

CLASIFICACIÓN MULTICLASE DE ARRITMIAS CARDÍACAS MEDIANTE UN MODELO HÍBRIDO CNN-1D + XGBOOST COMO APOYO AL DIAGNÓSTICO CARDIOVASCULAR

MULTICLASS CLASSIFICATION OF CARDIAC ARRHYTHMIAS USING A CNN-1D + XGBOOST HYBRID MODEL AS A SUPPORT TOOL FOR CARDIOVASCULAR DIAGNOSIS

Autores: ¹Mateo Adrián Campaña Tacoaman y ²Luis Fernando Tipán Vergara.

¹ORCID ID: <https://orcid.org/0009-0002-4955-2642>

²ORCID ID: <https://orcid.org/0000-0001-5328-8755>

¹E-mail de contacto: mcampana@institucional.edu.ec

²E-mail de contacto: ltipan@institucional.edu.ec

Afiliación: ^{1*2*}Universidad Politécnica Salesiana, (Ecuador).

Artículo recibido: 15 de Enero del 2026

Artículo revisado: 28 de Enero del 2026

Artículo aprobado: 06 de Febrero del 2026

¹Ingeniero en formación con experiencia en procesamiento de señales biomédicas y aprendizaje profundo.

²Ingeniero Electronico en Control graduado de la Escuela Politécnica Nacional, (Ecuador). Máster en Eficiencia Energética graduado de la Escuela Politécnica Nacional, (Ecuador).

Resumen

Este trabajo presenta un sistema híbrido para la clasificación automática de ritmos cardíacos a partir de señales de electrocardiograma (ECG) de 12 derivaciones. La propuesta combina una red neuronal convolucional unidimensional (CNN-1D) como extractor de características profundas y un clasificador XGBoost como etapa final de decisión. El sistema se evaluó utilizando el conjunto de datos PTB-XL bajo un esquema de partición estricta por paciente, garantizando una estimación realista de la capacidad de generalización interpaciente. El estudio aborda un escenario de clasificación multiclase que incluye cuatro ritmos clínicamente relevantes: ritmo sinusal normal, fibrilación auricular, taquicardia supraventricular y bradicardia sinusal, considerando el desbalance inherente entre clases. Los resultados muestran que el enfoque híbrido alcanza una exactitud balanceada del 76.11% y un AUC-ROC macro de 93.66%, incrementando la sensibilidad en clases minoritarias en comparación con una CNN entrenada de extremo a extremo. El bajo requerimiento computacional del sistema (tamaño del modelo: 0.47 MB, tiempo de inferencia: 116.53 ms) respalda su viabilidad para implementación en entornos con recursos

limitados como herramienta de apoyo al diagnóstico clínico.

Palabras claves: Arritmias, Clasificación multiclase, CNN 1D, Electrocardiograma, PTB-XL, XGBoost.

Abstract

This paper presents a hybrid system for the automatic classification of heart rhythms based on 12-lead electrocardiogram (ECG) signals. The proposal combines a one-dimensional convolutional neural network (CNN-1D) as a deep feature extractor and an XGBoost classifier as the final decision stage. The system was evaluated using the PTB-XL dataset under a strict patient partitioning scheme to ensure a realistic estimate of interpatient generalization ability. The study addresses a multi-class classification scenario that includes four clinically relevant rhythms: normal sinus rhythm, atrial fibrillation, supraventricular tachycardia, and sinus bradycardia, considering the inherent imbalance between classes. The results show that the hybrid approach achieves a balanced accuracy of 76.11% and a macro AUC-ROC of 93.66%, increasing sensitivity in minority classes compared to an end-to-end trained CNN. Furthermore, the system's low computational requirements (model size: 0.47 MB, inference time: 116.53 ms) support its

viability for implementation in resource-limited settings as a clinical diagnostic support tool.

Keywords: Arrhythmias, Multi-class classification, 1D CNN, Electrocardiogram, PTB-XL, XGBoost.

Sumário

Este trabalho apresenta um sistema híbrido para a classificação automática de ritmos cardíacos a partir de sinais de eletrocardiograma (ECG) de 12 derivações. A proposta combina uma rede neural convolucional unidimensional (CNN-1D) como extrator de características profundas e um classificador XGBoost como etapa final de decisão. O sistema foi avaliado utilizando o conjunto de dados PTB-XL sob um esquema de partição estrita por paciente, garantindo uma estimativa realista da capacidade de generalização interpaciente. O estudo aborda um cenário de classificação multiclasse que inclui quatro ritmos clinicamente relevantes: ritmo sinusal normal, fibrilação atrial, taquicardia supraventricular e bradicardia sinusal, considerando o desequilíbrio inerente entre classes. Os resultados mostram que a abordagem híbrida alcança uma exatidão balanceada de 76.11% e um AUC-ROC macro de 93.66%, incrementando a sensibilidade em classes minoritárias em comparação com uma CNN treinada de extremo a extremo. O baixo requerimento computacional do sistema (tamanho do modelo: 0.47 MB, tempo de inferência: 116.53 ms) respalda sua viabilidade para implementação em ambientes com recursos limitados como ferramenta de apoio ao diagnóstico clínico.

Palavras-chave: Arritmias, classificação multiclasse, CNN 1D, eletrocardiograma, PTB-XL, XGBoost.

Introducción

Las enfermedades cardiovasculares constituyen una de las principales causas de mortalidad a nivel mundial, representando un problema prioritario de salud pública. Según estimaciones de la Organización Mundial de la Salud, este

grupo de patologías ocasiona más de veinte millones de muertes anuales. Su impacto es particularmente significativo en países de ingresos bajos y medios, donde las limitaciones en el acceso a diagnóstico oportuno incrementan la carga social y económica asociada (World Health Organization, 2023). Dentro de este conjunto de patologías, las arritmias cardíacas constituyen un desafío clínico importante debido a su diversidad y complejidad diagnóstica. Estas alteraciones se originan por fallas en la generación o conducción de los impulsos eléctricos del corazón. Entre las más comunes se incluyen el ritmo sinusal anómalo, las taquicardias supraventriculares, la fibrilación auricular y las bradicardias (Rajpurkar et al., 2017; Kirchhof et al., 2016). La presencia de fibrilación auricular y otras taquiarritmias se asocia con un aumento significativo del riesgo de accidente cerebrovascular, insuficiencia cardíaca y muerte súbita, especialmente cuando no se detectan de manera temprana (Rajpurkar et al., 2017; Kirchhof et al., 2016).

El presente estudio aborda el problema como una tarea de clasificación multiclase restringida a cuatro ritmos cardíacos: ritmo sinusal normal, fibrilación auricular, taquicardia supraventricular y bradicardia sinusal. Esta delimitación permite evaluar el desempeño del sistema en un escenario de clasificación de ritmo a nivel de registro completo (Rajpurkar et al., 2017). Un desafío principal radica en la naturaleza asintomática de numerosas arritmias durante sus etapas incipientes, lo que entorpece su identificación temprana. Esta carencia de signos clínicos provoca un retraso en la aplicación de terapias, afectando la estabilidad hemodinámica y el pronóstico del individuo (Kirchhof et al., 2016). De ahí que la detección precoz constituya una prioridad. En este marco, la ingeniería biomédica aporta innovaciones

tecnológicas que fortalecen los protocolos de asistencia diagnóstica. El electrocardiograma (ECG) permanece como el estándar de oro clínico por su bajo costo, disponibilidad y naturaleza no invasiva. El uso de registros multiderivación permite un análisis detallado de la propagación del frente de onda y la actividad bioeléctrica del corazón. No obstante, la interpretación de estas señales presenta un componente subjetivo considerable, limitación que se acentúa al procesar registros extensos o señales degradadas por ruido. El análisis manual resulta ineficiente y vulnerable a la variabilidad interobservador (Schläpfer y Wellens, 2017).

Recientemente, las metodologías basadas en aprendizaje profundo han demostrado alta eficacia en el procesamiento automatizado de señales ECG. En particular, las redes neuronales convolucionales unidimensionales (CNN-1D) destacan por su capacidad para extraer representaciones jerárquicas a partir de la señal cruda, prescindiendo de la extracción manual de características. Estas arquitecturas logran capturar patrones morfológicos complejos asociados a diferentes tipos de arritmias (Rajpurkar et al., 2017; Hannun et al., 2019; Strodthoff et al., 2020). Sin embargo, el aumento del desempeño predictivo suele ir acompañado de un incremento considerable en la complejidad de los modelos. Arquitecturas profundas que incorporan bloques residuales o mecanismos de atención requieren mayores recursos computacionales y tiempos de inferencia prolongados (He et al., 2016; Vaswani et al., 2017). Estas características limitan su implementación práctica en contextos clínicos con restricciones de infraestructura tecnológica.

Adicionalmente, las bases de datos clínicas presentan un desbalance natural entre clases. En

repositorios como PTB-XL, el volumen de registros de ritmo sinusal normal supera considerablemente a aquellos de arritmias con menor frecuencia. Esta disparidad induce sesgos en los modelos de aprendizaje automático, limitando su sensibilidad para identificar patologías minoritarias (Wagner et al., 2020). Como alternativa, se han desarrollado modelos híbridos que combinan redes neuronales convolucionales con algoritmos clásicos de aprendizaje automático. En estos esquemas, la CNN actúa como extractor automático de características profundas, mientras que la clasificación final se delega a modelos más ligeros. Entre estos, XGBoost ha demostrado un desempeño consistente debido a su capacidad para modelar relaciones no lineales, su tolerancia al desbalance de clases y su eficiencia computacional (Strodthoff et al., 2020; Chen y Guestrin, 2016). A partir de estas consideraciones, la presente investigación se enfoca en el desarrollo y validación de una arquitectura híbrida para la clasificación automática de arritmias cardíacas. La propuesta integra una red CNN-1D como extractor de descriptores profundos y un clasificador XGBoost como paso final de decisión, aplicada al conjunto de datos PTB-XL. Se prioriza la detección de cuatro entidades clínicas básicas bajo un esquema de validación estricta por paciente, buscando un equilibrio entre precisión diagnóstica y eficiencia computacional.

Materiales y Métodos

El estudio se desarrolló mediante un enfoque cuantitativo de carácter aplicado y exploratorio, empleando un diseño no experimental de tipo transversal basado en el análisis de datos secundarios. La investigación se orientó a la comparación técnica de dos arquitecturas: una red CNN-1D entrenada bajo el paradigma end-to-end, y un modelo híbrido donde la CNN-1D

actúa como extractor automático de descriptores, delegando la clasificación final a XGBoost. La evaluación del desempeño se llevó a cabo mediante métricas globales y macro-promediadas, empleando un esquema de separación estricta por paciente. Este procedimiento permitió estimar de forma realista la capacidad de generalización interpaciente, evitando la fuga de información entre los conjuntos de entrenamiento, validación y prueba (Goodfellow et al., 2016; Raschka, 2018).

Los experimentos se ejecutaron en una computadora portátil Lenovo IdeaPad 3, equipada con una unidad de almacenamiento sólido Kingston NV2 y una memoria RAM total de 20 GB. Las limitaciones de este entorno computacional influyeron en la frecuencia de muestreo adoptada, la profundidad de la arquitectura propuesta y la estrategia de validación implementada. Este enfoque busca reflejar condiciones realistas de implementación, acordes con escenarios clínicos donde no se dispone de infraestructura de alto rendimiento (McMahan et al., 2017). Se utilizó el conjunto de datos PTB-XL, el cual contiene registros de electrocardiograma de 12 derivaciones con una duración aproximada de diez segundos y anotaciones diagnósticas a nivel de registro (Wagner et al., 2022). A partir de dichas anotaciones se definió un escenario de clasificación multiclase conformado por cuatro ritmos clínicamente relevantes: ritmo sinusal normal (SR), fibrilación auricular (AFIB), taquicardia supraventricular (STACH) y bradicardia sinusal (SBRAD).

La selección de estas categorías responde a su elevada prevalencia clínica y utilidad funcional en los procesos de triaje electrocardiográfico. En estos entornos, resulta prioritario discriminar con precisión entre los registros

normales y aquellas arritmias con impacto potencial sobre la morbilidad cardiovascular. En el conjunto PTB-XL, un mismo registro puede presentar más de una etiqueta diagnóstica. Con el objetivo de asignar una única clase por registro, se estableció un criterio de priorización clínica: fibrilación auricular (AFIB), taquicardia supraventricular (STACH), bradicardia sinusal (SBRAD) y ritmo sinusal normal (SR). Esta jerarquización se fundamenta en el impacto diferencial de dichas arritmias sobre el riesgo cardiovascular (Wagner et al., 2022; Hong et al., 2020; January et al., 2019). Luego del proceso de limpieza y mapeo de etiquetas, el flujo experimental utilizó un subconjunto de 11,735 registros, correspondientes a aquellos que cumplieron los criterios de selección y la partición estricta por paciente. El flujo metodológico implementado comprendió las siguientes etapas secuenciales:

- Carga de las señales ECG y metadatos del conjunto PTB-XL
- Selección de registros con etiquetas válidas a nivel de ritmo cardíaco
- Mapeo de las etiquetas originales a las cuatro clases definidas
- Resolución de registros con múltiples etiquetas mediante criterio de priorización
- Preprocesamiento de las señales (filtrado, normalización y remuestreo)
- Partición estricta del conjunto de datos por paciente
- Entrenamiento de la red CNN-1D y obtención de representaciones latentes
- Aplicación de TomekLinks y ponderación por clase
- Ajuste de hiperparámetros, entrenamiento y validación del clasificador XGBoost

Cada derivación fue sometida a un filtrado pasabanda con frecuencias de corte entre 0.5 Hz y 45 Hz, para atenuar desplazamientos de la línea

base y reducir ruido muscular. Este rango permite conservar la información fisiológica relevante de las ondas P, complejos QRS y ondas T. Posteriormente, se aplicó una normalización tipo z-score de manera independiente por derivación, garantizando una media cercana a cero y una desviación estándar unitaria. Esta estrategia favorece la estabilidad del entrenamiento de la red neuronal (Hannun et al., 2019; Yildirim, 2018). Las señales originales fueron remuestreadas de 500 Hz a 100 Hz, manteniendo una duración de diez segundos por registro. Esta decisión se fundamenta en evidencias que demuestran que los componentes morfológicos esenciales del ECG se mantienen íntegros a frecuencias iguales o superiores a 100 Hz (Strodtzoff et al., 2020; Wagner et al., 2022). Se adoptó un esquema de 56/14/30 para entrenamiento, validación y prueba, orientado a una evaluación interpaciente más rigurosa. La asignación de un porcentaje mayor al estándar para el grupo de prueba responde a la necesidad de obtener estimaciones de desempeño más estables y representativas de la variabilidad fisiológica interindividual (Goodfellow et al., 2016; Yildirim, 2018).

Tabla 1. Distribución final de los datos por subconjunto

Subconjunto	Porcentaje (%)
Entrenamiento	56
Validación	14
Prueba	30

Fuente: Elaboración propia

La arquitectura de la CNN-1D fue diseñada para realizar una extracción progresiva de atributos relevantes a partir de señales ECG multiderivación. Se estructuró mediante cuatro bloques convolucionales dispuestos jerárquicamente, permitiendo que el modelo capture patrones morfológicos desde niveles

básicos hasta representaciones de mayor abstracción. El bloque inicial incorpora un módulo inspirado en la arquitectura Inception, el cual emplea tres ramas de convolución paralelas con 32 filtros cada una. Esta configuración multiescala resulta adecuada para el procesamiento de señales ECG, ya que permite detectar características temporales de distinta duración. La profundidad de la arquitectura se incrementó gradualmente en los bloques posteriores, configurando capas con 64, 128 y 192 filtros respectivamente. Cada bloque convolucional integra normalización por lotes (Batch Normalization) y funciones de activación ReLU. Se implementaron conexiones residuales para favorecer la propagación del gradiente durante el entrenamiento (Chen y Guestrin, 2016). Adicionalmente, se incorporaron módulos Squeeze-and-Excitation, los cuales permiten recalibrar dinámicamente la relevancia de las características extraídas (Hu et al., 2018). Una vez concluida la fase de extracción jerárquica, se empleó una capa de Global Average Pooling. Posteriormente, el flujo converge en una capa densa encargada de proyectar los atributos aprendidos hacia un vector latente de 64 dimensiones, denominado embedding. La arquitectura consolida aproximadamente 1.3 millones de parámetros entrenables.

Table 2. Resumen de la arquitectura CNN-1D propuesta

Bloque / Elemento	Filtros / Unidades y operación
Bloque Inception 1	32 filtros en tres ramas paralelas para detectar patrones temporales de distinta duración
Bloque 2	64 filtros con conexión residual
Bloque 3	128 filtros con conexión residual
Bloque 4	192 filtros con conexión residual
Global Average Pooling	Reducción de los mapas de activación a vector de 384 dimensiones
Capa Densa Final	64 unidades (embedding) con activación ReLU y dropout
Capa de Salida	4 unidades con función Softmax para clasificación multiclase

Fuente: Elaboración propia

La incorporación de XGBoost como etapa final se fundamenta en su capacidad para construir fronteras de decisión estables sobre espacios latentes. Este enfoque resulta adecuado en escenarios con desbalance entre clases, ya que XGBoost admite esquemas de ponderación que favorecen la detección de categorías minoritarias. El clasificador fue entrenado utilizando como entrada los vectores latentes de 64 dimensiones generados por la CNN-1D. Previo al entrenamiento, estos embeddings fueron estandarizados. Se aplicó el algoritmo TomekLinks exclusivamente sobre el conjunto de entrenamiento, permitiendo identificar y eliminar pares de muestras pertenecientes a clases opuestas que presentan alta similitud. Adicionalmente, se incorporó un esquema de ponderación por clase durante el entrenamiento, asignando mayor peso a las arritmias minoritarias. El modelo XGBoost se configuró como un ensamble de 600 árboles de decisión, con una profundidad máxima de 5 niveles y una tasa de aprendizaje de 0.03 (Raschka, 2018; Hong et al., 2020).

Tabla 3. Configuración de hiperparámetros para XGBoost

Parámetro	Valor asignado
n_estimators	600
max_depth	5
learning_rate	0.03
subsample	0.85
colsample_bytree	0.85
min_child_weight	1
gamma	0.05
objective	multi:softprob
eval_metric	mlogloss

Fuente: Elaboración propia

Resultados y Discusión

El desempeño del sistema propuesto fue evaluado mediante un esquema de partición estricta por paciente. Se analizaron dos enfoques: una red CNN-1D entrenada de extremo a extremo y un modelo híbrido en el que la CNN-1D actúa como extractor de

características, delegando la decisión final a XGBoost.

Tabla 4. Métricas de desempeño global del modelo CNN

Métrica	Valor
Accuracy	0.9057
Balanced Accuracy	0.6956
Precision (macro)	0.7311
Recall (macro)	0.6956
F1-score (macro)	0.7117

Fuente: Elaboración propia

Los resultados indican que el modelo CNN-1D presenta un desempeño consistente, manteniendo un equilibrio entre precisión y sensibilidad. El valor de exactitud balanceada evidencia una capacidad adecuada para discriminar tanto el ritmo sinusal normal como las arritmias de menor prevalencia. El análisis cuantitativo de la matriz de confusión permite identificar las regiones de incertidumbre del modelo. Se observa que el Ritmo Sinusal (SR) presenta el desempeño más sólido con 2847 aciertos; no obstante, las discrepancias más recurrentes se manifiestan en la clasificación errónea de 53 registros de STACH y 59 de SBRAD como SR. Estas imprecisiones responden a la convergencia de estos ritmos en el espacio de características latentes. La detección de Fibrilación Auricular (AFIB) alcanza 173 aciertos, aunque registra una confusión notable con el SR (54 casos), lo que subraya la dificultad del algoritmo para discriminar ciertas firmas electrofisiológicas cuando la señal presenta ruido o morfología de onda P débil.

Resultados del modelo híbrido CNN + XGBoost

El enfoque híbrido obtuvo los siguientes resultados globales:

- Accuracy: 85.26%
- Balanced Accuracy: 76.11%

- Precision (macro): 62.34%
- Recall (macro): 76.11%
- F1-score (macro): 66.44%
- AUC-ROC macro (OvR): 93.66%

Resultados globales del modelo CNN

En el conjunto de prueba, el modelo CNN alcanzó los siguientes resultados globales:

- Accuracy: 90.57%
 - Balanced Accuracy: 69.56%
 - Precision (macro): 73.11%
 - Recall (macro): 69.56%
 - F1-score (macro): 71.17%
 - AUC-ROC macro (OvR): 94.90%

Tabla 5. Métricas de desempeño del modelo CNN + XGBoost

Métrica	Valor
Accuracy	85.26%
Balanced Accuracy	76.11%
Precision (macro)	62.34%
Recall (macro)	76.11%
F1-score (macro)	66.44%
AUC-ROC macro (OvR)	93.66%

Fuente: Elaboración propia

La evaluación del modelo híbrido sobre el conjunto de prueba reveló un cambio significativo en la dinámica de clasificación. Es fundamental destacar que, aunque la exactitud nominal es inferior a la del modelo CNN-1D puro, la Exactitud Balanceada se incrementó de forma notable, alcanzando un 76.11%. Este comportamiento se explica por una mejora sustancial en la sensibilidad de las clases minoritarias; el modelo híbrido logró identificar correctamente el 74% de los casos de AFIB y el 69% de las STACH, superando los valores obtenidos por la arquitectura convencional. Un hallazgo fundamental es la superioridad del paradigma híbrido en la detección de AFIB, logrando 180 aciertos frente a los 173 registrados por la CNN end-to-end. Este

incremento fortalece la integridad del triaje clínico ante una patología donde la omisión diagnóstica conlleva riesgos severos. La bradicardia sinusal presenta 90 aciertos, mejorando significativamente respecto a los 62 del modelo previo.

Análisis de eficiencia computacional

Tabla 6: Comparación de eficiencia computacional

Métrica	CNN-1D	CNN-1D + XGBoost
Tamaño del modelo (MB)	15.94	0.4678
Tiempo de inferencia (ms)	206.92	116.53

Fuente: Elaboración propia

El modelo híbrido presenta una reducción del 97.1% en el tamaño del modelo y una disminución del 43.7% en el tiempo de inferencia respecto al modelo CNN-1D puro. Esta eficiencia computacional favorece significativamente su implementación en dispositivos con recursos limitados, tales como sistemas de monitoreo ambulatorio, herramientas de telemedicina y aplicaciones de diagnóstico asistido en entornos clínicos con infraestructura tecnológica restringida.

Conclusiones

A partir de los resultados obtenidos y su análisis, se pueden establecer las siguientes conclusiones sobre el sistema híbrido propuesto para la clasificación automática de arritmias cardíacas:

- La característica principal de la metodología empleada radica en la combinación efectiva de extracción profunda de características mediante CNN-1D y clasificación robusta con XGBoost, logrando una exactitud balanceada del 76.11%, superior al modelo CNN puro (69.56%). El modelo híbrido demostró

mayor sensibilidad en la detección de clases minoritarias, específicamente fibrilación auricular (180 aciertos vs 173) y bradicardia sinusal (90 aciertos vs 62), aspectos críticos en el contexto clínico.

- La eficiencia computacional del sistema híbrido, con una reducción del 97.1% en el tamaño del modelo y 43.7% en el tiempo de inferencia, respalda su viabilidad para implementación en entornos con recursos limitados. El esquema de validación estricta por paciente garantizó una estimación realista de la capacidad de generalización interpaciente, evitando sesgos por fuga de información entre conjuntos de datos.
- Las estrategias de TomekLinks y ponderación por clase demostraron efectividad para mitigar el desbalance inherente del conjunto de datos PTB-XL, mejorando la equidad en la detección de arritmias minoritarias. La metodología propuesta establece una base técnica sólida para el desarrollo de herramientas de apoyo al diagnóstico cardiovascular en sistemas de telemedicina y entornos de primer nivel de atención.

Referencias Bibliográficas

- Chen, T. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794.
- Goodfellow, I. (2016). *Deep Learning*. MIT Press.
- Hannun, A. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*, 25(1), 65–69.
- He, K. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- Hong, S. (2020). Opportunities and challenges of deep learning methods for electrocardiogram data: A systematic review. *Computers in Biology and Medicine*, 122, 103801.
- Hu, J. (2018). Squeeze-and-excitation networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7132–7141.
- January, C. (2019). 2019 AHA/ACC/HRS focused update of the 2014 AHA/ACC/HRS guideline for the management of patients with atrial fibrillation. *Journal of the American College of Cardiology*, 74(1), 104–132.
- Kirchhof, P. (2016). 2016 ESC Guidelines for the management of atrial fibrillation. *European Heart Journal*, 37(38), 2893–2962.
- McMahan, B. (2017). Communication-efficient learning of deep networks from decentralized data. *Artificial Intelligence and Statistics*, 1273–1282.
- Rajpurkar, P. (2017). Cardiologist-level arrhythmia detection with convolutional neural networks. *arXiv*. <https://arxiv.org/abs/1707.01836>
- Raschka, S. (2018). Model evaluation, model selection, and algorithm selection in machine learning. *arXiv*. <https://arxiv.org/abs/1811.12808>
- Schläpfer, J. (2017). Computer-interpreted electrocardiograms: Benefits and limitations. *Journal of the American College of Cardiology*, 70(9), 1183–1192.
- Strodthoff, N. (2020). Deep learning for ECG analysis: Benchmarks and insights from PTB-XL. *IEEE Journal of Biomedical and Health Informatics*, 25(5), 1519–1528.
- Vaswani, A. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.
- Wagner, P. (2020). PTB-XL, a large publicly available electrocardiography dataset. *Scientific Data*, 7(1), 154.
- Wagner, P. (2022). PTB-XL+, a comprehensive electrocardiographic feature dataset. *Scientific Data*, 9(1), 391.
- World Health Organization. (2023). Cardiovascular diseases (CVDs). WHO Fact

Sheets. <https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases>

Yildirim, Ö. (2018). A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification. Computers in Biology and Medicine, 96, 189–202.



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © Mateo Adrián Campaña Tacoaman y Luis Fernando Tipán Vergara.

