

# Detección De La Fibrilación Auricular En El Intervalo R-R (Junio de 2022)

Benavides Andres, Coronell Carlos, Gomez Mateo, Leonardo Corrales

## II. FIBRILACIÓN AURICULAR

Resumen --La fibrilación auricular es cuando se presenta un ritmo cardiaco irregular, normalmente se vincula con un latido rápido. Una de las formas de comprobar si la persona está padeciendo un de FA es por medio del pulso o por medio de un electrocardiograma. Para diagnosticar FA en una persona se tiene en cuenta la duración de la lectura entre ondas R o conocido como intervalo R-R, además de tener en cuenta la variabilidad de la frecuencia cardiaca (HRV).

El objetivo de esta investigación es comparar metodologías y determinar una capaz de detectar FA con una precisión exacta y a la vez lograr implementarlas en un dispositivo portátil para el alcance del público. Se tuvieron en cuenta varias bases de datos obtenidas del repositorio PhysioNet con datos extraídos de un ECG.

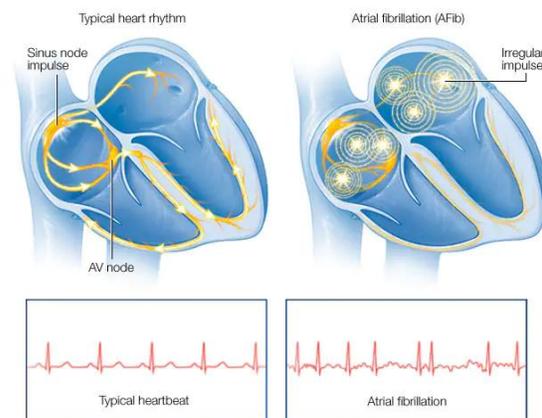
Al hacer las comparaciones entre métodos, se obtuvo un método donde tiene un porcentaje del 100% en precisión.

**ABSTRACT** --Atrial fibrillation is when an irregular heart rhythm occurs, usually associated with a rapid heartbeat. One of the ways to check if the person is suffering from AF is through the pulse or through an electrocardiogram. To diagnose AF in a person, the duration of the reading between R waves or known as the R-R interval is taken into account, in addition to taking into account the variability of the heart rate (HRV).

The objective of this research is to compare methodologies and determine one capable of detecting AF with exact precision and at the same time to implement them in a portable device for the public. Several databases obtained from the PhysioNet repository with data extracted from an-ECG were taken into account.

When making the comparisons between methods, a method was obtained where it has a percentage of 100% in precision.

## I. Introducción



© MAYO FOUNDATION FOR MEDICAL EDUCATION AND RESEARCH. ALL RIGHTS RESERVED.  
<https://www.mayoclinic.org/es-es/diseases-conditions/atrial-fibrillation/symptoms-causes/syc-20350624>

La fibrilación auricular es un ritmo cardíaco irregular, con una característica principal asociada a un latido rápido, lo cual permite que su identificación sea más factible, indicando la existencia de una arritmia, que usualmente provoca coágulos de sangre en el corazón. Es riesgo de padecer esta enfermedad es que acrecientan las probabilidades de accidentes cerebrovasculares, una insuficiencia cardíaca y, asimismo, complicaciones relacionadas con el corazón.

Durante la fibrilación auricular, las cavidades superiores del corazón suelen latir de forma caótica e irregular, de forma no sincronizada con las cavidades inferiores (ventrículos) del corazón. En muchas personas, la fibrilación auricular puede ser asintomática. Existen tipos como fibrilación auricular paroxística la cual es la fibrilación auricular que dura < 1 semana después de haberse convertido a ritmo sinusal normal espontáneamente o con una intervención. Los episodios pueden recidivar.

La fibrilación auricular permanente no se puede convertir al ritmo sinusal, cuanto más prolongada es la fibrilación auricular, menos probable es su conversión espontánea y más difícil la cardioversión debido al remodelado de las aurículas (cambios inducidos por la frecuencia auricular rápida en los parámetros electrofisiológicos auriculares, en los que predomina una disminución de la refractariedad auricular y también podría observarse una dispersión espacial de la refractariedad auricular, con reducción de la velocidad de conducción auricular o ambas). [1]

### III. DIAGNÓSTICO DE FA MEDIANTE LA ONDA R.

Los autores dan a entender que existen muchas formas de comprobar si una persona padece de fibrilación auricular entre estas tenemos el pulso del paciente y un electrocardiograma los cuales son técnicas que sirven para comprobar la posibilidad de que el paciente padezca de FA, por un lado se puede comprobar debido a que la persona tiene un pulso irregular para conocer esto se realiza una toma de pulso en la zona de la arteria radial ubicada en la muñeca, además de esto si se nota la irregularidad en el pulso el paciente debe ser sometido a un electrocardiograma con el fin de comprobar si padece de FA.

Lograr este diagnóstico mediante el electrocardiograma es posible ya que este es un estudio el cual muestra las ondas P, Q, R, S y T además de los intervalos RR, segmentos PR, intervalo QT y segmento ST.

Para lograr diagnosticar la fibrilación auricular mediante el electrocardiograma (EKG) se toma en cuenta la onda R ya que este presenta intervalos RR irregulares siendo esta la distancia entre dos ondas R sucesivas, este intervalo es medido desde el principio de la onda R hasta el inicio de la siguiente. Se denota la presencia de la fibrilación auricular debido a que los intervalos RR son irregulares, los cuales se hacen regulares a medida que aumenta la respuesta ventricular.

[2]Por otro lado, se debe tener en cuenta la variabilidad de la frecuencia cardiaca (HRV). La cual nos indica dos puntos de vista que deben ser tomados en cuenta debido a que una alta HRV es asociada a altos

*Figura: Ejemplo de valores tomados en el análisis de tiempo dominante.*

Este estudio permite analizar a fondo los intervalos R-R lo cual genera un diagnóstico efectivo a un paciente

consumos de oxígeno y bajos valores en HRV denota alta posibilidad de mortalidad. [3]Esta frecuencia cardiaca da a conocer el tiempo que transcurre entre los intervalos RR en el electrocardiograma además refleja la actividad del sistema nervioso autónomo la medición de esta se considera una herramienta predictiva y diagnostica de enfermedades cardiovasculares. por lo tanto, para realizar la medición de esta variación se lleva a cabo un análisis de tiempo dominante el cual permite conocer de manera matemática la variación en los intervalos R-R de manera que se puede observar a detalle las irregularidades de los intervalos R-R ya que estas medidas capturadas muestran una gran diferencia con las medidas de una persona que no padece de fibrilación auricular.

Además de esto, Mediante el análisis del tiempo dominante el cual se basa en la obtención de variables las cuales pueden ser tomadas de diferentes puntos de vista, por un lado, se pueden tomar desde las medidas de los intervalos R-R o de la diferencia entre los mismos intervalos realizando la toma de medias de los intervalos se obtienen las siguientes variables.

**Promedio R-R:** Es la media de todos los intervalos R-R, para obtener este dato se realiza la sumatoria de todos los intervalos y luego es dividida entre el total de los intervalos.

**SDNN:** Conocido como la desviación estándar de todos los intervalos R-R. Mostrando la variación en cortos y largos periodos en cuanto a la variación de los intervalos R-R

De otra forma, las variables obtenidas por la diferencia en los intervalos R-R son:

**NN50:** Este es el número de intervalos adyacentes con una variación más alta que 50ms.

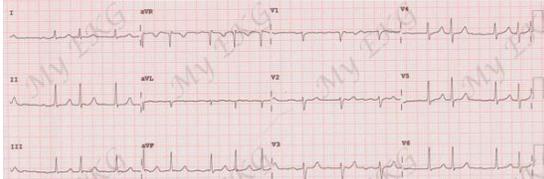
**pNN50:** conocido como el número de intervalos adyacentes con la variación por arriba de 50 expresado en porcentaje. [4]

Datos	Valor	Unidad
Duración	0:10:17	
Velocidad de muestreo	Intervalos R-R	
Número de latidos	723	latidos
Intervalo R-R mínimo	881	ms (87 ppm)
Intervalo R-R medio	853	ms (70 ppm)
Intervalo R-R máximo	1018	ms (59 ppm)
Desviación estándar	47,2	ms
Promedio RR ponderado	856	ms
SD1	30,9	ms
SD2	66,8	ms
RMSSD	30,6	ms
pNN50	4,7	%
Potencia total (0,00 - 0,40 Hz)	32444,32	ms <sup>2</sup>
MEF (0,00 - 0,04 Hz)	31584,34	ms <sup>2</sup> (97,3 %)
EF (0,04 - 0,15 Hz)	590,03	ms <sup>2</sup> (1,8 %)
AF (0,15 - 0,40 Hz)	269,95	ms <sup>2</sup> (0,8 %)
Relación EF/AF	218,6	%

<https://efdportes.com/efd121/variabilidad-de-la-frecuencia-cardiaca-una-herramienta-util.htm>

que padezca de FA debido a que los valores obtenidos de todas las variables tomadas son comparados con variables obtenidas en modelos de personas sanas sin ningún tipo de padecimientos cardiacos.

#### IV. COMO SE DIAGNOSTICA LA FA POR MEDIO DE ECG USANDO LA VARIACIÓN DEL RITMO CARDIACO.



<https://www.lecturio.com/es/concepts/pericarditis/>

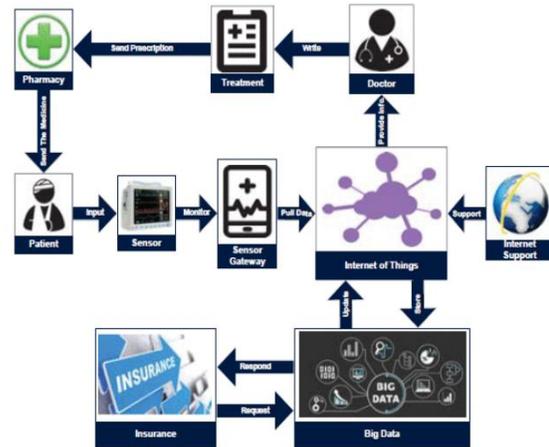
La FA se diagnostica teniendo en cuenta lo siguiente:  
 Intervalos R-R totalmente irregulares.  
 Ausencia de ondas P. Pueden verse ondas pequeña e irregulares denominadas ondas f (de fibrilación).  
 Complejos QRS de morfología similar a los complejos QRS del ritmo sinusal.

Las ondas f son conocidas por ser oscilaciones irregulares en amplitud, frecuencia y reproducibilidad de sus ciclos secuenciales en el intervalo RR.

Las ondas f al igual que las ondas P son más exactas evaluarse en las derivaciones DII y V1, con una frecuencia entre 320 y 520 latidos por minuto. La visibilidad de las ondas f tiene una variación inversa con la frecuencia ventricular. Los intervalos RR son irregulares, se hacen más regulares cuando aumenta la respuesta ventricular. El diagnóstico puede pasarse por alto en presencia de ritmo continuo de marcapaso ventricular. [4]

#### V. BENEFICIOS DE APLICAR EL IOT EN LA

FA.



<https://ezproxy.unisimon.edu.co:2131/document/8355206>

El McKinsey Global Institute (Instituto para la investigación empresarial y económica) asegura que el IoT va a tener un impacto económico muy importante de hasta 11 millones de dólares en 2025, según Gartner (empresa consultora de tecnología) ha dado un estimado de 25000 millones de cosas estarán conectadas al internet.[36]

El objetivos de implementar IoT es mejorar el diagnóstico de la FA. Además de garantizar una medicina preventiva, personalizada y los más importante es que esa brindada en tiempo real y es más interactiva con el paciente, crea la atención sin necesidad de acudir directamente a un centro hospitalario, llamado también telemedicina. Esto ayuda a la gestión de los recursos en los centros de salud, al reducirse los tiempos de espera también permite la disponibilidad de datos, así como su accesibilidad para ser consultados en cualquier momento y lugar, lo que ayuda a realizar intervenciones más rápidas por parte de los doctores, también se quiere mejora los diagnósticos ya que son más acertados al poseer una gran cantidad de información constante obtenida de los múltiples pacientes se quiere tener un seguimiento diario de una enfermedad temporal o crónica a distancia, pues los doctores pueden controlar las constantes del paciente de forma remota, además de ayuda a reducir costes tales como mantenimiento de equipos y servicios médicos, a largo plazo, gracias a la automatización de estos procesos y gestiones, por otro lado hace más fácil disponer de bases de datos conectada en la nube para múltiples pacientes, también se busca la posibilidad de mezclarse con otras tecnologías tales como la robótica y realidad aumentada con los beneficios que estos nos brindan.

## VI. IMPLICACIONES, LIMITACIONES Y

## VII. ESTADO DEL ARTE.

### DEMÁS CONSIDERACIONES DE UTILIZAR

#### REDES NEURONALES EN IOT.

Los dispositivos IOT pueden tener Inteligencia artificial con el fin de habilitar funciones, las cuales permitan el reconocimiento facial, control por voz, entre otras.

Pero para lograr acceder a estas funciones es necesario que el dispositivo cuente con componente potentes como la CPU y GPU, para así lograr ejecutar predicciones en redes neuronales profundas además de esto es necesario el poder ejecutar estas funciones de formas OFF-LINE, por lo cual los dispositivos quedaran sin el acceso a potentes servidores en la nube, dejando la tarea del procesamiento y de la predicción a los componentes de los aparatos. [5]

Se realizo un exhaustivo análisis de varios articulos donde se obtienen distintas metodologías, métricas y resultado, como observación se ve un 90% del uso de redes neuronales convolucionales (CNN).

Articulo	Año de Publicidad	Red Neuronal	Metodologia	Métricas
[5]	2019	RNN, CNN	Al seleccionar los datos, se hace una exhaustiva selección de características para el análisis. Y pasan a las redes neuronales.	Casi los mismos resultados logrados para diferentes tamaños de dispersión de la función de base radial.
[3]	2019	CNN	aplicamos un modelo de red neuronal y usamos los componentes de frecuencia de las señales de ECG como datos de entrenamiento para determinar los coeficientes de las neuronas.	93.7 % en detección y 6.9% tasa de alarmas falsas
[6]	2020	RNN PROFUNDA	clasifica la variación latida a latido de los episodios de fibrilación auricular en tiempo real utilizando frecuencias cardíacas instantáneas (IHR).	exactitud (89,75 %), precisión (90,37 %), recuperación (81,84 %), puntuación F1 (85,89 %), AUC (96,48 %) y especificidad (94,62 %)

Artículo	Año de Publicación	Red Neuronal	Metodología	Métricas
[4]	2019	CNN	aplicamos un modelo de red neuronal y usamos los componentes de frecuencia de las señales de ECG como datos de entrenamiento para determinar los coeficientes de las neuronas.	93.7 % en detección y 6.9% tasa de alarmas falsas
[7]	2020	RNN PROFUNDA	clasifica la variación latida a latido de los episodios de fibrilación auricular en tiempo real utilizando frecuencias cardíacas instantáneas (IHR).	exactitud (89,75 %), precisión (90,37 %), recuperación (81,84 %), puntuación F1 (85,89 %), AUC (96,48 %) y especificidad (94,62 %)
[8]	2018	CNN PROFUNDA	se propone una fusión multiescala de red neuronal convolucional profunda	alcanza 96. 99% de precisión de clasificación en registros de ECG
[9]	2020	ANN	Se utiliza un método de aprendizaje automático de reconocimiento de patrones, Se recopilan los datos y se hace el procesamiento de ellos y luego estiman el desempeño de la clasificación.	99,3 %, la especificidad del 97,4 % y la precisión del 98,3 %

[10]	2020	RNN	Selección de datos, filtrado de datos, clasificación de los datos y luego realizan la detección del enfoque.	Se obtuvo un probabilidad de detectar FA entre 0,3 y 0,7
[11]	2020	RNN, CNN		La proporción de cada clase en el conjunto de datos varía del 3,27 % para el ruido obtenido en las lecturas del ECG
[12]	2020	DNN	El parche ECG calcula la variabilidad del Ritmo Cardíaco	Lograron un resultado general de 0,92% en el conjunto de prueba
[13]	2022	CNN	Entrenamiento con imágenes 2-D obtenidas al convertir señales de ECG en escalogramas wavelet	se observaron valores medios superiores al 85% para todos los índices de desempeño
	2021	CNN PROFUNDA UNIDIMENSIONAL	Para evaluar la viabilidad de implementación del modelo desarrollado, se interconectó con una aplicación de teléfono inteligente y se integró dentro de un contexto de monitoreo de salud.	El modelo logró un rendimiento en la precisión: 95,50 %, sensibilidad: 94,50 % y especificidad: 96,00 %

Artículo	Año de Publicación	Red Neuronal	Metodología	Métricas
[14]	2022	CRN	En el estudio de la base de datos se dividió en un 50% de entrenamiento y un 50% de prueba, de modo que los métodos desarrollados pudieran validarse en un conjunto de datos independiente.	Se logró una precisión del 96,4 %, se obtuvo una mejora del 3 % en la precisión de la detección de FA.
[15]	2021	(LSTM) RNN	Se diseñó una RNN con la capacidad de aprender para detectar de manera automática la FA basándose en las señales del ECG, acompañado de una LSTM.	Se obtuvo una precisión del 85,7 %
[16]	2020	CNN LSTM	Se desarrolló una aplicación móvil como medio de visualización del dispositivo wearable, la cual analiza los resultados, da un diagnóstico y almacena los datos en Firebase. El dispositivo wearable con el que se trabaja es NodeMCU (prototipo).	precisión de prueba del 84,64%
[17]	2020	CNN PROFUNDA	Para la realización de esta investigación, se trabajó con redes neuronales de convolución profunda multiescala MS-DCNN para lograr la detección automática de los episodios de FA teniendo en cuenta las señales del ECG. Para esto, se contó con una muestra de 8.528 sujetos y sus EKG, adquiridos por medio del dispositivo AliveCor.	precisión, sensibilidad, especificidad y puntuación F1 promedio de 84,31 %, 84,80 %, 83,82 % y 84,31 %
[18]	2020	NA	Estado del arte. Se analizaron investigaciones de FA. La edad media promedio con la que se trabaja en la mayoría de los estudios es mayor de 70 años. Además de esto, es importante mencionar que la mayoría de los estudios incluyen menos de 100 voluntarios.	N/A
[19]	2018	CNN, RNN y LSTM	Para llevar a cabo este estudio se trabajó con una Red Neuronal Convolutiva Recurrente con memoria a corto plazo para lograr el procesamiento y clasificación de datos sensores digitales en tiempo real. La red	obtenemos una precisión de prueba del 84,64 %.
[13]	2017	DNN	Se aplicó una transformada wavelet continua a los datos PPG y se entrenó una red neuronal convolutiva (CNN) en los espectrogramas derivados para detectar AF.	Exactitud lograda fue de un 91,8%
[20]	2020	DNN	se implementa un sistema de monitorización basado en IoT para pacientes cardiovasculares. El sistema envía la señal de ECG a un servicio de capa de niebla utilizando el protocolo de comunicación LoRa	Exactitud lograda fue de un 90% en un grupo de 100 muestras
[21]	2022	CNN	se comparan 3 enfoques de uso de la representación 2D de señales ECG como entrada a la Red Neuronal Convolutiva (CNN), que se sabe que son los más adecuados para la clasificación de imágenes. El espectrograma, el escalograma y la reconstrucción del atractor (AR) se utilizan para la detección AFIB dentro de las ventanas 5s de la señal ECG cruda	Se logró una sensibilidad del 94 % (escalograma), el 95 % (espectrograma), el 90 % (AR) y la puntuación F1 del 94 % (escalograma), el 93 % (espectrograma) y el 89 % (RA)

Como se describe en el artículo los investigadores E. Prabhakararao y S. Dandapat para la realización de esta investigación, se trabajó con redes neuronales de convolución profunda multiescalar MS-DCNN para lograr la detección automática de los episodios de FA teniendo en cuenta las señales del ECG. Para esto, se contó con una muestra de 8.528 sujetos y sus EKG, adquiridos por medio del dispositivo ALiveCor. Tras llevar a cabo la investigación, los resultados son prometedores, pues este método presenta una precisión de 84,31%, lo cual convierte a la MS-DCNN en un método más adecuado para dispositivos portátiles, en específico para la detección temprana de FA. [6]

A. Brasoveanu, M. Moodie, and R. Agrawal realizan un estudio con una Red Neuronal Convolutiva Recurrente con memoria a corto plazo para lograr el procesamiento y clasificación de datos sensores digitales en tiempo real. La red neuronal permite realizar tareas de procesamiento de señales como, por ejemplo, el filtrado y la detección de picos. [7]

L. M. Eerikäinen, A. G. Bonomi, L. R. C. Dekker, R. Vullings, y R. M. Aarts determinaron para la realización de este estado del arte, se presenta un análisis de la detección de la FA por medio de dispositivos Wearable, específicamente de los utilizados en las muñecas y que trabajan con mediciones PPG. Teniendo esto en cuenta, los resultados obtenidos son prometedores, pues el uso de dispositivos wearables facilita en gran medida la detección de FA, sin embargo, se debe redireccionar el uso de estos dispositivos a personas que mayores, las cuales son las que presentan mayores riesgos de padecer FA. [8]

Este trabajo S. Banerjee y su equipo tiene como objetivo el desarrollo de una aplicación portátil que acompañe un dispositivo wearable para lograr la clasificación de las ondas representadas en el ECG y así poder alertar a los usuarios sobre su condición. Las alertas sobre el estado del ECG se transmiten a través de la app móvil, la cual está conectada a una base de datos en tiempo real por medio de la nube Este método es confiable y rápido, además le brinda al usuario un diagnóstico temprano. [9]

En esta investigación S. P. Shashikumar, A. J. Shah, Q. Li, G. D. Clifford, y S. Nemati buscaron detectar la FA en una ventana de secuencias cortas y con el uso de un dispositivo de movimiento significativo. Los datos PPG se obtuvieron de 98 sujetos, los cuales se registraron con una pulsera multicanal, además se realizó un ECG por sujeto como forma de verificación del ritmo cardiaco. Teniendo estos datos, se desarrolló una red neuronal profunda que permite clasificar la FA a partir de las señales PPG obtenidas de la muñeca. [10]

Para la realización de esta investigación S. Sadasivuni, R. Chowdhury, V. E. G. Karnam, I. Banerjee, and A. Sanyal diseñaron una red LTSTM y una RNN la cual fuera capaz de aprender dependencias temporales en señales provenientes de ECG, con el fin de lograr una detección automática de FA a partir de las señales de ECG. Al llevar a cabo la investigación y analizar los resultados, se logró evidenciar que el sistema propuesto tuvo una muy buena efectividad, siendo esta del 85,7% [11]

La propuesta presentada en este estudio es la detección de AF silencioso (SAF) se realiza mediante el uso de diferentes esquemas de redes neuronales. En el primer paso, la selección de características se realiza utilizando un algoritmo genético. Este paso da como resultado la obtención de 8 características HRV. En el siguiente paso, el espacio de características obtenido se asigna a las redes neuronales. El enfoque propuesto proporciona un buen rendimiento de clasificación en la detección de eventos PAF. [12]

Los autores de la investigación proponen un sistema para predecir los resultados de la desfibrilación durante el período de fibrilación ventricular. aplicamos un modelo de red neuronal y usamos los componentes de frecuencia de las señales de ECG como datos de entrenamiento para determinar los coeficientes de las neuronas. Luego, el sistema entrenado se valida (prueba) utilizando diferentes conjuntos de datos para justificar el rendimiento. Se proporcionan resultados experimentales para mostrar un rendimiento superior del sistema propuesto. [13]

P. Panindre, V. Gandhi, y S. Kumar han desarrollado varios algoritmos de IA para clasificar la variación latido a latido de los episodios de F.A. utilizando frecuencias cardíacas instantáneas (IHR). Se han utilizado bases de datos de Physionet.org para entrenar los algoritmos de IA. Se evalúan la exactitud, la sensibilidad, la especificidad, etc. Se encontró que, en comparación con otros algoritmos de IA, la (RNN) con memoria bidireccional a largo plazo (LSTM) demuestra un mejor rendimiento para clasificar los episodios de AFib. Los modelos desarrollados pueden integrarse en aplicaciones mHealth basadas en rastreadores de salud inalámbricos para detectar AFib usando IHR en tiempo real. [14]

Los autores proponen una fusión multiescala de red neuronal convolutiva profunda (MS-CNN) para descartar grabaciones de FA de grabaciones de ECG corto de una sola derivación. Los resultados experimentales muestran que el MS-CNN propuesto alcanza 96.99% de precisión de clasificación en registros de ECG recortados/rellenados a 5 s. Especialmente, la mejor precisión de clasificación, 98,13 %, se obtiene en registros de ECG de 20 s. En comparación con la red neuronal artificial. El excelente rendimiento de detección

de AF del MS-CNN puede satisfacer a la mayoría de los ancianos para el monitoreo diario con dispositivos portátiles logrando un mejor rendimiento de clasificación. [15]

En esta investigación proponen un modelo de clasificación de bajo recursos desarrollado por los investigadores para la detección robusta de episodios de FA en señales de ECG, utilizando intervalos RR de las señales de ECG e introduciéndolos en una red neuronal (ANN) para la clasificación, Además, comparamos nuestro clasificador con otros clasificadores. Usamos la base de datos de arritmia del MIT-BIH. Los resultados logran la sensibilidad del 99,3 %, la especificidad del 97,4 % y la precisión del 98,3 %, superando a la mayoría. En consecuencia, observamos que ANN que usa intervalos RR como característica de entrada puede ser un candidato adecuado para la clasificación automática de AF. [16]

J. van Zaen propone en su investigación un sistema para detectar AF de las grabaciones de PPG. Este sistema está compuesto por un detector de latidos para extraer intervalos entre latidos y un clasificador para la detección. Entrenamos al clasificador en una gran base de datos pública de intervalos entre latidos y luego evaluamos todo el sistema en los registros de PPG recopilados durante los procedimientos de ablación con catéter. Logramos una precisión de 0.986 para la detección de FA con una sensibilidad y especificidad de 1,0 y 0,978 respectivamente. Estas métricas se comparan favorablemente con los sistemas existentes. [17]

En este artículo los investigadores hablan de la creación de una IA usando CNN como modelo de red neuronal, utilizando un DL (Aprendizaje Profundo) con el propósito de distinguir los datos de una imagen. Utilizando el gráfico de Lorenz de la variabilidad de la frecuencia cardíaca del ECG de 24 h en sujetos con ritmo sinusal (SR) y FA cuyo diagnóstico se confirmó como datos del maestro. Y obtenemos un resultado del 100% en la distinción de imágenes. [18]

En este trabajo los investigadores aplicaron Knowledge Distillation (En el aprendizaje automático, la destilación del conocimiento es el proceso de transferir conocimiento de un modelo grande a uno más pequeño.) a la red neuronal recurrente convolucional utilizada para la detección y clasificación de arritmias cardíacas. Se muestra que la red resultante se redujo a la mitad la huella de memoria y el número de operaciones en comparación con la línea de base. En el artículo obtienen resultados prometedores para consolidar una base estable para la implementación de redes neuronales para la detección de arritmias cardíacas en dispositivos portátiles de bajo consumo. [19]

M. Shao, Z. Zhou, G. Bin, Y. Bai, y S. Wu en este artículo proponen un sistema de telemonitorización de electrocardiograma (ECG) portátil para la detección de fibrilación auricular (FA) basado en un teléfono inteligente y computación en la nube. Conectado a un parche de ECG portátil para la recolección y el envío de las señales al dispositivo Android para visualizar las formas de las ondas. Propusieron un método para clasificar los resultados del ECG basándose en un aprendizaje automático (CatBoost) para la detección de la FA. La aplicación de Android muestra el resultado de las señales del ECG. Pasa a la nube para ser revisada por el médico y devolver el resultado al paciente. El sistema de monitoreo propuesto puede ser potencialmente útil para la telemonitorización de ECG a largo plazo para la detección de FA. [20]

En este artículo Á. H. Herraiz y su equipo de investigadores realizan un método basado en la alta capacidad de aprendizaje de una red neuronal convolucional, que ha sido entrenada con imágenes 2-D obtenidas al convertir señales de ECG en escalogramas wavelet. Los resultados obtenidos revelan una capacidad discriminatoria para detectar extractos de ECG de alta calidad y descartar los extractos de baja calidad obteniendo hasta un 93% de efectividad, clasificando erróneamente alrededor del 5 % de los segmentos AF limpios como ruidosos. [21]

J. Ramesh, y sus compañeros plantea desarrollar un modelo capaz de generalizar la clasificación de la Fibrilación Auricular en las distintas modalidades, ECG y PPG. En esta investigación se utiliza una Red Neuronal Convolucional Profunda Unidimensional que utiliza características de la Variabilidad de la Frecuencia Cardíaca (HRV) para clasificar los ritmos cardíacos. Con un entrenamiento de tres bases de datos distintas obtenidas de distintas maneras, usando ECG y PPG. Teniendo una efectividad del 95%. [22]

Z. Xiong, M. K. Stiles, A. M. Gillis, y J. Zhao marcaron como objetivo el desarrollar un marco de aprendizaje profundo de código abierto para la detección automática de FA utilizando el mayor conjunto de datos de ECG de una sola derivación disponible públicamente a través de un dispositivo Kardia móvil mejorado con un aumento de datos basado en transferencia de estilo.

Desarrollaron y validaron una red recurrente convolucional de 37 capas (CRN) utilizando 5834 ECG de una sola derivación con una duración media de 30 segundos del PhysioNet Challenge 2017 para detectar automáticamente el ritmo sinusal y la FA. Para abordar el desafío de la falta de una gran cantidad de muestras de FA, propusimos un generador de transferencia de estilo novedoso que fusiona ECG clínicos específicos del paciente y características de ECG modeladas matemáticamente para sintetizar ECG realistas por cinco. [23]

J. A. Rincon y sus compañeros investigadores presentan un sistema de monitoreo basado en las IoT para pacientes con arritmias cardiacas. El sistema se basa en un envío de señal ECG a un servicio de capa en la niebla utilizando LoRa el cual es un protocolo de comunicación, además se basa en la IA para crear un algoritmo capaz de detectar la AF y otros ritmos

La telemedicina y todo tipo de sistemas de monitorización han demostrado ser muy útil y de bajo costo con gran eficiencia [24]

Los autores presentan una arquitectura de red neuronal convolucional-recurrente con memoria a corto plazo para el preprocesamiento de dato y pos-clasificación en tiempo real de las señales emitidas por los sensores digitales. La encargada de realizar tareas tales como el filtrado y detección de picos en la red la cual aprende incrustaciones de la señal resuelta, para llevar a cabo las anteriores tareas se utiliza un prototipo de dispositivo portátil multisensorial para recopilar más de 180 horas de PPG [25]

En esta investigación los autores comparan 3 enfoques de aplicabilidad de las representaciones en 2D de las señales ECG como las entradas a la red neuronal (CNN)

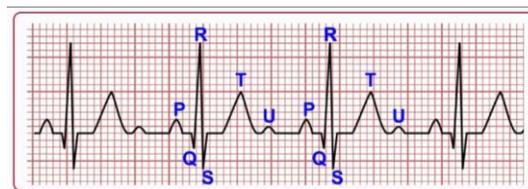
Para la detección de AF dentro de las ventanas se utilizan el espectrograma, el escalograma y la reconstrucción del atractor (AR), estas son señales ECG sin procesar

También se permite verificar el método de la reconstrucción del atractor para detectar la AF [26]

## VIII. DESCRIPCIÓN ECG

El corazón genera, por sí mismo, una actividad eléctrica que se transmite por todo el órgano produciendo la contracción de este. Un electrocardiograma (ECG) no es más que un registro de la actividad eléctrica del corazón el cual se expresa por medio de gráficos como ondas, intervalos y segmentos. De su interpretación depende el diagnóstico de enfermedades como las arritmias, cardiopatía isquémica o alteraciones de la conducción.

Las ondas electrocardiográficas son distintas curvas que toman forma en el ECG hacia arriba o hacia abajo. Son producto de los potenciales de acción que se producen durante la estimulación del corazón. Estas, han sido denominadas **P, Q, R, S, T, U** por ese orden y van unidas entre sí por una línea isoelectrica.



<https://laboratoriomartinez.com/electrocardiograma/>

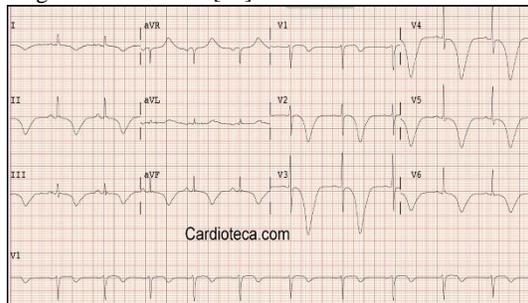
La onda R, corresponde con la despolarización ventricular, es la primera onda positiva del complejo QRS y es la única onda de visualización constante. El voltaje de esta onda no debe ser mayor de 25 mm en V5-V6, de 20 mm en I y de 15 mm en VL, aunque puede haber excepciones, sobre todo, en adolescentes deportistas y en ancianos delgados.

Por otro lado, Se puede observar en el electrocardiograma un ritmo R-R el cual se visualiza desde la primera onda R hasta la siguiente, el cálculo de la distancia en ms es una herramienta útil para lograr el diagnóstico de la FA en pacientes.

Este complejo cumple un papel importante al momento de diagnosticar Fibrilación Auricular (FA) es cual es la arritmia más común, seria y frecuente en la población adulta. Los mecanismos de producción más frecuente son: los trastornos de conducción y períodos refractarios en las aurículas, especialmente en la aurícula izquierda.

En el ECG característico de una FA no es posible observar ondas P, las cuales son reemplazadas por ondas f que corresponden a despolarizaciones auriculares de múltiples morfologías y extremadamente rápidas, con frecuencia mayor de 300 lpm; además de complejos QRS estrechos y ritmo irregular.

La FA se caracteriza por un ritmo irregularmente irregular, sea con complejos QRS anchos, como el caso del bloqueo de la rama derecha, o QRS angostos. Por tanto, si no se observa onda P en un ECG y el ritmo ventricular sea completamente irregular se deberá diagnosticar una FA. [27]



<https://www.cardioteca.com/blogs/ecg-electrocardiograma/entry/ecg-electrocardiograma/ecg-telegraph-76-como-es-el-ecg-del-tako-tsubo.html>

## IX. DATA BASE

**MIT-BIH ECG Compression Test Database:** Esta base de datos contiene 168 registros de ECG cortos (20,48 segundos cada uno) seleccionados para plantear una variedad de desafíos para los compresores de ECG, en particular para los métodos de compresión con pérdida. [28]

**The PhysioNet/Computing in Cardiology Challenge 2001:** Esta base de datos de registros de ECG de dos canales se creó para su uso en Computers in Cardiology Challenge 2001, una competencia abierta con el objetivo de desarrollar métodos automatizados para predecir la fibrilación auricular paroxística (PAF). [29]

**MIT-BIH Atrial Fibrillation Database:** Esta base de datos incluye 25 registros de ECG a largo plazo de sujetos humanos con fibrilación auricular (en su mayoría paroxística). De estos, 23 registros incluyen las dos señales de ECG (en los archivos .dat); los registros 00735 y 03665 están representados solo por el ritmo (.atr) y el tiempo no auditado (archivos de anotación. qrs). [30]

## X. METODOLOGÍAS USADAS EN

### DIAGNÓSTICO DE AF USANDO ONDA R

En la actualidad existen múltiples metodologías aplicables a la detección de la AF gracias a las posibilidades tecnológicas que se utilizan para desarrollar las mismas capacidades que las personas en el campo de la medicina, las máquinas se encargan de procesar informaciones de entradas con el fin de dar un diagnóstico, gracias a la IA, machine learning, deep learning.

Las técnicas para la extracción de actividad auricular tratadas anteriormente en este proyecto con Redes Neuronales Artificiales, presentan un mejor rendimiento que las técnicas clásicas, aunque necesitan del uso de la información contenida en varias derivaciones y o registros con una determinada duración para obtener los mejores resultados.

Los investigadores utilizaron unos registros ECG los cuales son serían capaces de predecir la finalización de la (FA) para esto se utilizaron bases de datos de PHYSIONET, de estos se extrajeron espectros como parámetros y de tiempo/frecuencia, también se calculó la variación del intervalo RR el cual representa la actividad

ventricular, en cuanto a los resultados este método obtuvo un 100% de precisión lo cual lo catapultó como uno de los métodos más eficientes para la detección de esta arritmia [31]

K. Tahsin, M. F. Hossain, y M. A. Rahman afirman que los métodos de detección de AF publicados y los procesos de eliminación de ruido utilizan un procedimiento muy complejo. En el campo de la detección de AF, las transformadas wavelets se han utilizado para el procesamiento de señales que tiene el problema del método de muestreo. [32]

En este estudio D. R. Seshadri usó el método Bland-Altman que evalúa la precisión del monitor de frecuencia cardíaca Apple Watch en cincuenta pacientes que experimentaron F.A. en comparación con la telemetría. Los resultados de este estudio piloto demostraron un coeficiente de correlación de 0,7 entre todas las lecturas del Apple Watch y la telemetría. Además, el Apple Watch evaluó la frecuencia cardíaca con mayor precisión en pacientes con fibrilación auricular que en aquellos que no la tenían ( $rc = 0,86$ , pacientes con FA, vs.  $rc = 0,64$ , pacientes que no están en FA. [33]

D. Lai y su equipo de investigadores proponen un método novedoso de clasificación de FA con una CNN, dos características del ritmo cardíaco de los intervalos RR y el espectro de frecuencia de ondas F llamado Pan-Tompking se combinaron en la CNN para una buena aplicabilidad de la aplicación móvil. Se recopilaron más de 23 registros de electrocardiograma (ECG) de diez horas de pacientes de la base de datos MIT-BIH, y cada uno de los cuales se segmentó en fragmentos de datos de 10 para entrenar la CNN diseñada y evaluar el rendimiento del método propuesto [34]

S. Sadasivuni y compañía realizan la detección automática de FA a partir de datos ECG sin previo procesamiento se utilizaron redes neuronales recurrentes (RNN) anidada a una red de memoria a corto plazo apilada (LSTM) [11]

P. Siwindarto, A. B. Dianisma, Z. Abidin, y S. S. Mahmudov diseñaron un circuito detector que utiliza la variación del intervalo RR de las señales de electrocardiogramas ECG, la metodología se basa en clasificar las señales de ECG como ritmo sinusal normal NSR cuando el intervalo RR se detecta regularmente, AF cuando el intervalo RR se detecta de manera irregular. [35]

## XI. DISCUSIÓN

Se puede detectar la fibrilación auricular de distintas maneras posibles, se puede utilizar la transformada de Wavelet o la transformada de Fourier, son métodos eficientes, pero realizando la comparación con otros métodos no son lo suficientemente eficientes. [31] Extrayendo de las onda fibrilatoria auricular varios parámetros espectrales y de tiempo-frecuencia arrojados de las señales del ECG. Se calcularon características temporales. Estos parámetros se evaluaron usando un criterio de dispersión final, donde se seleccionan las mejores características para dar un resultado lo más exacto posible. Se evaluó con una técnica de análisis conocida como

Análisis Discriminante Lineal (LDA), donde se obtuvo un resultado del 100% en precisión. En el conjunto de entrenamiento y el conjunto de prueba, lo que revela una mejora significativa en comparación con otros métodos.

## XII. CONCLUSIÓN

La fibrilación auricular es un ritmo cardíaco irregular, con una característica principal asociada a un latido rápido, lo cual permite que su identificación sea más factible, indicando la existencia de una arritmia, que usualmente provoca coágulos de sangre en el corazón, existen diversos modelos propuesto para el eficaz pronóstico de esta arritmia, en este artículo se trataron de evaluar métodos que utilizan redes neuronales las cuales son las encargadas de resolver los problemas de

## XIII. REFERENCIA

- [1] “Fibrilación auricular”, MayoClinic.org, 14-dic-2021. [En línea]. Disponible en: <https://www.mayoclinic.org/es-es/diseases-conditions/atrial-fibrillation/symptoms-causes/syc-20350624>.
- [2] G. Mora-Pabón, “Evaluación de la fibrilación auricular mediante electrocardiograma y Holter,” *Revista Colombiana de Cardiología*, vol. 23, pp. 27–33, Dec. 2016, doi: 10.1016/j.rccar.2016.10.006.
- [3] T. Guterman, “Variabilidad de la frecuencia cardiaca, una herramienta útil”, *Efdeportes.com*. [En línea]. Disponible en: <https://www.efdeportes.com/efd121/variabilidad-de-la-frecuencia-cardiaca-una-herramienta-util.htm>.
- [4] L. Veloza, C. Jiménez, D. Quiñones, F. Polanía, L. C. Pachón-Valero, and C. Y. Rodríguez-Triviño, “Heart rate variability as a predictive factor of cardiovascular diseases,” *Revista Colombiana de Cardiología*, vol. 26, no. 4. Elsevier B.V., pp. 205–210, Jul. 01, 2019. doi: 10.1016/j.rccar.2019.01.006.
- [5] “D. G. F. Ramírez, “repositorio universidad de los andes”, <https://repositorio.uniandes.edu.co/bitstream/handle/1992/55580/261>

predicción de esta arritmia de una manera más abstracta a través de dispositivos IoT , arrojando resultados muy alentadores para el campo tecnológico de la medicina

este estudio va encaminado a la utilización del ritmo cardiaco el cual nos brinda ciertos patrones de comportamientos de esta arritmia entre ellos nos brinda información importante como los límites normales de la frecuencia cardíaca los cuales son de 60 a 100 latidos por minuto, En el caso del ritmo regular cardíaco:

La señal viaja desde el nódulo sinusal a través de las aurículas.

La señal pasa a través de una vía entre las cavidades superior e inferior llamada nodo auriculoventricular.

El movimiento de la señal hace que el corazón se contraiga y envíe sangre al corazón y al cuerpo.

En el caso de la fibrilación auricular, la frecuencia cardíaca oscila entre 100 y 175 latidos por minuto. Las señales en las cavidades superiores del corazón son caóticas. Como resultado, las cavidades superiores tiemblan. Luego, el nodo auriculoventricular recibe una gran cantidad de impulsos con señales que intentan llegar a los ventrículos. lo cual es el causante de un ritmo cardíaco acelerado e irregular.

las alternativas planteadas coinciden en obtener la serie de tiempos de intervalos RR a partir de los datos "sin procesar" de una salida de registros ECG y contrastar los resultados con los

registros globales de ciertas bases de datos como lo son PhysioNet, estas alternativas combinadas con los dispositivos IoT ayudarían a millones de personas que carecen de esta arritmia, ya que muchos de ellos son de bajo coste y gran eficiencia

- 81.pdf?sequence=1. [En línea].  
 Disponible en:  
<https://repositorio.uniandes.edu.co/bitstream/handle/1992/55580/26181.pdf?sequence=1>.
- [6] E. Prabhakararao and S. Dandapat, "Multiscale convolutional neural network for detecting paroxysmal atrial fibrillation from single lead FPGA signals," in *Proceedings of 2020 IEEE Applied Signal Processing Conference, ASPCON 2020*, Oct. 2020, pp. 339–343. doi: 10.1109/ASPCON49795.2020.9276690.
- [7] A. Brasoveanu, M. Moodie, and R. Agrawal, "Textual evidence for the perfunctoriness of independent medical reviews," in *CEUR Workshop Proceedings*, 2020, vol. 2657, pp. 1–9. doi: 10.1145/nnnnnnn.nnnnnnn.
- [8] L. M. Eerikäinen, A. G. Bonomi, L. R. C. Dekker, R. Vullings, and R. M. Aarts, "Atrial fibrillation monitoring with wrist-worn photoplethysmography-based wearables: State-of-the-art review," *Cardiovascular Digital Health Journal*, vol. 1, no. 1, pp. 45–51, Jul. 2020, doi: 10.1016/j.cvdhj.2020.03.001.
- [9] S. Banerjee, A. Paul, A. Agarwal, and S. K. Jindal, "Real Time Arrhythmia Detecting Wearable using a Novel Deep Learning Model," in *Proceedings - 2020 International Conference on Interdisciplinary Cyber Physical Systems, ICPS 2020*, Dec. 2020, pp. 14–19. doi: 10.1109/ICPS51508.2020.00009.
- [10] S. P. Shashikumar, A. J. Shah, Q. Li, G. D. Clifford, and S. Nemati, "A deep learning approach to monitoring and detecting atrial fibrillation using wearable technology," in *2017 IEEE EMBS International Conference on Biomedical and Health Informatics, BHI 2017*, Apr. 2017, pp. 141–144. doi: 10.1109/BHI.2017.7897225.
- [11] S. Sadasivuni, R. Chowdhury, V. E. G. Karnam, I. Banerjee, and A. Sanyal, "Recurrent neural network circuit for automated detection of atrial fibrillation from raw ECG," in *Proceedings - IEEE International Symposium on Circuits and Systems*, 2021, vol. 2021-May. doi: 10.1109/ISCAS51556.2021.9401666.
- [12] O. Aligholipour, M. Kuntalp, and S. Sadaghiyanfam, "Silent paroxysmal atrial fibrillation detection by neural networks based on ECG records," Apr. 2019. doi: 10.1109/EBBT.2019.8741771.
- [13] IEEE Circuits and Systems Society and Institute of Electrical and Electronics Engineers, *2019 IEEE International Symposium on Circuits and Systems (ISCAS) : proceedings : ISCAS 2019 : Sapporo, Japan, May 26-29 2019*.
- [14] P. Panindre, V. Gandhi, and S. Kumar, "Comparison of Performance of Artificial Intelligence Algorithms for Real-Time Atrial Fibrillation Detection using Instantaneous Heart Rate," in *HONET 2020 - IEEE 17th International Conference on Smart Communities: Improving Quality of Life using ICT, IoT and AI*, Dec. 2020, pp. 168–172. doi: 10.1109/HONET50430.2020.9322658.
- [15] X. Fan, Q. Yao, Y. Cai, F. Miao, F. Sun, and Y. Li, "Multiscaled Fusion of Deep Convolutional Neural Networks for Screening Atrial Fibrillation from Single Lead Short ECG Recordings,"

- IEEE Journal of Biomedical and Health Informatics*, vol. 22, no. 6, pp. 1744–1753, Nov. 2018, doi: 10.1109/JBHI.2018.2858789.
- [16] F. Ma, J. Zhang, W. Liang, and J. Xue, “Automated Classification of Atrial Fibrillation Using Artificial Neural Network for Wearable Devices,” *Mathematical Problems in Engineering*, vol. 2020, 2020, doi: 10.1155/2020/9159158.
- [17] J. van Zaen *et al.*, “Atrial Fibrillation Detection from PPG Interbeat Intervals via a Recurrent Neural Network,” in *2019 Computing in Cardiology Conference (CinC)*, Dec. 2019, vol. 45. doi: 10.22489/cinc.2019.084.
- [18] C. T. January *et al.*, “2014 AHA/ACC/HRS guideline for the management of patients with atrial fibrillation: A report of the American college of Cardiology/American heart association task force on practice guidelines and the heart rhythm society,” *J Am Coll Cardiol*, vol. 64, no. 21, pp. e1–e76, Dec. 2014, doi: 10.1016/j.jacc.2014.03.022.
- [19] A. Faraone, H. Sigurthorsdottir, and R. Delgado-Gonzalo, “Atrial Fibrillation Detection on Low-Power Wearables using Knowledge Distillation,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2021, pp. 6795–6799. doi: 10.1109/EMBC46164.2021.9630957.
- [20] M. Shao, Z. Zhou, G. Bin, Y. Bai, and S. Wu, “A wearable electrocardiogram telemonitoring system for atrial fibrillation detection,” *Sensors (Switzerland)*, vol. 20, no. 3, Feb. 2020, doi: 10.3390/s20030606.
- [21] Á. H. Herraiz, A. Martínez-Rodrigo, V. Bertomeu-González, A. Quesada, J. J. Rieta, and R. Alcaraz, “A deep learning approach for featureless robust quality assessment of intermittent atrial fibrillation recordings from portable and wearable devices,” *Entropy*, vol. 22, no. 7, Jul. 2020, doi: 10.3390/E22070733.
- [22] J. Ramesh, Z. Solatidehkordi, R. Aburukba, and A. Sagahyoon, “Atrial fibrillation classification with smart wearables using short-term heart rate variability and deep convolutional neural networks,” *Sensors*, vol. 21, no. 21, Nov. 2021, doi: 10.3390/s21217233.
- [23] Z. Xiong, M. K. Stiles, A. M. Gillis, and J. Zhao, “Enhancing the detection of atrial fibrillation from wearable sensors with neural style transfer and convolutional recurrent networks,” *Computers in Biology and Medicine*, vol. 146, p. 105551, Jul. 2022, doi: 10.1016/j.compbiomed.2022.105551.
- [24] J. A. Rincon, S. Guerra-Ojeda, C. Carrascosa, and V. Julian, “An IoT and fog computing-based monitoring system for cardiovascular patients with automatic ECG classification using deep neural networks,” *Sensors (Switzerland)*, vol. 20, no. 24, pp. 1–19, Dec. 2020, doi: 10.3390/s20247353.
- [25] A. Brasoveanu, M. Moodie, and R. Agrawal, “Textual evidence for the perfunctoriness of independent medical reviews,” in *CEUR Workshop Proceedings*, 2020, vol. 2657, pp. 1–9. doi: 10.1145/nnnnnnn.nnnnnnn.
- [26] B. Król-Józaga, “Atrial fibrillation detection using convolutional neural networks on 2-dimensional

- representation of ECG signal,” *Biomedical Signal Processing and Control*, vol. 74, Apr. 2022, doi: 10.1016/j.bspc.2021.103470.
- [27] T. Guterman, “Variabilidad de la frecuencia cardiaca, una herramienta útil”, *Efdeportes.com*. [En línea]. Disponible en: <https://www.efdeportes.com/efd121/variabilidad-de-la-frecuencia-cardiaca-una-herramienta-util.htm>.
- [29] Moody GB, Goldberger AL, McClennen S, Swiryn SP. Predicting the Onset of Paroxysmal Atrial Fibrillation: The Computers in Cardiology Challenge 2001. *Computers in Cardiology* 28:113-116 (2001).
- [30] Moody GB, Mark RG. Un nuevo método para detectar fibrilación auricular usando intervalos RR. *Informática en Cardiología*. 10:227-230 (1983).
- [31] S. Saberi, V. Esmaeili, F. Towhidkhah, and M. H. Moradi, “Predicting atrial fibrillation termination using ECG features, a comparison.”
- [32] K. Tahsin, M. F. Hossain, and M. A. Rahman, “Computer Aided Atrial Fibrillation Detection from the Statistical Attributes of ECG Signal,” 2021. doi: 10.1109/ICECIT54077.2021.9641198.
- [33] D. R. Seshadri *et al.*, “Accuracy of the apple watch 4 to measure heart rate in patients with atrial fibrillation,” *IEEE Journal of Translational Engineering in Health and Medicine*, vol. 8, 2020, doi: 10.1109/JTEHM.2019.2950397.
- [34] D. Lai, X. Zhang, Y. Zhang, and M. Belal Bin Heyat, *Convolutional Neural Network Based Detection of Atrial Fibrillation Combining R-R intervals and F-wave Frequency Spectrum*; *Convolutional Neural Network Based Detection of Atrial Fibrillation Combining R-R intervals and F-wave Frequency Spectrum*; 2019. doi: 10.0/Linux-x86\_64.
- [35] P. Siwindarto, A. B. Dianisma, Z. Abidin, and S. S. Mahmudov, “ECG signal processing for early detection of atrial and ventricular fibrillation based on R-R interval,” in *EECCIS 2020 - 2020 10th Electrical Power, Electronics, Communications, Controls, and Informatics Seminar*, Aug. 2020, pp. 142–146. doi: 10.1109/EECCIS49483.2020.9263454.
- [36] “El Internet de las cosas (IOT): el futuro de la interconectividad”, *Lenovo Tech Today México*, 17-ago-2017. [En línea]. Disponible en: <https://techtoday.lenovo.com/mx/es/solutions/smb/el-internet-de-las-cosas-iot-el-futuro-de-la-interconectividad>.