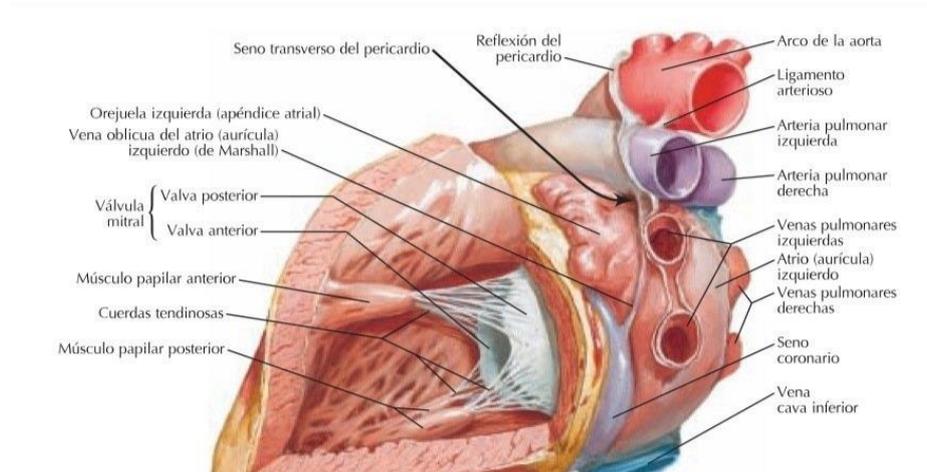


Figura 2. Estructura de la aurícula izquierda (Paradigmia)

1.1.2 Aurícula derecha

La aurícula derecha (AD) desempeña un papel fundamental en la función circulatoria, actuando como reservorio de sangre desoxigenada que recibe de las venas cavas y del seno venoso. Durante la diástole ventricular, transfiere la sangre al ventrículo derecho a través de la válvula tricúspide. La AD también es clave para medir la presión venosa central (PVC), un indicador del estado circulatorio. Contiene el nódulo sinusal y el nódulo auriculoventricular, estructuras esenciales para mantener el ritmo cardíaco coordinado y eficiente.

La AD tiene forma irregular y varias paredes:

- **Pared anterior:** contiene la válvula tricúspide y el septum interauricular.
- **Pared posterior:** donde desembocan las venas cavas y el seno venoso.
- **Pared lateral:** incluye la orejuela derecha, una estructura triangular que aumenta la capacidad de la aurícula.

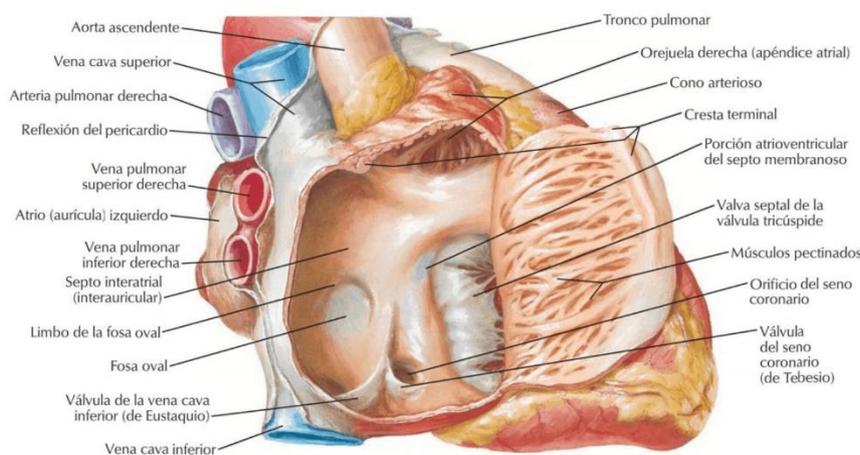


Figura 3. Estructura de la aurícula derecha (Cardiomedica)

1.2 Electrocardiograma (ECG)

El electrocardiograma es una herramienta esencial y sencilla que registra la actividad eléctrica del corazón de manera rápida y no invasiva. Esta actividad eléctrica es fundamental para coordinar las contracciones de las cuatro cámaras cardíacas, permitiendo que el corazón bombee sangre por todo el cuerpo.

Cuando se obtiene un ECG, se visualizan ondas que representan esta actividad eléctrica. Los médicos analizan estas señales para detectar anomalías que podrían indicar problemas cardíacos, proporcionándoles información crucial sobre la rapidez, regularidad e intensidad del ritmo cardíaco, lo que guía el diagnóstico y el tratamiento médico.

1.2.1 Lectura de un electrocardiograma

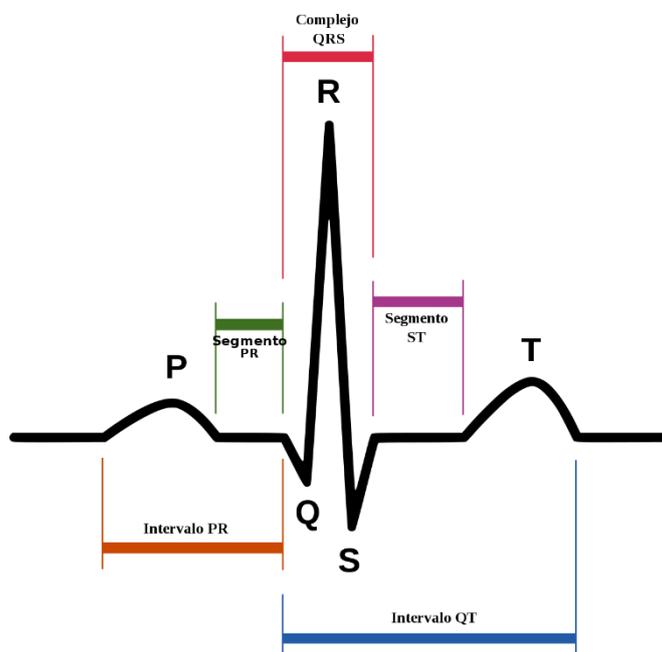


Figura 4. Señal de un ECG (Quora)

El registro de un ECG representa el comportamiento del ritmo cardíaco, mostrando la presencia de tres ondas principales: la onda P, el complejo QRS y la onda T. Basándose en las características de estas ondas, sus formas y duración, se pueden identificar irregularidades en los latidos.

La onda P es la primera onda del ciclo cardíaco y representa la despolarización de las aurículas. Combina la actividad eléctrica de ambas aurículas. La despolarización inicial corresponde a la aurícula derecha, mientras que la parte final se asocia con la aurícula izquierda.

El complejo QRS representa la despolarización de los ventrículos y su forma puede variar según la derivación utilizada. La primera onda negativa se denomina onda Q, la primera onda positiva es la onda R, y cualquier onda negativa después de la onda R es la onda S. Si el complejo es completamente negativo, se denomina complejo QS.

La onda T refleja la repolarización de los ventrículos. Sucede tras la actividad del complejo QRS y marca el final de la actividad cardíaca. Normalmente es de menor amplitud que el QRS y presenta una forma asimétrica y redondeada, pero una forma puntiaguda o cóncava puede indicar la presencia de alteraciones cardíacas.

Es importante que el intervalo de tiempo entre la onda P y la onda T sea regular durante todo el ECG. Cualquier variación en este intervalo puede señalar posibles irregularidades en el ritmo cardíaco.

Para determinar la frecuencia cardíaca se identifica el punto más alto “R” y se cuenta el número de cuadrados que delimitan ese punto y el del siguiente latido. En el papel de medición, cada cuadrado es de 10 mm y representa 0.1 mV en el eje vertical y 0.04 s en el horizontal. Cada 5 cuadrados se resalta un cuadrado grande para facilitar la interpretación, el cual representa 0.2 s. Para conocer la frecuencia cardíaca en pulsos por minuto se debe dividir 300 (número total de cuadrados en un minuto) entre el número de cuadrados medido. Por ejemplo, si hay 3 cuadros grandes entre dos picos, la frecuencia cardíaca sería de 100 pulsos por minuto.

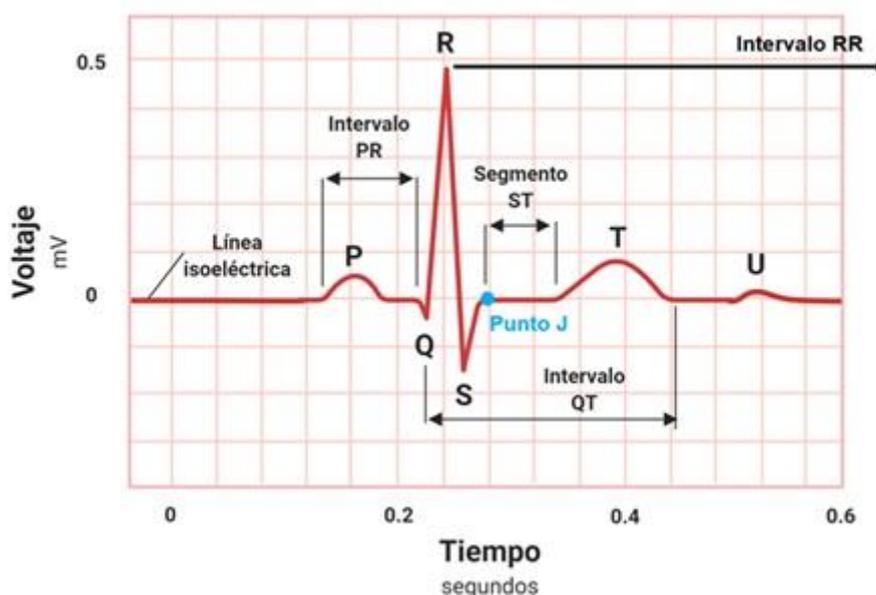


Figura 5. Determinación de la frecuencia cardíaca a partir de un ECG (UNAM)

Este cálculo proporciona la cantidad de latidos por minuto que tiene una persona. Normalmente, el ritmo cardíaco debe oscilar entre 60 y 100 latidos por minuto. Si la frecuencia cardíaca está por debajo de esta cifra, se considera bradicardia, mientras que, si está por encima, se denomina taquicardia, describiendo respectivamente un ritmo cardíaco anormalmente lento o rápido.

1.2.2 Derivaciones de un electrocardiograma

En el electrocardiograma, las derivaciones cardíacas representan la diferencia de potenciales eléctricos entre dos puntos, ya sea entre dos electrodos (derivación bipolar) o entre un punto virtual y un electrodo (derivaciones monopares). Es fundamental considerarlas en conjunto, ya que cada una ofrece una perspectiva única del estímulo eléctrico del corazón. Se dividen en

derivaciones de extremidades, que se centran en el plano frontal, y derivaciones precordiales, que se enfocan en el plano horizontal.

Las derivaciones de extremidades, obtenidas con electrodos en las extremidades del paciente, proporcionan información electrocardiográfica en el plano frontal, independiente de los potenciales dirigidos hacia delante o hacia atrás. Se distinguen dos tipos principales:

- Derivaciones bipolares estándar: registran la diferencia de potencial entre dos electrodos en diferentes extremidades, como D1 (entre brazo derecho y brazo izquierdo), D2 (entre brazo derecho y pierna izquierda) y D3 (entre brazo y pierna izquierda). Estas derivaciones forman el triángulo de Einthoven.
- Derivaciones monopolares aumentadas: registran la diferencia potencial entre un punto teórico en el centro del triángulo de Einthoven y cada extremidad. Incluyen aVR (brazo derecho), aVL (brazo izquierdo) y aVF (pierna izquierda), mostrando el potencial absoluto amplificado en cada extremidad con respecto al punto teórico.

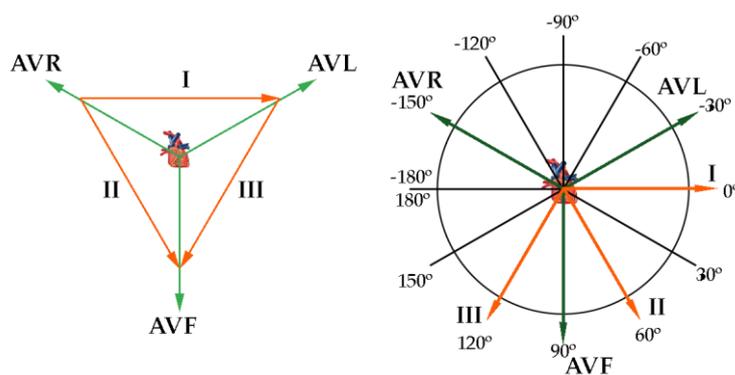


Figura 6. Derivaciones bipolares y monopolares (My EKG)

Por otro lado, las derivaciones precordiales, identificadas con una letra V seguida de un número del 1 al 6, son de tipo monopolar y se enfocan en el plano horizontal. Son consideradas eficaces para detectar anomalías en el ventrículo izquierdo, especialmente en las paredes anterior y posterior. En un electrocardiograma normal, muestran complejos QRS predominantemente negativos en V1 y V2 y positivos en V4 a V6.

Cada una de las derivaciones precordiales tiene una función específica (My EKG, 2024):

- V1: registra los potenciales de las aurículas, parte del tabique y la pared anterior del ventrículo derecho. Presenta una pequeña onda R seguida de una onda S profunda.
- V2: ubicado sobre la pared ventricular derecha, muestra una onda R ligeramente más prominente que en V1, seguida de una onda S profunda.
- V3: se sitúa en una zona de transición entre potenciales izquierdos y derechos del ECG, lo que da lugar a un complejo QRS isobifásico, con onda R y onda S casi iguales.
- V4: posicionada en el ápice del ventrículo izquierdo, muestra una onda R alta seguida de una onda S pequeña.
- V5 y V6: colocadas sobre el miocardio del ventrículo izquierdo, presentan una onda R menor que en V4, aunque sigue siendo prominente, precedida de una onda Q pequeña.

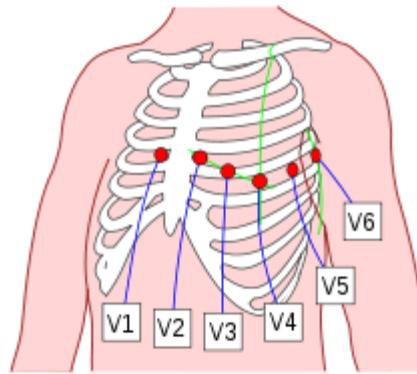


Figura 7. Derivaciones precordiales

1.3 Body surface potencial mapping (BSPM)

El Mapeo de Potenciales de Superficie Corporal (BSPM, por sus siglas en inglés) es una técnica no invasiva para evaluar la actividad eléctrica del corazón, con una importante aplicación práctica para investigación clínica.

A diferencia del electrocardiograma clínico estándar (ECG) que emplea 12 derivaciones, el BSPM requiere un mayor número de electrodos, oscilando entre 64 y 300, distribuidos estratégicamente por la superficie del torso. La disposición de los electrodos puede adoptar la forma de tiras o chalecos para facilitar su colocación, permitiendo una adquisición más completa de las señales bioeléctricas.

La calidad de las señales registradas es un aspecto crucial en el BSPM. Se emplean técnicas avanzadas para eliminar el ruido eléctrico proveniente de los cables de conexión y de equipos cercanos. Las señales se convierten a formato digital para su posterior procesamiento, visualización y análisis cuantitativo.

Las señales digitalizadas se visualizan mediante mapas espaciales del potencial de la superficie corporal, los cuales incorporan información espacial de la ubicación de los electrodos. Para ello, se utiliza una representación geométrica del torso basada en las posiciones de los electrodos, definiendo una malla superficial mediante triangulación de puntos.

Proporciona una adquisición integral de señales bioeléctricas en todo el tórax, permitiendo un análisis más complejo y extenso que el electrocardiograma estándar. Aunque no es una herramienta común en la práctica clínica, su importancia radica en la investigación y como entrada para otros modos de análisis, como la imagen electrocardiográfica (ECGI).



Figura 8. Chaleco para la obtención del BSPM (Corify)

1.3.1 Métodos de análisis

Una vez obtenidos los electrocardiogramas, el análisis de BSPM se divide en tres enfoques principales (Hearts, 2021):

1. Enfoques basados en señales: Estos métodos se centran en características temporales de las señales, como desviaciones en el segmento ST o formas de ondas como P, QRS o T. No consideran la disposición de los electrodos, sino los parámetros de las señales. Desde la perspectiva del análisis de imágenes, estos enfoques son similares al uso de uno o más haces de ultrasonido para estimar el movimiento cardíaco.
2. Enfoques de mapeo: Este enfoque aprovecha tanto el muestro temporal como espacial para crear mapas de bioelectricidad, estáticos o interactivos, que permiten identificar características de la actividad eléctrica y enfermedades cardíacas. Sin embargo, pueden presentar distorsiones debido a la variabilidad en la resistencia eléctrica del torso.
3. Reconstrucciones de fuentes cardíacas (ECGI): Este proceso requiere información adicional para estimar las fuentes a partir de mediciones remotas. Utiliza señales de BSPM y conocimiento anatómico del torso para estimar las fuentes bioeléctricas en el corazón. A pesar de las dificultades, es una técnica aplicada en diversas situaciones clínicas y es la única técnica de BSPM implementada comercialmente.

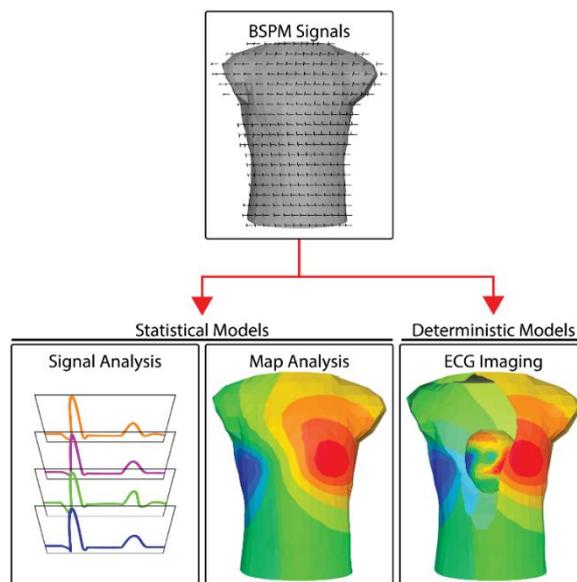


Figura 9. Análisis de señales BSPM utilizando modelos estadísticos y deterministas. (Hearts (Basel), 2021, Body Surface Potential Mapping: A Comprehensive Review, 2(4), 514–542).

1.4 Imagen electrocardiográfica (ECGI)

La imagen electrocardiográfica (ECGI) es una técnica avanzada diseñada para comprender la actividad eléctrica mediante mediciones eléctricas en la superficie corporal. Este enfoque surge de la necesidad de simular los potenciales en la superficie del cuerpo para caracterizar detalladamente cómo el corazón genera y distribuye los impulsos eléctricos que regulan su función.

Pertenece a la categoría de problemas inversos que buscan reconstruir fuentes a partir de mediciones remotas, como la estimación de la fuente cardíaca a partir de registros BSPM. Dichos problemas rara vez tienen una solución única y pueden verse afectados significativamente por pequeñas perturbaciones en la entrada, como el ruido.

Esta técnica permite la caracterización no invasiva de la actividad eléctrica del corazón en diversos escenarios, eliminando la necesidad de mediciones invasivas. Sin embargo, sus limitaciones van más allá de los requisitos del propio BSPM. Otro factor que complica la situación es la precisión de la geometría del corazón y del torso en el procesamiento BSPM. Se han investigado técnicas para reconstruir la geometría cardíaca utilizando únicamente registros de la superficie corporal, lo que permitiría un enfoque de “ECGI sin imágenes”, pero la regularización del problema inverso sigue siendo uno de los aspectos más desafiantes del ECGI.

Para abordar este desafío, se emplean métodos numéricos para estimar la fuente cardíaca que genera los potenciales observados, convirtiendo el BSPM en información clínicamente relevante sobre la actividad cardíaca. Sin embargo, el ECGI enfrenta desafíos importantes, especialmente en términos de costo computacional, adquisición y procesamiento de señales, lo que limita su uso en la práctica clínica.

La implementación de ECGI requiere geometrías precisas del torso y del corazón, lo que añade complejidad y costos adicionales. A pesar de los avances en los métodos computacionales para

resolver estos problemas, el ECGI todavía no es un procedimiento común en la práctica debido a sus limitaciones y desafíos.

1.5 Las redes neuronales

Las redes neuronales, también conocidas como redes neuronales artificiales (ANN) o redes neuronales simuladas (SNN), son un tipo de tecnología en el campo del machine learning, siendo la base del deep learning. Se inspiran en la estructura y funcionamiento del cerebro humano, imitando la forma en que las neuronas biológicas se comunican entre sí.

Estas redes se basan en la estructura y función de las neuronas del cerebro humano, compuestas por dendritas, soma y axón. Las dendritas captan impulsos nerviosos de otras neuronas, procesados en el soma y transmitidos por el axón, generando impulsos nerviosos dirigidos a las neuronas adyacentes.

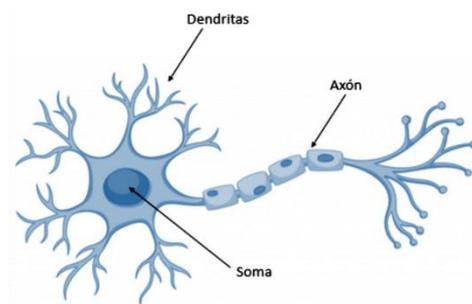


Figura 10. Neurona biológica (Xeridia)

Una neurona artificial se representa como un círculo o nodo, con entradas que llegan desde otras neuronas o desde el entorno, y una salida que lleva la señal procesada hacia otras neuronas o hacia el exterior del sistema. Dentro de la neurona, se pueden representar los procesos de suma ponderada de las entradas, seguido de la aplicación de una función de activación que determina la salida de la neurona en función de la entrada recibida.

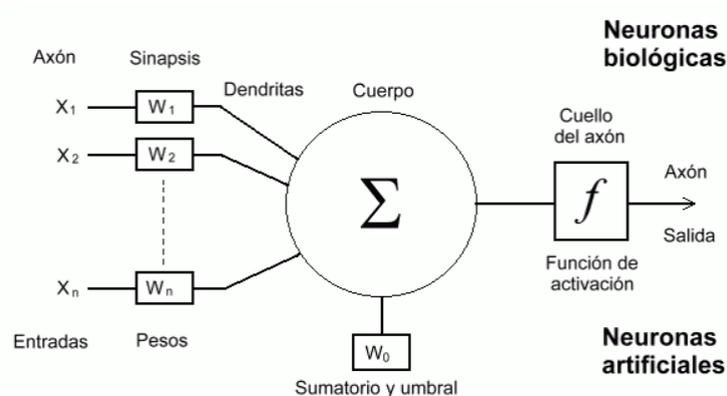


Figura 11. Esquema de neuronas biológicas y neuronas artificiales (Requena et al., Universidad de Murcia)

Su estructura consta de capas de nodos, que incluyen una capa de entrada, una o varias capas ocultas y una capa de salida. Cada nodo, o neurona artificial, está conectado a otros nodos y tiene

asignados un peso y un umbral. Cuando la salida de un nodo supera el umbral establecido, se activa y se transmite datos a la siguiente capa de la red. En caso contrario, no se envían datos a la siguiente capa.

Según su ubicación en la red, podemos identificar tres tipos de capas:

1. Capa de entrada: Recibe directamente la información de fuentes externas a la red.
2. Capas ocultas: Se encuentran en el interior de la red y no tienen conexión directa con el entorno externo. El número de capas ocultas puede variar de 0 a un número considerable. Las neuronas en estas capas pueden estar conectadas de diversas maneras, lo que, junto con su cantidad, determina las distintas topologías de las redes neuronales.
3. Capa de salida: Transmiten información desde la red hacia el exterior.

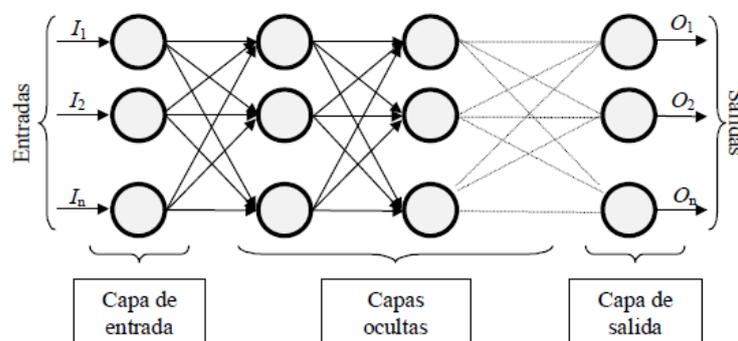


Figura 12. Ejemplo de red neuronal (Matich, D. J. (2001). Redes neuronales: Conceptos básicos y aplicaciones. Universidad Tecnológica Nacional – FR Rosario.)

Estas redes se basan en el entrenamiento con datos para mejorar su precisión con el tiempo, convirtiéndose en herramientas poderosas de informática e inteligencia artificial, capaces de clasificar y procesar datos a gran velocidad una vez ajustadas correctamente.

Una de las características clave de las redes neuronales es su capacidad de aprendizaje adaptativo. Esto significa que pueden aprender a realizar diversas tareas a través de ejemplos ilustrativos durante el entrenamiento. Al ser capaces de diferenciar patrones mediante ejemplos y entrenamiento, no requieren la creación de modelos previos ni la especificación de funciones de distribución de probabilidad.

Durante el proceso de aprendizaje, los pesos de las conexiones entre las neuronas se ajustan para lograr resultados específicos, generando sus propias distribuciones de pesos a través del aprendizaje. Algunas redes siguen aprendiendo tras completar su periodo de entrenamiento inicial.

1.5.1 Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN) son una red neuronal muy utilizada en el procesamiento de imágenes y vídeos. En estas redes, las neuronas están organizadas en capas convolucionales, donde cada neurona está conectada solo a una región local de la capa anterior en lugar de a todas las neuronas de esa capa. Esta arquitectura permite la detección de

características específicas en una imagen, como bordes y patrones, sin importar su ubicación en la imagen.

Son redes muy efectivas en segmentación de imágenes, ya que aprenden patrones complejos en los datos de entrada y generalizan bien a nuevas imágenes. Además, son altamente escalables y se pueden entrenar en conjuntos de datos utilizando hardware especializado, como unidades de procesamiento gráfico (GPU).

En el contexto de la estimación geométrica, las señales del cuerpo (BSPM) pueden ser tratadas como una imagen en la que las características locales son esenciales para determinar la geometría subyacente del corazón. Pueden reconocer patrones independientemente de su ubicación o tamaño dentro del input, permitiendo que el modelo sea robusto frente a variaciones en la forma y posición de las estructuras cardíacas, conduciendo a una estimación más precisa y consistente.

Debido al uso de operaciones convolucionales, permite entrenar modelos más complejos con grandes volúmenes de datos, mejorando así la precisión al aprovechar más datos de entrenamiento y realizar evaluaciones más detalladas.

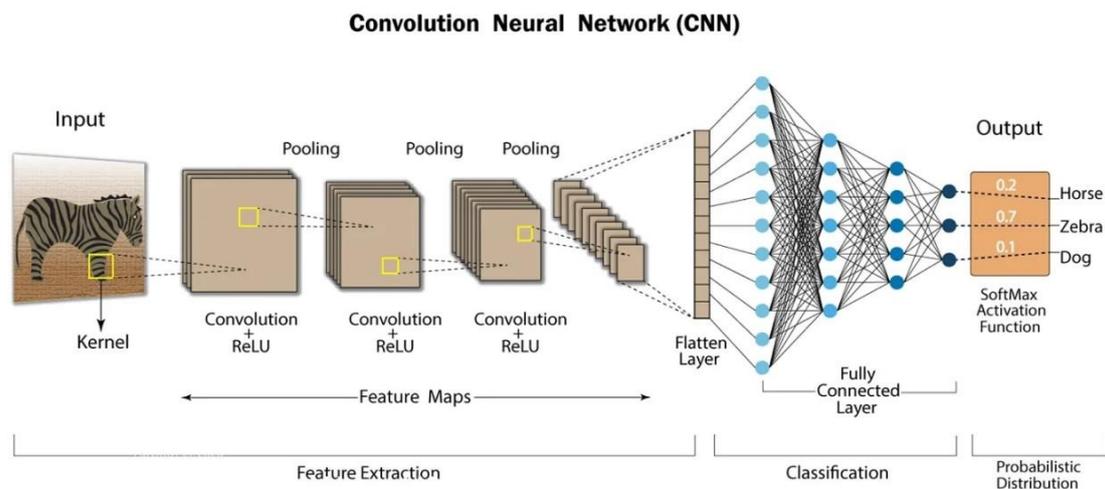


Figura 13. Red neuronal convolucional (Shahriar, N. (2023, April 15). What is a convolutional neural network (CNN). LinkedIn)

1.5.2 Funciones de activación y su importancia

Las funciones de activación son importantes en el funcionamiento de las redes neuronales debido a que cada neurona emplea una función de activación para determinar su salida basándose en la entrada que recibe.

La elección de la función de activación puede tener un impacto considerable en la capacidad de la red para aprender y generalizar a nuevos datos. Algunas funciones de activación comunes incluyen:

1. **Función Sigmoide:** Se caracteriza por su forma de “S” con un rango de salida entre 0 y 1. Se utiliza comúnmente en problemas de clasificación binaria. Su función se expresa como $f(x) = \frac{1}{(1+\exp(-x))}$

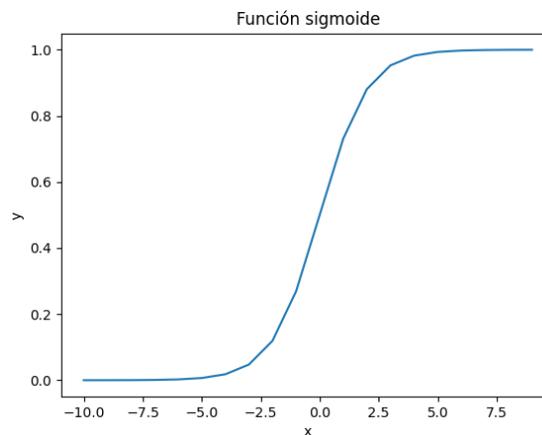


Figura 14. Representación de la función 'sigmoid' (OpenWebinars)

2. **Función ReLU:** Su expresión matemática es $f(x) = \max(0, x)$, lo que implica que la salida es 0 para valores negativos y lineal para valores positivos. Es la función más empleada en las redes neuronales.

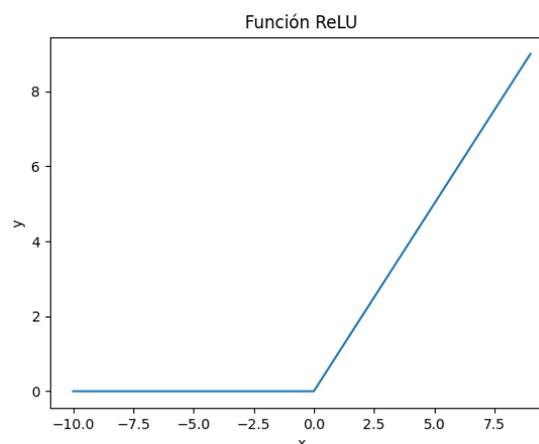


Figura 15. Representación de la función 'relu' (OpenWebinars)

1.5.3 Uso de redes neuronales para nuestro BSPM

Las redes neuronales son esenciales por su capacidad para manejar datos y ofrecer resultados claros y comprensibles en la investigación y en la práctica clínica de la electrofisiología cardíaca.

El proceso de entrenamiento de estas redes ajusta los parámetros del modelo, conocidos como “pesos”, para transformar eficazmente las entradas, señales BSPM, en salidas, resultados o predicciones.

Las redes neuronales convolucionales (CNN) son una arquitectura clave, que pueden detectar características con ubicaciones variables dentro de una imagen empleando filtros que abarcan todas las dimensiones de las señales de entrada. En el contexto del BSPM, estas arquitecturas

pueden aprovechar la información espacial al ordenar los electrodos en forma tensorial. Sin embargo, no capturan completamente las distancias físicas entre electrodos en su ordenamiento.

Las redes neuronales aprenden características de los datos sin necesidad de etiquetas explícitas. Esto ayuda a reducir la dimensionalidad del BSPM, haciéndolo más interpretable en un contexto clínico o de investigación. Además, pueden adaptar las grabaciones a los requisitos de entrada de la técnica.

Los modelos de aprendizaje automático ofrecen una oportunidad para utilizar mapas BSP como entrada y generar diagnósticos clínicamente útiles. Su flexibilidad permite desarrollar modelos específicos para abordar preguntas clínicas, como la detección de enfermedades o la evaluación de medidas fisiológicas relevantes para el diagnóstico y tratamiento del paciente. Con suficientes datos de entrenamiento, estos modelos pueden ampliar el uso de BSPM más allá de la fisiopatología cardíaca.

1.6 Estudios recientes en evaluación cardíaca

Un estudio reciente, realizado en enero de 2024 por investigadores de la Escuela de Medicina Icahn en Mount Sinai, y referenciado por el equipo editorial de HospiMedica, destaca el uso de inteligencia artificial (IA) para mejorar la evaluación del ventrículo derecho del corazón. Mediante un modelo de ECG de aprendizaje profundo (DL-ECG) entrenado con datos de ECG de 12 derivaciones y mediciones de resonancia magnética cardíaca (MRI), los investigadores lograron predecir eficazmente problemas cardíacos del lado derecho. Los resultados, validados en múltiples centros de salud, demuestran la promesa de esta tecnología en la detección temprana y el tratamiento eficaz de enfermedades cardíacas, especialmente relevantes para pacientes con cardiopatías congénitas. Aunque la IA en el análisis de ECG está en sus primeras etapas y no pretende reemplazar métodos diagnósticos avanzados, estos hallazgos representan un avance significativo en el campo médico (HospiMedica. (2024, enero). Análisis de ECG habilitado por IA predice eficazmente problemas cardíacos del lado derecho. <https://www.hospimedica.es/cuidados-criticos/articulos/294799891/analisis-de-ecg-habilitado-por-ia-predice-eficazmente-problemas-cardiacos-del-lado-derecho.html>).

Rodrigo et al. (2020) discutieron la posibilidad de eliminar la modalidad CT/MRI en el procedimiento ECGI, lo cual podría simplificar la integración del ECGI en la práctica clínica al reducir la necesidad de imágenes preprocedimentales. Este enfoque podría mejorar la precisión y eficiencia en la localización de la actividad eléctrica del corazón y facilitar el tratamiento de patologías como la fibrilación auricular (FA) (Rodrigo, M., Climent, A. M., Liberos, A., & Millet, J. (2021). Non-invasive ECG imaging in atrial fibrillation: State of the art and future challenges. *Frontiers in Physiology*, 12, 653013. <https://www.frontiersin.org/articles/10.3389/fphys.2021.653013/full>).

Estudios anteriores, como los de Han et al. (2011, 2013), demostraron la utilidad del ECGI en la imagen tridimensional de la secuencia de activación cardíaca durante la estimulación y la taquicardia ventricular. Estas investigaciones destacaron la capacidad del ECGI para proporcionar un mapeo preciso y no invasivo de las arritmias ventriculares, demostrando su potencial para mejorar la detección y el tratamiento de estas condiciones (Han, F. T., & Haqqani, H. M. (2015). Noninvasive electrocardiographic imaging in arrhythmia. *Current Cardiology Reports*, 17(6), 616. <https://doi.org/10.1007/s11886-015-0616-6>).



El presente estudio se diferencia de los anteriores al centrarse en el desarrollo de redes neuronales específicas para la estimación de características geométricas auriculares a partir de señales BSPM. A diferencia de los estudios previos que han utilizado técnicas de imagen como MRI o CT para mejorar la calidad del ECGI, este enfoque busca ofrecer una solución menos invasiva y más accesible, eliminando la necesidad de técnicas de imagen costosas y complejas. La aplicación de redes neuronales convolucionales (CNN) y otras arquitecturas avanzadas para procesar señales BSPM representa un avance significativo en la electrofisiología cardíaca, proporcionando una herramienta potencialmente poderosa para el diagnóstico y tratamiento de enfermedades cardíacas.



Capítulo 2. Objetivos

El objetivo del Trabajo de Fin de Grado (TFG) consiste en analizar y evaluar técnicas de procesamiento de señales cardíacas para estimar la posición del corazón a partir de señales electrocardiográficas de superficie. Este análisis se centra en la revisión exhaustiva de las técnicas de procesamiento de señales aplicadas específicamente en la estimación de la posición del corazón.

Se plantea también la evaluación de la eficacia y precisión de estas técnicas, utilizando datos de electrocardiogramas (ECG) y otras modalidades de imagen cardíaca. Para ello, se desarrollarán algoritmos destinados a mejorar dicha estimación, focalizándose en el diseño y desarrollo de técnicas de procesamiento de señales auriculares regulares, tales como latidos sinusales y ectópicos.

Además, se llevará a cabo una comparación y validación de los algoritmos propuestos, contrastándolos con los métodos estándar de estimación de posición cardíacas. Esta validación se realizará con datos de ECG y otras modalidades de imagen cardíaca, para asegurar la precisión y robustez de los algoritmos desarrollados.

Este estudio busca contribuir al avance tanto de la Ingeniería de Telecomunicaciones como de la Medicina Cardiovascular, proporcionando avances significativos en la estimación precisa de la posición del corazón, lo cual puede tener importantes aplicaciones en el diagnóstico y tratamiento de condiciones cardíacas.

Como línea futura, se sugiere la posibilidad de aplicar la metodología desarrollada para mejorar la calidad de la estimación en casos de fibrilación auricular (FA). Aunque este estudio no aborda directamente la FA, se considera un área prometedora para futuras investigaciones.

Capítulo 3. Metodología

La imagen electrocardiográfica (ECGI) permite estimar la actividad eléctrica en la superficie cardíaca de manera no invasiva. Los sistemas actuales de ECGI requieren de técnicas de imagen como resonancia magnética o tomografía axial computerizada para la obtención de las geometrías cardíacas sobre las que calcular las señales. La necesidad de técnicas de imagen encarece y alarga los procedimientos de ECGI, haciendo necesarias alternativas para estimar la posición del corazón de los pacientes por otros métodos. Por ello, este trabajo de fin de grado pretende desarrollar e implementar redes neuronales para estimar características geométricas auriculares, como la posición respecto al torso, a partir de señales electrocardiográficas de mapeo de superficie (BSPM).

Asimismo, este proyecto pretende mejorar la precisión en las soluciones del ECGI. Dado que se trata de un problema inverso, diversos tipos de ruido, tanto en la señal como en la geometría, pueden interferir con los resultados y llevar a errores en el diagnóstico. Por este motivo, la mejora en la estimación geométrica permite obtener un diagnóstico más preciso de patologías cardíacas auriculares y con ello un mejor tratamiento.

Para conseguir el objetivo propuesto, se ha utilizado una base de datos de 16.800 simulaciones matemáticas cardíacas con una elevada variabilidad de propagaciones eléctricas (sinusales y ectópicas), y de geometrías de corazón y torso obtenidas a partir de un Shape Model estadístico. Con los BSPM resultantes, se han entrenado distintas arquitecturas de red neuronal para identificar y extraer información relevante sobre la ubicación de las aurículas cardíacas y, finalmente, se ha evaluado el error cometido con una serie de métricas.

Con este trabajo se pretende avanzar en el campo del diagnóstico no invasivo de patologías cardíacas auriculares, reduciendo la necesidad de pruebas médicas invasivas y costosas, al tiempo que se aumenta la rapidez y precisión en la detección.

3.1 Base de Datos

Se ha usado una base de datos que consta de 16.800 señales, cuyo contenido es el siguiente:

- Electrogramas (EGM) generados a partir de simulaciones.
- Mapas de Superficie del Potencial Bioeléctrico (BSPM) calculados mediante el forward problem.
- Electrocardiografía de Imágenes (ECGi) derivada del problema inverso.

Cada simulación tiene asociado un torso diferente (16.800 en total), con variabilidad de sexo, 50% femenino y 50% masculino. El índice de masa corporal (IMC) promedio de la base de datos es de 30.29 ± 5.22 . Además, respecto a la geometría del corazón, se dispone de 42 geometrías auriculares obtenidas de pacientes reales que han sido asignadas homogéneamente entre los torsos, y se han desplazado y rotado de manera aleatoria dentro de unos rangos fisiológicos. Estos rangos se corresponden con desplazamientos en los ejes X, Y, Z de ± 50 mm y rotaciones de \pm

20° en X, Z y de $\pm 45^\circ$ en Y por ser el eje en el que el corazón varía un mayor ángulo debido a la respiración (PubMed, 2022) [<https://pubmed.ncbi.nlm.nih.gov/35065409/>].

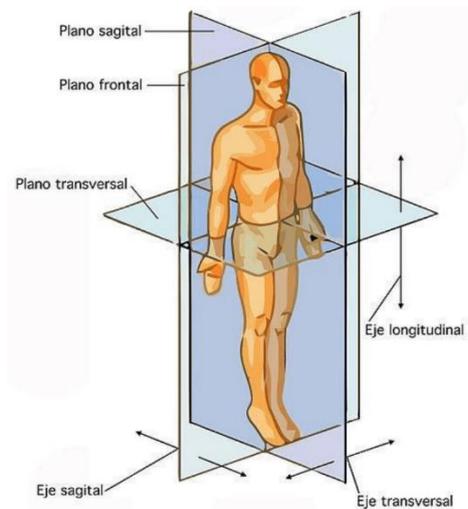


Figura 16. Planos anatómicos (Estudiante Médico. (2017, noviembre 19). Planos anatómicos - Generalidades de anatomía. <https://estudiantemedico.tumblr.com/post/167986512330/planos-anat%C3%B3micos-generalidades-de-anatomia>).

La imagen ilustra los planos anatómicos estándar: el plano sagital (eje Y), que divide el cuerpo en mitades derecha e izquierda; el plano frontal (eje X), que lo divide en partes anterior y posterior; y el plano transversal (eje Z), que lo divide en superior e inferior.

A cada geometría auricular le corresponden 400 simulaciones, con sus respectivos puntos de estimulación, de manera que todas las geometrías contemplan una estimulación en el nodo sinusal (SR), un ectópico común (09) como referencia localizada en la pared posterior de la aurícula izquierda y 398 nodos de las aurículas distribuidas entre 15 regiones que actúan como focos ectópicos. Salvo las dos primeras estimulaciones, el resto se seleccionan aleatoriamente entre todos los nodos geométricos disponibles.

Las carpetas están organizadas de la siguiente manera, tomando como ejemplo la carpeta F01, que indica el uso de la geometría 1, y todas las simulaciones dentro de esa carpeta comparten la misma geometría, aunque el resto de los parámetros varían en cada simulación.

- La carpeta SR señala que la simulación se ha estimulado en el nodo sinusal.
- La carpeta ectopic09 indica que la simulación se ha estimulado en el ectópico común.
- El resto de las simulaciones, 398 en total, se han simulado en puntos aleatorios de las distintas regiones de la aurícula.

Respecto a la duración de la onda P, que representa la despolarización auricular, se selecciona de forma aleatoria duraciones entre los 90 y los 150 ms, garantizando que la duración varíe en cada caso.

Para validar el desempeño de la metodología en pacientes reales, se han utilizado señales BSP, concretamente ondas P, de pacientes que presentaban episodios de FA y que fueron registrados en ritmo sinusal, o pacing en su defecto, previamente a una intervención de ablación en el hospital Clinic de Barcelona. Dichas intervenciones fueron realizadas cumpliendo con los requisitos de su comité ético para el tratamiento de los datos. Las señales obtenidas, junto con las geometrías de aurículas y torsos, han sido cedidas por la spin-off del laboratorio ITACA-COR, Corify Care S.L.

3.2 Software utilizado para realización del proyecto

Para el desarrollo y entrenamiento de las redes neuronales, se ha empleado Spyder con Python v3.9, facilitando la gestión y preparación de los archivos Python necesarios. Adicionalmente, se ha utilizado el software de Matlab R2022b para la obtención y análisis de métricas críticas. Se utilizó específicamente para la visualización de resultados, mediante gráficos y diagramas de cajas y bigotes, permitiendo la representación del torso con los electrodos, la predicción de la posición del corazón en comparación con su ubicación real, y el cálculo del error cuadrático medio en los ejes X, Y y Z.

3.3 Librerías

Se ha trabajado con diversas librerías de Python, cada una con un propósito específico para facilitar el análisis y modelado de datos. A continuación, se describen brevemente las principales librerías empleadas:

Sys

Permite acceder a variables y funciones del intérprete de Python, como añadir directorios al path de búsqueda de módulos mediante '`sys.path.append(...)`', entre otras funciones.

NumPy

Especializada en el cálculo numérico, facilita el manejo de grandes volúmenes de datos mediante objetos 'array', que permiten representaciones y procesamientos multidimensionales más eficientes que las listas de Python.

Keras

Biblioteca de alto nivel para la creación rápida de redes neuronales, que simplifica el diseño de modelos de deep learning y se ejecuta sobre backends como TensorFlow.

Matplotlib

Crea gráficos de datos en 2D, además de crear y personalizar histogramas, diagramas de barras, diagramas de caja y bigotes, entre otros, facilitando la visualización de los datos.

Pandas

Ofrece herramientas para el manejo y análisis de datos, incluyendo la lectura y escritura de ficheros CSV, Excel y bases de datos SQL, y proporciona estructuras como Series, DataFrame y Panel basadas en arrays de NumPy.

Importlib

Permite la importación dinámica de módulos en tiempo de ejecución, facilitando la carga de módulos según sea necesario.

Mat73

Se utiliza para leer archivos ‘.mat’ creados con versiones de Matlab 7.3 y superiores, en formato HDF5, integrando datos provenientes de Matlab.

TensorFlow

Biblioteca de código abierto para desarrollar y entrenar modelos de Machine Learning, ofreciendo herramientas avanzadas para construir redes neuronales complejas.

Scipy

Proporciona módulos para estadísticas, optimización, procesamiento de señales e imágenes, entre otros, complementando a NumPy con rutinas numéricas eficientes.

Glob

Facilita la búsqueda de archivos y directorios que coinciden con patrones especificados mediante comodines, ayudando en la manipulación y acceso a conjuntos de archivos.

3.4 Hardware utilizado en el servidor Titan

El servidor Titan utilizado cuenta con un procesador AMD Ryzen 9 5950X, 64GB de memoria RAM, una GPU PNY RTX A6000, y varias unidades de almacenamiento SSD y HDD, todo instalado en una caja SilverStone Kublai KL07. Se detallan el resto de las especificaciones en la siguiente tabla:

Características	
CPU	AMD Ryzen 9 5950X (3.4GHz, 16 núcleos, 32 hilos)
Disipador CPU	DeepCool Assassin III
RAM	64GB Team Group Delta RGB DDR4 a 3600MHz
GPU	PNY RTX A6000 con 48GB ECC
Placa base	Gigabyte Aorus X570 Master
SSD1	Corsair MP600 CORE de 2TB M.2 NVMe PCIe Gen 4 x4
SSD2	TOSHIBA THNSNH128GCST 128GB
HDD	TOSHIBA MG03ACA200 2TB
Interfaz de red	2 NICs (1 en uso)
Caja	SilverStone Kublai KL07 USB 3.0

Tabla 1. Especificaciones del hardware utilizado

3.5 Proceso de preparación para el entrenamiento de las redes

En el contexto del desarrollo de un modelo de red neuronal destinado a predecir la posición del corazón a partir de señales BSPM, se han implementado tres archivos para estructurar la configuración, preparación y evaluación del proceso de entrenamiento. Cada uno de estos archivos cumple un papel específico, desde la transformación inicial de los datos hasta la optimización y evaluación de los modelos entrenados.

3.5.1 *DataGenerator*

Este archivo Python prepara y transforma los datos de entrenamiento. Importa funciones para convertir señales BSPM en formatos adecuados para el análisis. La clase ‘DataGenerator2’ procesa y normaliza los datos BSPM, filtrando las señales relevantes y realizando interpolaciones para procesar eficientemente grandes cantidades de datos, asegurando que todos los datos estén listos para el entrenamiento.

Para cada identificador, primero se cargan los archivos BSPM desde un fichero ‘BSPM.mat’ correspondiente al identificador actual ID. Luego, se obtienen los datos del corazón de un fichero con terminación ‘*_data.txt’ y se extrae la posición del corazón. Finalmente, se cargan los datos del torso desde un archivo con terminación ‘*_Torso.mat’.

El proceso continúa con la extracción y normalización de las señales BSPM. Luego, se filtran las coordenadas de acuerdo con los valores de los electrodos (leads) funcionales y se seleccionan las BSPMs relevantes para el torso. Las señales se interpolan a una longitud fija de 76 puntos. Finalmente, las BSPMs procesadas y la posición del corazón se normalizan y ajustan a las dimensiones necesarias, asignándolas a las matrices X e Y, listas para el entrenamiento.

3.5.2 *ArquitecturasRed*

Este archivo define y configura varios modelos de redes neuronales utilizando TensorFlow y Keras. Evalúa diferentes arquitecturas y técnicas de regularización para identificar la configuración más eficiente. Los modelos desde ‘build_model_1’ hasta ‘build_model_6’, varían en capas convolucionales y densas, usando técnicas como Dropout y BatchNormalization para prevenir el sobreajuste y estabilizar el entrenamiento. Las capas convolucionales 3D son cruciales para extraer características espaciales y temporales de las señales BSPM. Además, se emplean funciones de pérdida personalizadas y el optimizador Adam para evaluar y comparar el rendimiento de los modelos.

Los modelos se evaluaron utilizando dos métricas principales: el error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE).

3.5.2.1 *Error absoluto medio (MAE)*

El error absoluto medio (MAE) es una métrica utilizada para evaluar la precisión de las predicciones realizadas por una red neuronal. Esta métrica mide la diferencia entre los valores predichos por el modelo y los valores reales observados. Para evitar que los errores positivos se cancelen con los negativos, se utiliza el valor absoluto de estas diferencias. Luego, se calcula el promedio de estos valores absolutos para obtener una medida del error global en todas las observaciones. Esto proporciona una visión clara de cuánto, en promedio, se desvían las predicciones del modelo respecto a los valores reales. La fórmula es la siguiente:

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

3.5.2.2 Raíz del error cuadrático medio (RMSE)

La raíz del error cuadrático medio (RMSE) es una métrica que se utiliza para evaluar la precisión de las predicciones de una red neuronal. Al igual que en el caso del error medio cuadrado (MSE), el RMSE evita que los errores positivos se cancelen con los negativos elevando al cuadrado las diferencias entre los valores predichos y los valores reales. Sin embargo, el RMSE mejora la interpretabilidad del MSE al tomar la raíz cuadrada de este valor, devolviendo el error a las unidades originales de los datos. Esto permite una evaluación más intuitiva de la precisión del modelo, ya que un valor de RMSE más cercano a cero indica una mayor precisión en las predicciones de la red neuronal. La fórmula es la siguiente:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}}$$

3.5.3 ReadData

Este archivo coordina la preparación y ejecución del entrenamiento del modelo. Selecciona tanto el generador de datos como la arquitectura del modelo, y organiza los datos en conjuntos de entrenamiento, validación y prueba. También establece parámetros clave como el tamaño del batch, el número de épocas y la tasa de aprendizaje. Al finalizar el entrenamiento, guarda el modelo y su historial de rendimiento, proporcionando un registro detallado de los resultados.

Se definen las listas de corazones para los conjuntos de entrenamiento, validación y prueba, distribuyendo el 70% para entrenamiento, el 15% para validación y el 15% restante para prueba. La distribución es la siguiente:

- Entrenamiento: F01 a F15 (mujeres) y M22 a M38 (hombres).
- Validación: F16 a F18 (mujeres) y M39 a M42 (hombres).
- Prueba: F19 a F21 (mujeres) y M43 a M46 (hombres).



Figura 17. Definición del conjunto de datos

3.6 Prueba para test

En la fase de evaluación, se realizan pruebas sistemáticas para verificar el rendimiento y precisión del modelo, asegurando que cumpla con los estándares necesarios para su aplicación práctica.



3.6.1 Test and Metrics BSPM

Durante la evaluación del modelo se cargan los datos de prueba y el modelo entrenado, y se realiza la conversión y normalización de las señales BSPM a un formato bidimensional para la predicción. Se generan predicciones y se calculan métricas clave, el error cuadrático medio (RMSE) y el error absoluto medio (MAE) mencionados previamente. Estos resultados se almacenan en un archivo '.mat' para su análisis en MATLAB, donde se generan gráficos comparativos, como boxplots y visualizaciones de la posición real frente a la predicha, facilitando así una evaluación detallada del desempeño del modelo en simulaciones, permitiendo entender su capacidad para predecir con precisión la posición del corazón.

3.6.2 Test Patients

Este archivo gestiona la carga y el procesamiento de datos de pacientes, ajustando configuraciones y convirtiendo las señales BSPM a una representación bidimensional adecuada para el análisis. Además, se realiza la interpolación y normalización de las señales, visualiza los resultados y aplica un modelo entrenado para obtener predicciones en 2D. Los resultados y las predicciones se almacenan en archivos '.mat', facilitando su evaluación y análisis. En esta fase, el enfoque está en la verificación del desempeño del modelo con datos reales de pacientes, permitiendo la comparación de las predicciones del modelo con la posición real del corazón y calculando métricas de error específicas. Este proceso asegura que el modelo no solo funcione correctamente, sino que también sea preciso en un contexto clínico real.

Capítulo 4. Desarrollo y resultados del trabajo

4.1 Modelos entrenados

Durante el desarrollo de modelos de redes neuronales para la predicción de la posición del corazón a partir de señales BSPM, se llevaron a cabo una serie de entrenamientos con diferentes configuraciones para identificar la mejor estrategia mediante el método GridSearch. Estos entrenamientos variaron principalmente en el número de neuronas y en el tamaño del lote (batch size). A pesar de probar varias tasas de aprendizaje (learning rate), se observó que la red no mostraba mejoras significativas, por lo que se decidió mantener una tasa de aprendizaje constante de 0.001.

Entre las arquitecturas evaluadas, la definida en 'build_model_4' demostró ser efectiva. Esta arquitectura, una red neuronal convencional 3D, procesa datos volumétricos comenzando con una capa de entrada adaptada a dimensiones específicas. Utiliza dos bloques de capas convolucionales 3D, seguidas de normalización y activación ReLU, para extraer características y reducir progresivamente las dimensiones espaciales mediante agrupación máxima 3D. Después, se aplican más capas convolucionales, aplanamiento y una capa de salida de activación LeakyReLU, para obtener las predicciones finales. El modelo entrenado con el optimizador Adam y evaluado usando MSE y MAE, mostró mejores resultados.

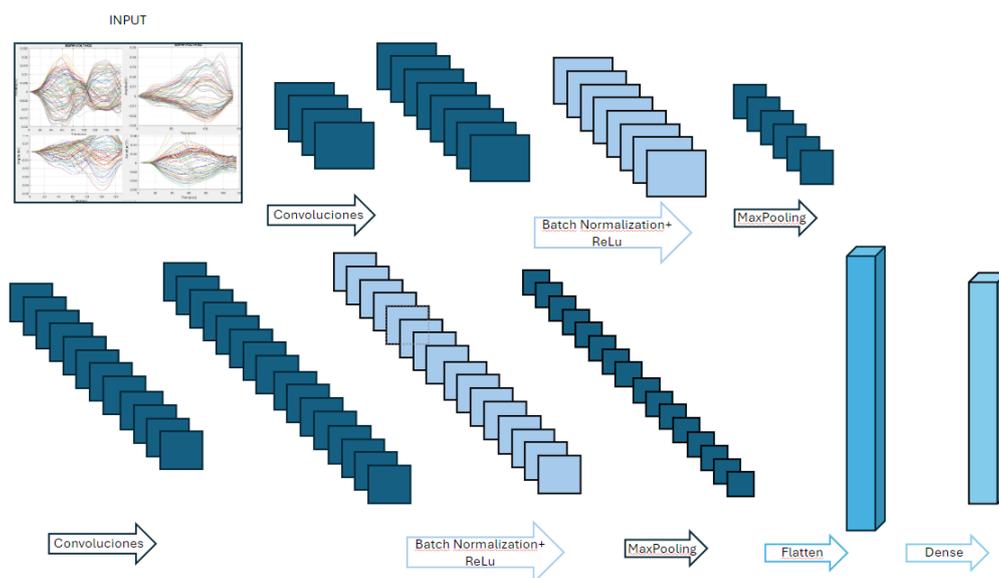


Figura 18. Esquema de la arquitectura empleada

Además, se exploró la incorporación de capas de abandono (dropout) mediante la arquitectura 'build_modelo_6'; sin embargo, esto no resultó en mejoras adicionales en el rendimiento del modelo.

A continuación, se presentan los resultados de las pruebas realizadas con las distintas configuraciones:

Neuronas	Batch size	Epochs	learning	val_loss did not improve from	epoch	loss	mae	val_loss	val_mae
10	40	100	0.001	0.00363	74	0.003	0.0424	0.0039	0.048
15	35	100	0.001	0.00318	71	0.0023	0.0378	0.009	0.0696
15	50	100	0.001	0.00338	81	0.0024	0.0388	0.0041	0.0498
20	30	100	0.001	0.00266	78	0.002	0.035	0.0031	0.043
20	35	100	0.001	0.00274	92	0.0019	0.0339	0.0038	0.0465
20	40	100	0.001	0.00283	75	0.0021	0.0355	0.0031	0.0426
25	30	100	0.001	0.00265	100	0.0016	0.0317	0.0033	0.0432
25	35	100	0.001	0.00323	57	0.0024	0.0383	0.0048	0.0548
25	40	100	0.001	0.00269	94	0.0018	0.0339	0.0035	0.0463
30	30	100	0.001	0.00316	63	0.002	0.0354	0.003	0.0422

Tabla 2. Modelos con la arquitectura 'build_model_4'

Neuronas	Batch size	Epochs	learning	val_loss did not improve from	epoch	loss	mae	val_loss	val_mae
15	40	100	0.001	0.00489	40	0.003	0.0452	0.0058	0.0578
20	30	100	0.001	0.00678	25	0.0041	0.0497	0.0069	0.0616
20	35	100	0.001	0.00405	89	0.002	0.0354	0.0056	0.0583

Tabla 3. Modelos con la arquitectura 'build_model_6'

Finalmente, el modelo con 25 neuronas, un tamaño de lote de 30, 100 épocas y una tasa de aprendizaje de 0.001 fue el que mostró el mejor rendimiento. Los resultados obtenidos incluyeron una pérdida de validación mínima (val_loss not improve) de 0.00265, una pérdida en los datos de entrenamiento (loss) de 0.0016, un error absoluto medio en los datos de entrenamiento (mae) de 0.0317, una pérdida en los datos de validación (val_loss) de 0.0033 y un error absoluto medio en los datos de validación (val_mae) de 0.0432.

4.2 Resultados en simulaciones

Una vez entrenados los modelos, los resultados de las 2800 simulaciones se analizan con MATLAB. Inicialmente, se carga el modelo previamente entrenado desde un archivo '.mat' específico y se importan las métricas de rendimiento, que incluyen el error cuadrático medio (RMSE), el error absoluto medio (MAE) y las coordenadas predichas y reales de las posiciones del corazón.

Estos datos se utilizan para generar gráficos de caja (boxplot) que visualizan la distribución de RMSE y MAE, proporcionando una representación clara de la variabilidad y tendencias en los errores del modelo. Además, se realiza una comparación detallada mediante gráficos tridimensionales que contrastan las posiciones predichas con las reales del corazón, facilitando la evaluación visual de la precisión del modelo. Esta representación visual se complementa con un modelo tridimensional del torso, donde se destaca una predicción específica junto con su correspondiente posición real, lo que permite identificar discrepancias y orientar futuras mejoras en la precisión del modelo de predicción de posición cardíaca.

Los análisis muestran un error absoluto medio (MAE) de 3.1350 mm.

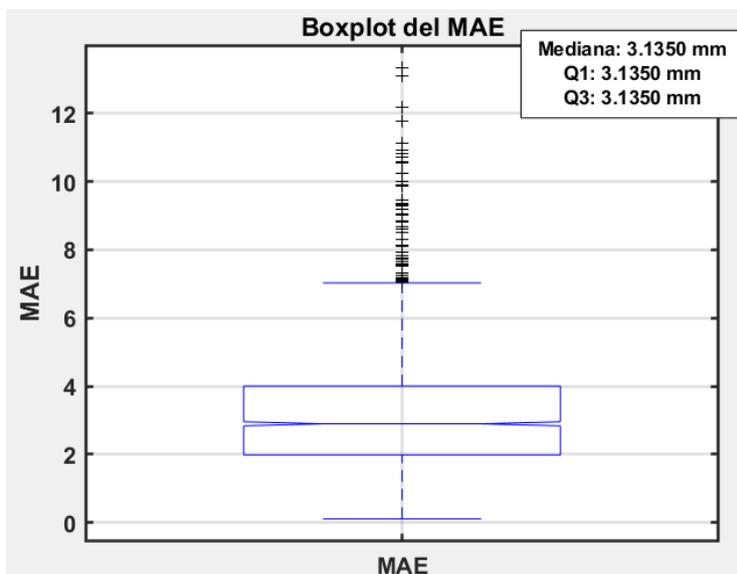


Figura 19. Boxplot del MAE en simulaciones (Matlab)

Y un error cuadrático medio (RMSE) de 4.0904 mm.

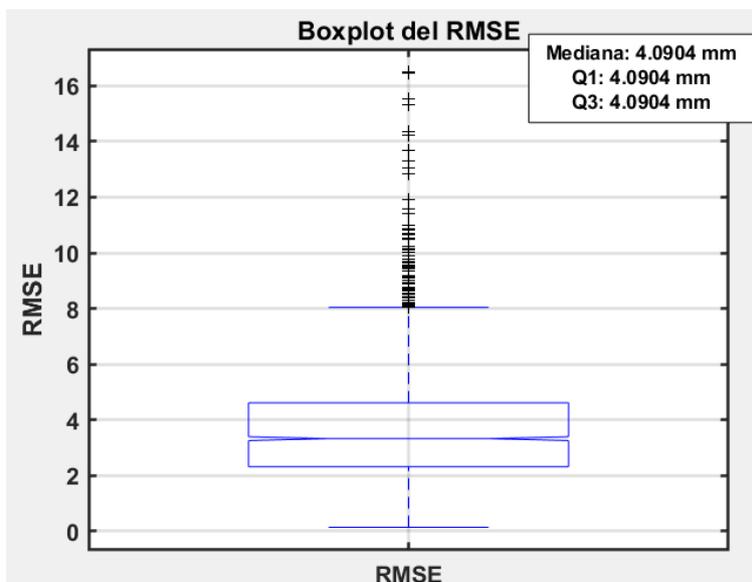


Figura 20. Boxplot del RMSE en simulaciones (Matlab)

Al analizar el error en cada eje, se obtienen los siguientes resultados: en el eje X, el RMSE es de 3.8648 mm, en el eje Y es de 3.7473 mm, y en el eje Z es de 4.6061 mm.

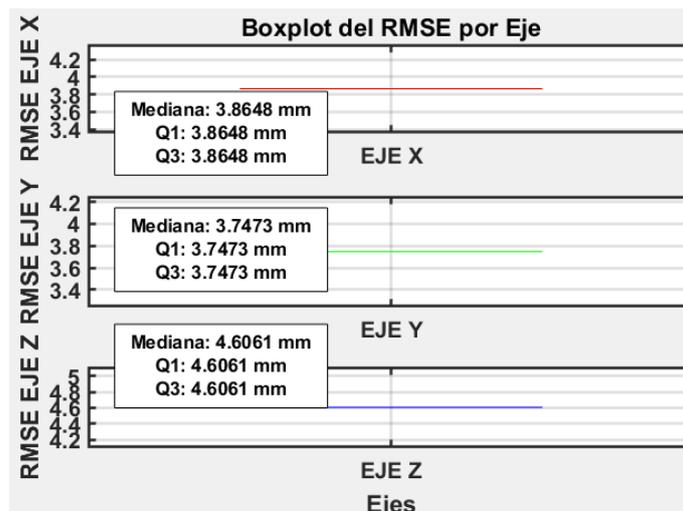


Figura 21. Boxplot del RMSE en simulaciones en cada eje (Matlab)

En cuanto al error medio absoluto (MAE), se registra un error de 3.0743 mm en el eje X, 2.8627 mm en el eje Y y 3.4681 mm en el eje Z.

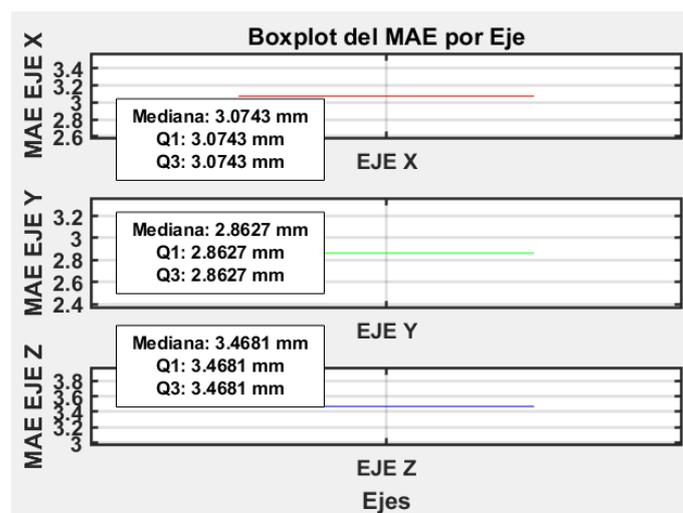


Figura 22. Boxplot del MAE en simulaciones en cada eje (Matlab)

Se han analizado diversos torsos de distintos pacientes y simulaciones, obteniendo resultados que reflejan la precisión de la predicción en relación con la ubicación real del corazón. A continuación, se detallan algunos casos.

Al cargar el torso de la carpeta ‘F15_simulation_1_20230815_SR_folder’, correspondiente a una simulación estimulada en el nodo sinusal, se observa el siguiente resultado para uno de los puntos críticos:

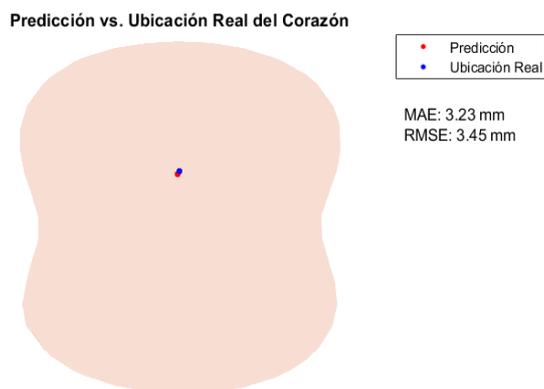


Figura 23. Torso correspondiente al archivo 6_Torso.mat

Cargando el torso de una simulación ectópica de la carpeta ‘F03_simulation_10_20230803_ectopic02_folder’, se obtiene el siguiente resultado:

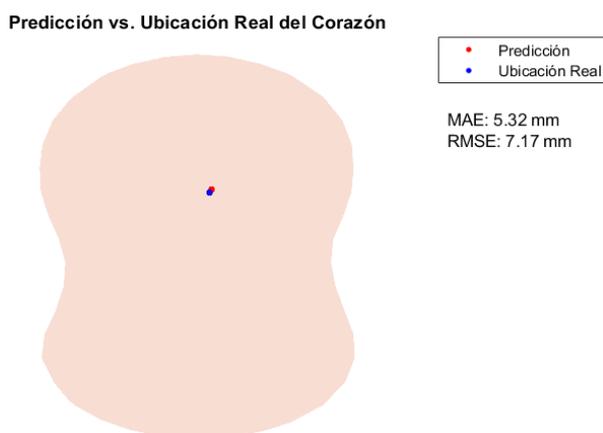


Figura 24. Torso correspondiente al archivo 337_Torso.mat

Otro análisis de una simulación ectópica, correspondiente a la carpeta ‘F10_simulation_18_20230810_ectopic02_folder’, muestra lo siguiente:

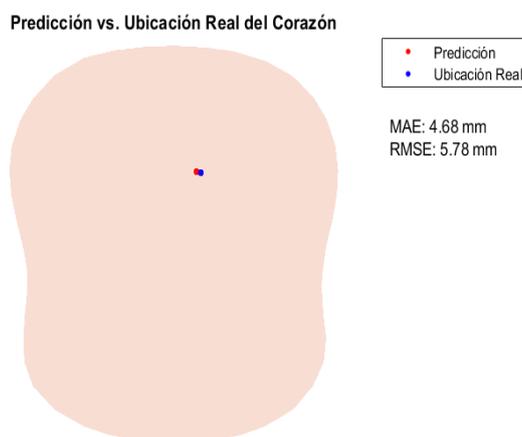


Figura 25. Torso correspondiente al archivo 613_Torso.mat

Al seleccionar los puntos con mayores errores globales, se identifican aquellos con los valores máximos de MAE y RMSE:

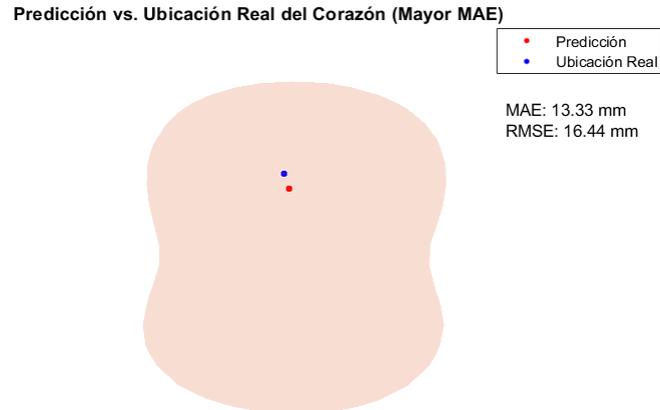


Figura 26. Mayor MAE correspondiente al torso 872_Torso.mat

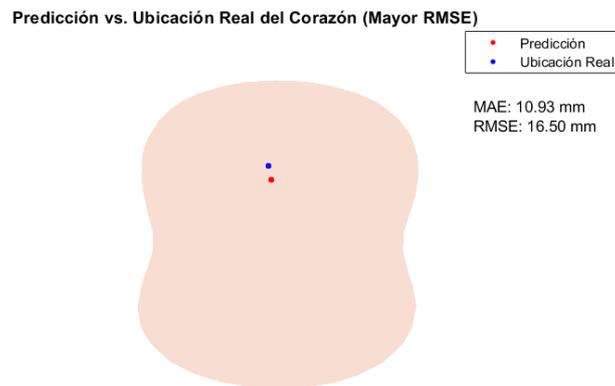


Figura 27. Mayor RMSE correspondiente al torso 872_Torso.mat

La estimación precisa de la posición del corazón tiene múltiples implicaciones significativas. En primer lugar, permite un diagnóstico más exacto de problemas cardíacos, facilitando la identificación de anomalías estructurales o funcionales del corazón. Además, contribuye a la detección temprana de enfermedades cardíacas, lo que posibilita intervenciones más rápidas y efectivas.

Desde una perspectiva investigadora, esta precisión en la estimación mejora el desarrollo de modelos predictivos para la simulación de condiciones cardíacas, lo que facilita la realización de estudios clínicos más rigurosos y con resultados más confiables.

4.3 Resultados en pacientes

Para analizar los resultados en pacientes, se utilizan los programas MATLAB y Spyder con el objetivo de cargar, procesar y analizar datos de un modelo de predicción de señales electrocardiográficas (ECGI). Este análisis evalúa la efectividad y precisión de los modelos de predicción en la localización de la actividad cardíaca basada en mediciones externas.

En primer lugar, se extraen y organizan los datos de los pacientes y las señales electrocardiográficas desde archivos '.mat'. Se selecciona y normaliza la señal de un paciente específico para su visualización, ajustando e interpolando las señales para adaptarlas a un tamaño predeterminado. Este paso asegura la coherencia de los datos al rellenar correctamente las matrices correspondientes.

Una vez normalizadas, se visualizan las señales aplicando técnicas de interpolación y restauración de imágenes para mejorar la calidad visual. Posteriormente, se cargan y prueban los modelos de predicción previamente entrenados con Keras, generando predicciones a partir de las señales procesadas. Estas predicciones se desnormalizan y los resultados se guardan en archivos '.mat' para su análisis posterior.

En MATLAB, se visualizan los datos de voltaje del BSPM y las geometrías del torso y el corazón de los pacientes, tanto en su estado original como traducido al centroide del torso. Estas visualizaciones facilitan la comparación entre las señales predichas y las señales originales, facilitando la evaluación de la precisión del modelo.

Para evaluar cuantitativamente el rendimiento del modelo, se calcula la raíz del error medio cuadrado (RMSE) entre las predicciones y las señales reales. Estos errores proporcionan una medida de la precisión del modelo, destacando las diferencias en las predicciones en los ejes X, Y y Z. Evaluando lo entrenado en pacientes reales, se obtienen los siguientes resultados:

Para el caso clínico 20220902_VENTRICLE, se obtiene un RMSE de 17.9081mm, con un error en el eje X de 26.7392mm, en el eje Y de 13.4754mm y en el eje Z de 8.0951mm. Además, la predicción obtenida es [5.6638, -10.5903, -34.4711].

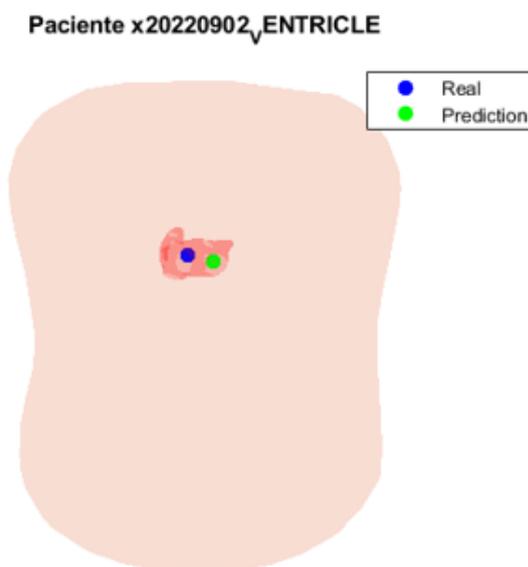


Figura 28. Predicción en el paciente 20220902_VENTRICLE

Para el caso clínico ACAMP1023OU004CI230017, se obtiene un RMSE de 18.9683mm, con un error en el eje X de 3.3323mm, en el eje Y de 7.72424mm y en el eje Z de 31.7588mm. Además, la predicción obtenida es [-9.9315, -9.4383, -37.1749].

Paciente ACAMP1023OU004CI₂30017

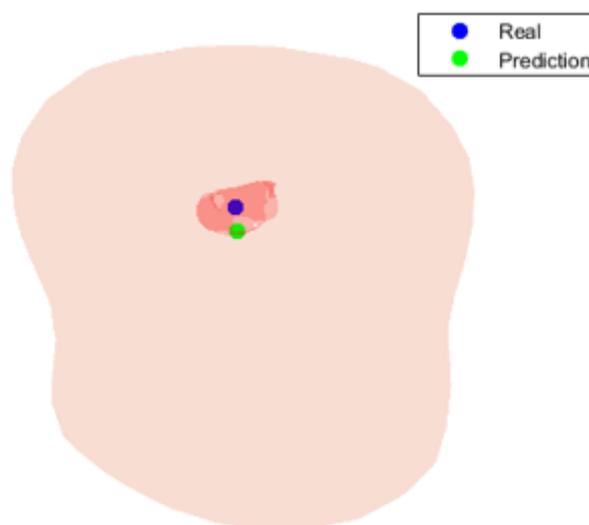


Figura 29. Predicción en el paciente ACAMP1023OU004CI230017

Para el caso clínico ACAMP1023OU004CI230030, se obtiene un RMSE de 28.934mm, con un error en el eje X de 32.4622mm, en el eje Y de 37.0469mm y en el eje Z de 9.2336mm. Además, la predicción obtenida es [20.1954, -12.2025, -23.8148].

Paciente ACAMP1023OU004CI₂30030

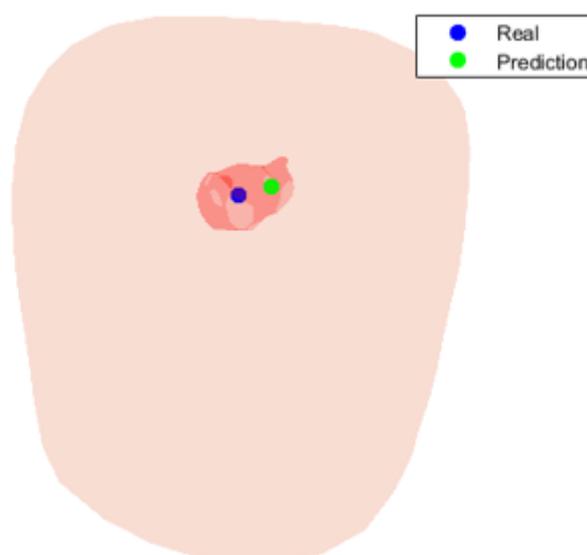


Figura 30. Predicción en el paciente ACAMP1023OU004CI230030

Para el caso clínico ACAMP1023OU004CI230051, se obtiene un RMSE de 23.9096mm, con un error en el eje X de 36.967mm, en el eje Y de 18.5659mm y en el eje Z de 1.9386mm. Además, la predicción obtenida es [12.3475, -21.3124, -38.2074].

Paciente ACAMP1023OU004CI₂30051

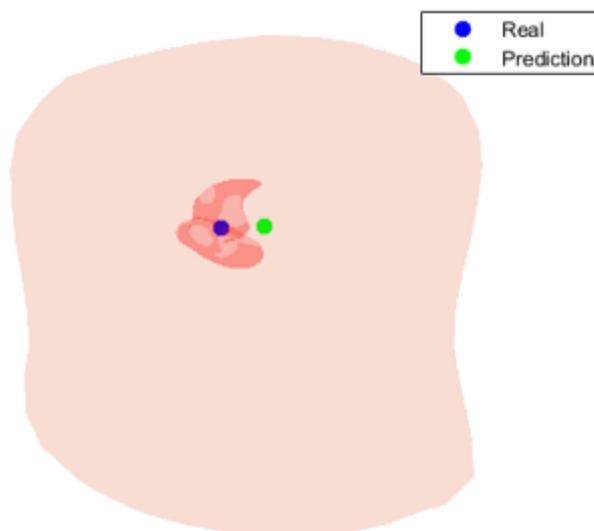


Figura 31. Predicción en el paciente ACAMP1023OU004CI230051

Para el caso clínico ACAMP1023OU004CI230060, se obtiene un RMSE de 16.1325mm, con un error en el eje X de 20.5283mm, en el eje Y de 6.6307mm y en el eje Z de 17.7594mm. Además, la predicción obtenida es [5.7639, -23.7065, -47.9450].

Paciente ACAMP1023OU004CI₂30060

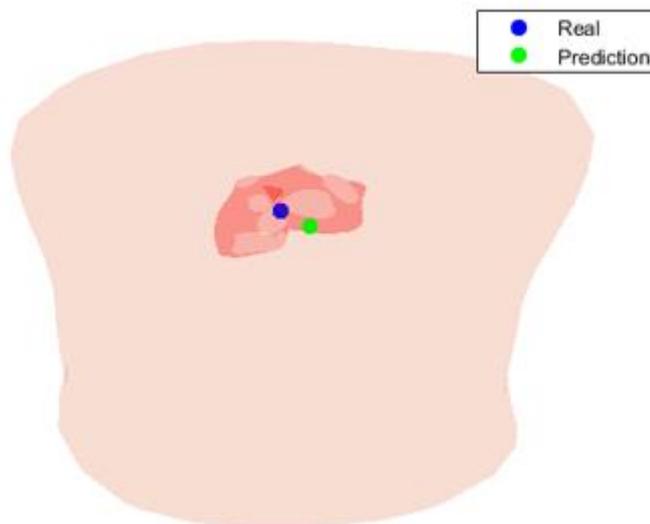


Figura 32. Predicción en el paciente ACAMP1023OU004CI230060

Mediante gráficos de caja, se analiza visualmente los errores, con un RMSE promedio de 18.9683 mm.

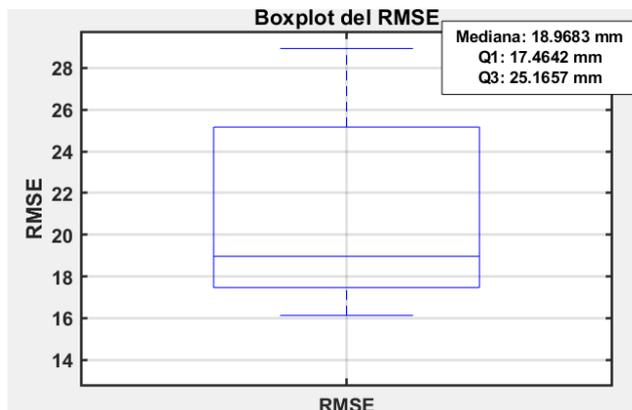


Figura 33. Boxplot del RMSE en pacientes

Para los errores en cada eje, se obtienen los siguientes resultados: un error de 26.7392 mm en el eje X.

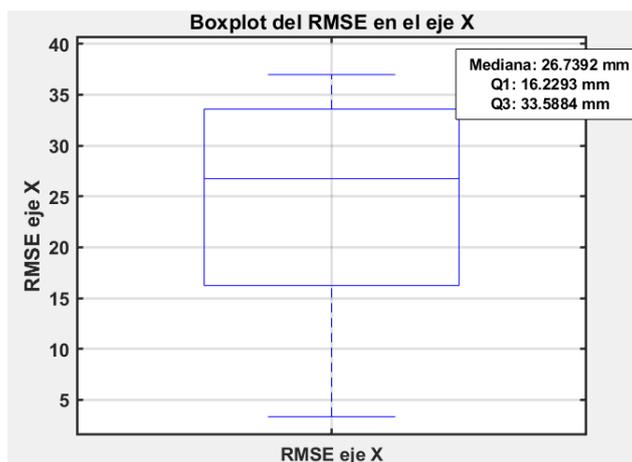


Figura 34. Boxplot del RMSE en pacientes en el eje X

Un error de 13.4754mm en el eje Y.

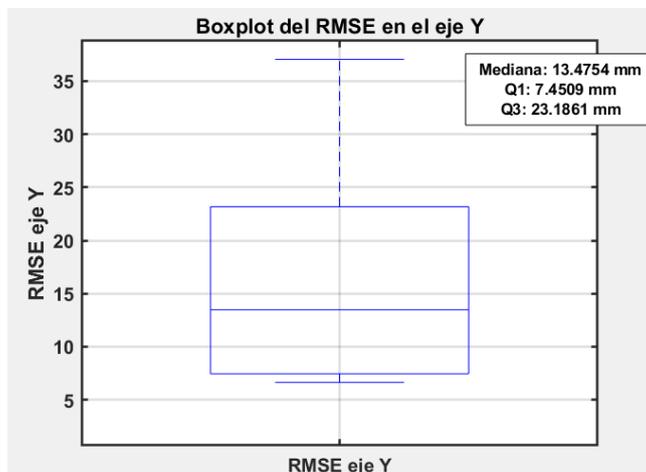


Figura 35. Boxplot del RMSE en pacientes en el eje Y

Y, por último, un error de 9.2336mm en el eje Z.

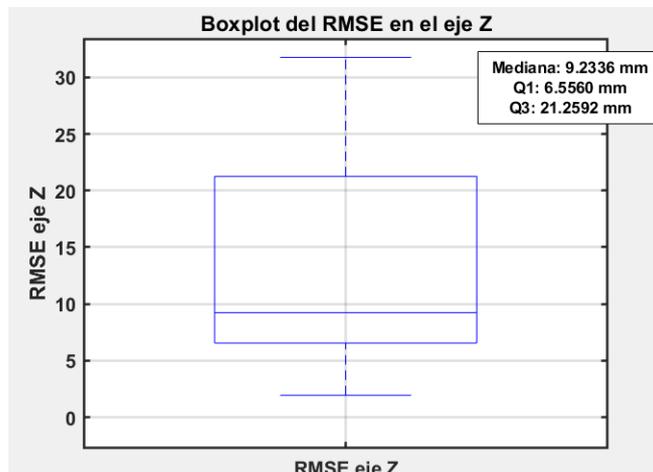


Figura 36. Boxplot del RMSE en pacientes en el eje Z

En el eje X, el error alto se atribuye a la variabilidad geométrica y limitaciones en la resolución espacial de las señales ECGI. El eje Y presenta un error causado por la variabilidad en la alineación del torso y corazón, y el ruido en las señales; mejorando el ajuste y normalización de las señales se podría reducir este error. El eje Z muestra el menor error, sugiriendo predicciones más precisas debido a la menor variabilidad en la profundidad anatómica.

4.4 Análisis de los errores obtenidos en simulaciones y en pacientes

Para facilitar la consulta de los errores obtenidos, se presentan a continuación dos tablas resumen:

	RMSE (mm)	MAE (mm)
Simulaciones	4.0904	3.1350
Pacientes	18.98	

Tabla 4. Resumen de errores obtenidos

	RMSE X (mm)			MAE (mm)		
	X	Y	Z	X	Y	Z
Simulaciones	3.8648	3.7473	4.6061	3.0743	2.8627	3.4681
Pacientes	26.739	13.745	9.2336			

Tabla 5. Resumen de errores obtenidos en cada eje

En simulaciones, los valores de RMSE y MAE son más bajos debido a la mayor precisión, resultado de la variabilidad controlada de los datos y la ausencia de ruido real. Sin embargo, el error obtenido en pacientes refleja una menor precisión en la predicción de la posición cardíaca en escenarios reales, debido a las variaciones anatómicas y al ruido en las señales.

En la estimación geométrica de pacientes el error cuadrático medio de la raíz es menor a 2 cm. Este resultado es relevante si consideramos estudios previos como en el artículo de Molero et al.



(2022) titulado "Robustness of imageless electrocardiographic imaging against uncertainty in atrial morphology and location", donde se reporta un error de 2.3 cm en la estimación geométrica de la aurícula basado en electrocardiografía sin imágenes y en el que concluye que un error de posicionamiento equivalente a 2 cm o inferior es aceptable ya que no se observan variaciones relevantes en el ECGI. El enfoque de este trabajo fin de grado utilizando redes neuronales convolucionales no solo mejora la precisión, sino que también sugiere que la metodología podría ofrecer estimaciones geométricas más confiables y potencialmente más útiles en un entorno clínico real.

Capítulo 5. Conclusiones y propuesta de trabajo futuro

En el presente trabajo se ha diseñado una metodología basada en redes neuronales capaz de estimar la ubicación del corazón a partir de los potenciales de superficie registrados en el torso, sin necesidad de recurrir a imágenes médicas.

Para ello, se ha utilizado una base de datos de 16.800 simulaciones con variabilidad de torsos, geometrías auriculares, ubicaciones relativas y patrones de propagación eléctrica con distintos niveles de ruido gaussiano, con el objetivo de aproximarse a una representación de la población real.

En cuanto a la fase de entrenamiento, se aplicó la técnica de GridSearch para optimizar la configuración del modelo. La arquitectura denominada 'build_model_4', que incorpora capas convolucionales 3D, normalización y funciones de activación ReLU y LeakyReLU, demostró ser la más precisa al estimar la ubicación del corazón a partir de las señales BSPM previamente procesadas para disponerlas de manera volumétrica. Se mantuvo una tasa de aprendizaje fija de 0.001, ya que variaciones en este parámetro no produjeron mejoras notables.

El modelo elegido destacó por su estabilidad en converger, obteniendo un valor en la función de pérdida del grupo de validación (MSE) bajo y error MAE reducido en comparación con las otras redes evaluadas, lo que indica que el tamaño del lote y la capacidad del modelo estaban bien ajustados. Curiosamente, la inclusión de capas de dropout no mejoró el rendimiento, lo que sugiere que la regularización ya era efectiva o que, en este caso, las capas de dropout no eran necesarias.

Respecto a la validación del modelo, en el grupo de test de simulaciones, el modelo alcanzó un RMSE de 4.0904 mm y un MAE de 3.1350 mm, lo que refleja su alta precisión. Sin embargo, se observó una variabilidad en la precisión entre los diferentes ejes, con el eje Z presentando mayores desafíos, posiblemente debido a la complejidad de predecir la profundidad anatómica.

En el caso de datos de pacientes reales, el RMSE promedio aumentó a 18.9683 mm, con errores significativos en todos los ejes. Este incremento en el error, en comparación con las simulaciones, podría deberse a la gran variabilidad anatómica entre pacientes y al ruido presente en las señales electrocardiográficas. Los errores más pronunciados se dieron en los ejes X e Y, siendo en este caso el eje Z el que presentó mayor precisión.

La mayor precisión observada en las simulaciones en comparación con los casos reales subraya la necesidad de mejorar la robustez del modelo frente a la variabilidad anatómica y el ruido, así como la necesidad de incrementar la complejidad de la base de datos para que represente mejor el mundo real.

Para abordar los desafíos observados, especialmente el mayor error en el eje Z en el caso de simulaciones, es crucial investigar y mejorar la modelización de la profundidad anatómica. Este eje, que es más difícil de predecir debido a la variabilidad en la profundidad y densidad de las estructuras internas, podría beneficiarse del estudio e implementación de las consecuencias de la



respiración, ya que este fenómeno afecta principalmente al desplazamiento de ese eje del corazón, de manera que considerarlo podría reducir el margen de error en las predicciones.

Para aumentar la robustez del modelo frente a las condiciones del mundo real, sería beneficioso incorporar ruidos más realistas en las simulaciones que reflejen mejor las variabilidades y artefactos presentes en datos clínicos reales. Esto podría incluir la simulación de diferentes niveles de interferencia y variabilidad en las señales, replicando más fielmente las condiciones a las que el modelo se enfrentará en la práctica clínica.

Otra mejora importante sería expandir la base de datos con una mayor variedad de geometrías cardíacas y torácicas, así como condiciones cardíacas patológicas. Este enfoque no solo haría que el modelo fuera más robusto, sino que también le permitiría generalizar mejor a diferentes poblaciones y casos clínicos, incrementando así su aplicabilidad clínica.

Finalmente, el modelo ha mostrado un error de predicción de la ubicación del corazón en casos reales inferior a 2 cm, límite que se ha considerado aceptable en estudios previos, ya que errores inferiores a este no reflejan variaciones relevantes en el ECGI. Esto sugiere que el método desarrollado, con una serie de iteraciones de optimización y la implementación de las sugerencias de mejora mencionadas, puede llegar a proporcionar información valiosa y precisa para el diagnóstico y tratamiento de arritmias cardíacas, sin necesidad de recurrir a técnicas costosas y demoras para la adquisición de imágenes médicas.

Capítulo 6. Bibliografía

- [1] CardioAlianza, “Fibrilación Auricular”, <https://cardioalianza.org/las-enfermedades-cardiovasculares/fibrilacion-auricular/>. [Online]
- [2] Policlínica Metropolitana, “ECG: ¿Qué es un electrocardiograma?”, <https://policlinicametropolitana.org/informacion-de-salud/electrocardiograma-que-es/>. [Online]
- [3] My-EKG, “Derivaciones cardíacas,” <https://www.my-ekg.com/generalidades-ekg/derivaciones-cardiacas.html>. [Online]
- [4] ECG Imaging, “What is ECGI,” <https://www.ecg-imaging.org/home/what-is-ecgi>. [Online]
- [5] IBM, “Redes neuronales,” <https://www.ibm.com/es-es/topics/neural-networks>. [Online]
- [6] Matich, Gustavo, “Redes Neuronales,” https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_ano/orientadora1/monograis/matic-h-redesneuronales.pdf. [Online]
- [7] OpenWebinars, “Qué son las redes neuronales y sus aplicaciones,” <https://openwebinars.net/blog/que-son-las-redes-neuronales-y-sus-aplicaciones/>. [Online]
- [8] OCW-EHU, “Redes Neuronales,” https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf. [Online]
- [9] SCIELO, “Aurícula Izquierda,” https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-85602009000100011. [Online]
- [10] Universidad de Buenos Aires, “Aurícula y Ventrículo Izquierdo,” <https://fmed.uba.ar/sites/default/files/2019-04/Aur%C3%ADcula%20y%20Ventr%C3%ADculo%20Izquierdo.pdf>. [Online]
- [11] Elsevier, “JACC,” <https://jacc.elsevier.es/es-pdf-XX735109719001600>. [Online]
- [12] Hearts (Basel). (2021). Body Surface Potential Mapping: A Comprehensive Review. *Hearts*, 2(4), 514–542. <https://doi.org/10.3390/hearts2040040>
- [13] Química.es, “Aurícula derecha,” https://www.quimica.es/enciclopedia/Aur%C3%ADcula_derecha.html. [Online]
- [14] Quirónsalud, “Anatomía del corazón,” <https://www.quironsalud.com/blogs/es/corazon/anatomia-cardiaca-debemos-saber>. [Online]
- [15] My-EKG, “Lectura del electrocardiograma,” <https://www.my-ekg.com/generalidades-ekg/ondas-electrocardiograma.html>. [Online]
- [16] Incentro, “Librería TensorFlow,” <https://www.incentro.com/es-ES/blog/que-es-tensorflow>. [Online]
- [17] Aprende con Alf, “Librería pandas,” <https://aprendeconalf.es/docencia/python/manual/pandas/>. [Online]

- [18] IONOS, “Librería Keras,” <https://www.ionos.es/digitalguide/online-marketing/marketing-para-motores-de-busqueda/que-es-keras/>. [Online]
- [19] Aprende con Alf, “Librería numpy,” <https://aprendeconalf.es/docencia/python/manual/numpy/>. [Online]
- [20] Aprende con Alf, “Librería matplotlib,” <https://aprendeconalf.es/docencia/python/manual/matplotlib/>. [Online]
- [21] Python Docs, “Librería sys,” <https://docs.python.org/es/3/library/sys.html>. [Online]
- [22] Python Docs, “Librería importlib,” <https://docs.python.org/es/3.10/library/importlib.html>. [Online]
- [23] PyPI, “Librería scipy,” <https://pypi.org/project/scipy/>. [Online]
- [24] Python Docs, “Librería glob,” <https://docs.python.org/es/3.9/library/glob.html>. [Online]
- [25] Requena, A., Quintanilla, R., Bolarín, J.M., Vázquez, A., Bastida, A., Zúñiga, J., & Tomás, L.M. (2024). Nuevas Tecnologías y Contaminación de Atmósferas, para PYMEs. VI-3-4, Pag. 3. Universidad de Murcia. Recuperado de <https://www.um.es/LEQ/Atmosferas/Ch-VI-3/F63s4p3.htm>. [Online]
- [26] Arrijoja, N. (2020, 23 de octubre). *Métricas en regresión*. Medium. Recuperado de <https://medium.com/@nicolassarrijoja/m%C3%A9tricas-en-regresi%C3%B3n-5e5d4259430b> [Online]
- [27] Molero, R., González-Ascaso, A., Climent, A. M., & Guillem, M. S. (2022). Robustness of imageless electrocardiographic imaging against uncertainty in atrial morphology and location. *Journal of Electrocardiology*, 73, 53-60. <https://doi.org/10.1016/j.jelectrocard.2022.07.004>
- [28] Estudiante Médico. (2017, November 19). Planos anatómicos - Generalidades de anatomía. Estudiante Médico. <https://estudiantemedico.tumblr.com/post/167986512330/planos-anat%C3%B3micos-generalidades-de-anatomia>
- [29] PubMed. (2022). <https://pubmed.ncbi.nlm.nih.gov/35065409/>
- [30] Rodrigo, M., Climent, A. M., Liberos, A., & Millet, J. (2021). Non-invasive ECG imaging in atrial fibrillation: State of the art and future challenges. *Frontiers in Physiology*, 12, 653013. <https://www.frontiersin.org/articles/10.3389/fphys.2021.653013/full>
- [31] Han, F. T., & Haqqani, H. M. (2015). Noninvasive electrocardiographic imaging in arrhythmia. *Current Cardiology Reports*, 17(6), 616. <https://doi.org/10.1007/s11886-015-0616-6>
- [32] Hospimedica. (2024, January). Análisis de ECG habilitado por IA predice eficazmente problemas cardíacos del lado derecho. <https://www.hospimedica.es/cuidados-criticos/articulos/294799891/analisis-de-ecg-habilitado-por-ia-predice-eficazmente-problemas-cardiacos-del-lado-derecho.html>
- [33] Lyon, A., Mincholé, A., Martínez, J. P., Laguna, P., & Rodríguez, B. (2018). "Computational Techniques for ECG Analysis and Interpretation in Light of Their Contribution to Medical Advances". *Journal of the Royal Society Interface*, 15(138), 20170821. <https://doi.org/10.1098/rsif.2017.0821>