

Clasificación de arritmias cardiacas usando redes neuronales convolucionales en muestras de ECG



Revista EIA
ISSN 1794-1237
e-ISSN 2463-0950
Año XIX/ Volumen 21/ Edición N.41
Enero - junio de 2024
Reia4105 pp. 1-22

Publicación científica semestral
Universidad EIA, Envigado, Colombia

**PARA CITAR ESTE ARTÍCULO /
TO REFERENCE THIS ARTICLE /**
Astudillo-Delgado, V. M.; Revelo-Luna,
D. A. Y Muñoz-Chaves, A.
Clasificación de arritmias cardiacas
usando redes neuronales
convolucionales en muestras de ECG

Revista EIA, 21(41), Reia4105.
pp. 1-22.
<https://doi.org/10.24050/reia.v21i41.1719>

✉ *Autor de correspondencia:*

Astudillo-Delgado, V. M.
Ingeniero Mecatronico
Corporación Universitaria
Comfacauca (Unicomfacauca)
Correo electrónico:
victorastudillo@unicomfacauca.edu.co

Recibido: 18-07-2023
Aceptado: 09-11-2023
Disponible online: 01-01-2024

✉ Ing. Victor Manuel Astudillo-Delgado¹
M. Sc. David Armando Revelo-Luna¹
PhD. Javier Andrés Muñoz-Chaves¹

1. Corporación Universitaria Comfacauca - Unicomfacauca

Resumen

El electrocardiograma (ECG) es una herramienta esencial en el diagnóstico de enfermedades cardiovasculares, proporcionando información valiosa sobre el ritmo y la función del corazón. Tradicionalmente, los médicos se basaban en características heurísticas identificadas manualmente para detectar anomalías en el ECG. Sin embargo, esta metodología presentaba limitaciones en términos de precisión y fiabilidad. Con el objetivo de mejorar la precisión en la identificación de arritmias cardiacas, esta investigación se enfocó en el desarrollo de modelos basados en redes neuronales convolucionales. Se utilizaron dos conjuntos de datos: el dataset PhysioNet MIT-BIH, ampliamente utilizado en la comunidad científica, y datos adquiridos por el simulador de arritmias Bio-Tek BP Pump NIBP. Se entrenaron cinco modelos con diferentes arquitecturas, incluyendo modelos convencionales como VGG16, ResNet-50 y AlexNet, así como dos arquitecturas propuestas por los autores. Todos los modelos se entrenaron con el mismo número de muestras y configuración de hiperparámetros. La evaluación del desempeño se realizó utilizando métricas comunes como exactitud, *recall*, F1-score y exactitud —accuracy—. Los resultados demostraron que la arquitectura VGG16 fue la más eficaz en la clasificación de arritmias cardiacas, alcanzando una exactitud del 98,8% en el conjunto de datos MIT-BIH. Además, al evaluar los datos de prueba del simulador Bio-Tek BP Pump NIBP, el modelo customize-2 demostró el mejor rendimiento con una exactitud del 96,3%. Estos resultados son prometedores, ya que demuestran el potencial de las redes neuronales convolucionales para mejorar la precisión en el diagnóstico de arritmias cardiacas. Los modelos desarrollados en esta investigación podrían ser una herramienta útil para los médicos en la detección temprana y el tratamiento adecuado de estas afecciones cardiovasculares.

Palabras clave: Segmentación de latidos, Electrocardiograma (ECG), Arritmias cardiacas, Dataset PhysioNet MIT-BIH, clasificación de ECG, matriz de confusión, data Augmentation, Hiperparámetros, redes neuronales convolucionales, simulador de arritmias.

Classification of cardiac arrhythmias using convolutional neural networks in ECG samples

Abstract

The electrocardiogram (ECG) is an essential tool in the diagnosis of cardiovascular disease, providing valuable information about heart rhythm and function. Traditionally, physicians relied on manually identified heuristic features to detect ECG abnormalities. However, this methodology had limitations in terms of accuracy and reliability. With the aim of improving accuracy in the identification of cardiac arrhythmias, this research focused on the development of models based on convolutional neural networks. Two data sets were used: the PhysioNet MIT-BIH dataset, widely used in the scientific community, and data acquired by the Bio-Tek BP Pump NIBP arrhythmia simulator. Five models were trained with different architectures, including conventional models such as (VGG16, ResNet-50 and AlexNet), as well as two architectures proposed by the authors. All models were trained with the same number of samples and hyperparameter settings. Performance evaluation was performed using common metrics such as precision, recall, F1-score and accuracy. The results showed that the VGG16 architecture was the most effective in classifying cardiac arrhythmias, achieving an accuracy of 98.8% on the MIT-BIH dataset. Furthermore, when evaluating test data from the Bio-Tek BP Pump NIBP simulator, the customize-2 model demonstrated the best performance with an accuracy of 96.3%. These results are promising, as they demonstrate the potential of convolutional neural networks to improve accuracy in the diagnosis of cardiac arrhythmias. The models developed in this research could be a useful tool for clinicians in the early detection and appropriate treatment of these cardiovascular conditions.

Keywords: Beat segmentation, Electrocardiogram (ECG), Cardiac arrhythmias, PhysioNet MIT-BIH Dataset, ECG classification, confusion matrix, data Augmentation, Hyperparameters, convolutional neural networks, arrhythmia simulator.

1. Introducción

El electrocardiograma (ECG) es una técnica no invasiva que permite registrar y medir las señales eléctricas generadas por el corazón. Consiste en la captación de la variación temporal del potencial bioeléctrico durante cada ciclo cardíaco, utilizando electrodos colocados en la superficie cutánea del paciente (Zhang *et al.*, 2021). El análisis del electrocardiograma proporciona datos sobre el sistema cardiovascular, en particular el corazón, lo que permite detectar diversas enfermedades que pueden afectar su funcionamiento adecuado. Estas enfermedades incluyen arritmias cardíacas, obstrucción de arterias, insuficiencia cardíaca y ataques al corazón (National Library of Medicine, 2020). En este sentido, según la WHO (World Health Organization, 2021) el 32% de muertes en el mundo se deben a enfermedades cardiovasculares (ECV), siendo la principal causa de muerte a nivel mundial.

La identificación de arritmias cardíacas en pacientes puede tener un impacto positivo en el proceso de diagnóstico de enfermedades y facilitar un tratamiento oportuno. Una opción para la detección de arritmias es el análisis de las señales de electrocardiograma (Huang *et al.*, 2019). Tradicionalmente, el análisis de la señal ECG se divide en dos pasos: extracción de características y clasificación de patrones. Por lo general, los médicos emplean características heurísticas diseñadas manualmente o utilizan arquitecturas de aprendizaje de características superficiales para la interpretación de los electrocardiogramas (Pyakillya Kazachenko y Mikhailovsky, 2017). Sin embargo, el problema radica en la posibilidad de no encontrar la mayoría de las características apropiadas que darán una alta exactitud en el diagnóstico a partir de las señales.

En los últimos años, ha habido un creciente interés en los métodos computacionales aplicados a la salud, por ejemplo Revelo, Mejía y Munoz (2021) y Verma (2021) aplicaron estos métodos a la identificación de COVID-19. En investigaciones previas sobre el análisis y la categorización de señales de ECG utilizando técnicas de aprendizaje automático (Chazal, O'Dwye y Reilly, 2004; Lanatá *et al.*, 2011), generalmente se han utilizado cuatro categorías como base: **1.** Procesamiento, consiste en captar las señales ECG y

atenuar el ruido incorporado por actividad muscular del paciente o por factores externos. **2.** Segmentación, es delimitar parte de la señal donde está la información de mayor interés según sea el caso, generalmente es el complejo QRS, que es la principal desviación positiva en el ECG producida por la despolarización ventricular (Pal, 2019). **3.** Extracción de características, se obtienen características particulares de la señal. **4.** Clasificación, proceso en el cual a partir de las características obtenidas se realiza la clasificación en ciertas categorías predefinidas (Luz *et al.*, 2013).

Se han empleado diversos enfoques para extraer características, centrándose en la morfología del complejo QRS y haciendo uso del reconocimiento de patrones. Chazal, O'Dwyre y Reilly (2004) identificaron cuatro características del intervalo RR en el análisis de señales de ECG. Estas características incluyen el intervalo entre un latido cardíaco dado y el latido anterior, el intervalo entre un latido dado y el siguiente latido, el promedio de todos los intervalos RR en una grabación completa y el promedio de los intervalos RR de los diez latidos circundantes a un latido específico. Otros investigadores han empleado métodos robustos para obtener funciones de base de Karhunen-Loeve (KL) que representan el complejo QRS. Estas expansiones de KL utilizan cinco términos en un intervalo de 200 ms, que incluye el complejo QRS y parte del segmento ST (Moody and Mark, 1989). Laguna, *et al.* (1996) presentaron un sistema de estimación del modelo de Hermite adaptativo (AHMES) para la estimación en línea latido a latido de las características que describen el complejo QRS con el modelo de Hermite. Gómez Herrero, *et al.* (2005), presentaron un algoritmo conocido como "Matching Pursuit" que ofrece la capacidad de descomponer cualquier señal en una combinación lineal de formas de onda extraídas de un diccionario redundante de funciones llamado Gabor. Este algoritmo se ha reconocido como una herramienta eficaz para realizar transformaciones adaptativas de tiempo-frecuencia en señales de ECG, lo que permite obtener características relevantes en el dominio tiempo-frecuencia.

Otros métodos relevantes implican la extracción de características a partir de dominios transformados, tales como la Transformada de Coseno Discreta (DCT), la Transformada Wavelet

Continua (CWT) y la Transformada Wavelet Discreta (DWT). Estas técnicas permiten analizar las señales de ECG en diferentes representaciones y obtener características significativas para su posterior procesamiento y análisis. Khorrami and Moavenian (2010) utilizaron la CWT con dos técnicas de transformación de datos DWT y DCT, con el fin de mejorar la capacidad de dos clasificadores de patrones en la clasificación de arritmias ECG. Song, *et al.* (2005) extrajeron diecisiete características de entrada originales de señales pre-procesadas mediante transformada wavelet, utilizando el análisis discriminante lineal (LDA). El rendimiento del clasificador SVM (Máquina de Soporte Vectorial) con características reducidas por LDA mostró ser mayor que con el análisis de componentes principales (PCA) e incluso con características originales.

Yu y Chen (2007) utilizaron la transformación wavelet y la red neuronal probabilística (PNN), para descomponer las señales de latido de ECG en diferentes sub-bandas utilizando la transformada wavelet discreta. Posteriormente, seleccionaron tres conjuntos de características estadísticas de las señales descompuestas para caracterizar las señales de ECG, así como la potencia de AC y el intervalo RR instantáneo de la señal original. Ye, Coimbra y Kumar (2010) propusieron un enfoque de combinación de características morfológicas y dinámicas refiriéndose a la transformada de wavelet (WT) y el análisis de componentes independientes (ICA) aplicándose por separado a cada latido del corazón para extraer los coeficientes correspondientes como características morfológicas. Además, se concatenaron la información del intervalo RR y estos dos tipos diferentes de características, y se utilizó la máquina de vectores de soporte (SVM) para la clasificación. Li y Zhou (2016) propusieron un método para clasificar las señales de ECG utilizando la entropía de paquetes wavelet (WPE) y bosques aleatorios (RF), descomponiendo las señales ECG por descomposición de paquetes de ondas (WPD) y calculando a continuación la entropía del coeficiente descompuesto como característica representativa, para finalmente utilizar (RF) para construir un modelo de clasificación de ECG. Particularmente, en la última etapa de clasificación, los clasificadores más utilizados incluyen la máquina de soporte vectorial (SVM), redes neuronales artificiales (ANN), k-vecinos más cercanos (KNN) y probabilidades bayesianas.

En ese sentido, Lin *et al.* (2008) y, Moavenian y Khorrami (2010), utilizando SVM y la base de datos de arritmias MIT-BIH con dos conjuntos de datos de prueba con diferentes configuraciones obtuvieron un MSE (mean square error) 0.14 y 0.15 respectivamente para cada prueba. Song *et al.* (2005) identificaron seis tipos diferentes de arritmias obteniendo una exactitud del 98.49%. Ye, Coimbra y Kumar (2010) reconocieron 15 clases de latidos con una exactitud del 99,66% en un grupo de prueba de 85,945 muestras, Yu y Chou (2009) consideraron ocho tipos de latidos obteniendo una exactitud del 98.71%.

Así mismo, Kachuee, Fazeli y Sarrafzadeh (2018) utilizaron el mismo dataset MIT-BIH, y el dataset PTB de PhysionNet, identificaron cinco tipos de arritmias con una exactitud del 93.4% y 95.9% respectivamente para cada dataset, usando ANN.

Usando KNN como clasificador, Lanatá *et al.* (2011) reconocieron seis clases de arritmias mediante análisis espectral de orden superior. Wiggins *et al.* (2008) utilizando probabilidades bayesianas, clasificaron a los pacientes por edad a partir de la información extraída de sus electrocardiogramas. En estos casos, la red bayesiana evolucionada obtuvo mejores resultados (86,25% de AUC) que la desarrollada con el algoritmo codicioso (65% de AUC) y el clasificador Naive Bayes (84,75% de AUC).

La mayoría de las investigaciones realizadas en este contexto presentan sistemas de clasificación basados en técnicas clásicas de ML de entrenamiento supervisado (Moavenian y Khorrami, 2010; Song *et al.*, 2005; Ye, Coimbra y Kumar, 2010; Yu y Chou, 2009), no supervisado (Lanatá *et al.*, 2011), o métodos estadísticos (Chazal, O'Dwyre y Reilly, 2004; Wiggins *et al.*, 2008). Durante la revisión del estado del arte, se identificaron únicamente dos estudios en los que se emplearon redes neuronales convolucionales para la clasificación de arritmias cardiacas (Huang *et al.*, 2019; Kachuee, Fazeli y Sarrafzadeh 2018). Sin embargo, ninguno de estos estudios anteriores validó los modelos entrenados utilizando datos externos al conjunto de datos utilizado. En este estudio se propone no sólo explorar las redes neuronales convolucionales para la clasificación de arritmias a partir de señales de ECG, sino también comparar diversas arquitecturas y proponer dos nuevas arquitecturas. Además, se busca

validar los modelos entrenados utilizando datos externos al conjunto de datos original, empleando equipos especializados en la generación de arritmias cardiacas.

En este contexto, el objetivo de la investigación es evaluar un clasificador de arritmias en señales de ECG mediante la utilización de diversas arquitecturas de redes neuronales convolucionales. Además, se comparan los resultados obtenidos con arquitecturas convencionales como VGG16, ResNet-50 y AlexNet. Para ello, se entrenaron las redes utilizando el dataset de arritmias —PhysioNet MIT-BIH— y se llevaron a cabo cuatro etapas principales: procesamiento de la señal, segmentación, extracción de características y clasificación. El propósito fundamental de esta investigación es identificar cinco tipos de arritmias en pacientes. El clasificador fue evaluado utilizando una parte del dataset MIT-BIH, así como datos sintéticos generados por el simulador “Bio-Tek BP Pump NIBP Monitor Tester”. El desempeño de los modelos fue evaluado mediante métricas de rendimiento incluyendo exactitud, recall, precisión, y F1score.

2. Materiales y metodos

Dataset de entrenamiento

El conjunto de datos utilizado en esta investigación se obtuvo de la base de datos de ECG de diagnóstico de arritmia (PhysioNet MIT-BIH). Esta base de datos consta de 48 grabaciones, cada una con una duración de 30 minutos, obtenidas de 47 sujetos en un rango de edad comprendido entre 23 y 89 años. Estos datos proporcionan una muestra representativa de diferentes edades y condiciones de los pacientes, lo que permite realizar un análisis exhaustivo y preciso en la clasificación de arritmias cardiacas. El Laboratorio de Arritmias de BIH (Goldberger *et al.*, 2000; Moody y Mark, 2001) realizó la toma de medidas de la derivación II (MLII) y una de las derivaciones modificadas V1, V2, V4 o V5. Cada latido fue anotado por al menos dos cardiólogos. La frecuencia de muestreo utilizada fue de 360 Hz con una resolución de 11 bits en un rango de 10 mV. El dataset se obtuvo en formato csv de la plataforma abierta KAGGLE.

Para el procesamiento y segmentación de los datos ECG se utilizó la metodología propuesta por Kachuee, Fazeli y Sarrafzadeh (2018). En esta investigación, se empleó la derivación II del ECG en todos los experimentos, ajustando la frecuencia de entrada a 125 Hz. El enfoque se centró en la clasificación de las cinco clases de latidos cardíacos, que representan el 95% de todos los latidos, utilizando la base de datos de arritmias de MIT-BIH, ver tabla 1.

Se emplearon técnicas de aumento de datos —*data augmentation*— en las clases S y F para aumentar el tamaño de la muestra. De todas las muestras disponibles, se seleccionaron 1000 para la validación y 800 para las pruebas, para cada una de las clases. Esta estrategia permitió ampliar el conjunto de datos y mejorar la capacidad de generalización del modelo en la clasificación de arritmias.

Tabla 1. Anotaciones de las clases seleccionadas. *Elaboración Propia*

Clases	Anotación	Tamaño Muestra
N	Latido Normal	90.589
S	latido supra-ventricular prematuro	2.779
V	Contracción ventricular prematura	7.236
F	Fusión de latido ventricular y normal	803
Q	Ritmo inclasificable	8.039

Procesamiento datos

En este apartado se presenta el procesamiento a los datos ECG y la segmentación de los latidos. El procesamiento se basó en investigaciones previas (Kachuee, Fazeli y Sarrafzadeh 2018; Chazal, O'Dwyre y Reilly, 2004). A continuación, se presenta los pasos de procesamiento:

- 1) Dividir la señal de ECG continua en ventanas de 10 segundos con una frecuencia de muestreo de 125Hz.

- 2) Hallar los valores máximos y mínimos de cada ventana de 10 segundos.
- 3) Escalar los valores de ECG en un rango de cero a uno, tomando como cero el valor mínimo y el valor máximo como uno, ver Eq.1.

$$V_{escal_i} = \frac{X_i - V_{min}}{V_{max} - V_{min}} \quad (1)$$

X_i es el valor perteneciente a cada uno de los datos de la señal ECG, V_{min} es el valor mínimo tomado en la ventana de 10 segundos y V_{max} es el valor máximo.

- 4) Encontrar el conjunto de todos los máximos (ECG R-Peak) de cada ventana de 10 segundos utilizando el cruce por cero de la primera derivada.
- 5) Validar si cada máximo (V_{max}) —ECG R-Peak— es mayor o igual al 80% del valor máximo.
- 6) Calcular el tiempo promedio entre picos (R-R) para cada ventana de 10 segundos.
- 7) Obtener muestras independientes de cada ventana, iniciando de un pico R hasta una longitud de 1.2 del tiempo promedio encontrado.
- 8) Establecer una longitud predefinida de 187 datos por cada muestra, si es menor a ese valor se rellenan con ceros.

Arquitectura de la CNN

En esta investigación, se propuso el uso de redes neuronales convolucionales para la clasificación de arritmias cardíacas. Se exploraron cinco arquitecturas distintas, incluyendo tres redes convencionales: ResNet-50, VGG16 y AlexNet. Se realizaron modificaciones en las capas de entrada y salida para adaptarse a los datos de entrada [187,1] y a la forma de salida requerida. Las dos arquitecturas restantes fueron propuestas específicamente para este estudio. Detalles de las arquitecturas usadas son presentadas en la figura 1. Las tres primeras son arquitecturas con más de 17.000.000 parámetros para entrenamiento. La arquitectura de la Figura 1.d está

compuesta por 3 etapas, la primera consiste en aplicar una primera convolución con 32 filtros, y kernel de tamaño 5×5 , la segunda etapa corresponde a 2 convoluciones de 64 y 32 filtros consecutivas con kernel de tamaño 5×5 , luego, una función de activación tipo ReLU, seguido de un MaxPool utilizando un *pool-size* de 5, esta etapa se repite cinco veces. Por último, dos capas totalmente conectadas con 32 neuronas cada una, y una activación SoftMax para predecir la clase de salida. Por último, la arquitectura de la Figura 1.e es una modificación de la anterior, agregando una convolución, y configurando 64 filtros para todas las capas de convolución.

Para entrenar y validar las cinco arquitecturas se utilizaron los frameworks TensorFlow y Keras. El tamaño de entrada de cada red fue 187×1 que corresponde al tamaño de cada muestra. El entrenamiento se realizó con batch-size de 64, 100 Epoch para todas las arquitecturas, y optimizador Adam.

Métricas de desempeño

Con el objetivo de evaluar el desempeño de las redes neuronales convolucionales entrenadas, se usaron métricas tales como: precisión, *recall*, F1score y exactitud, las cuales fueron calculadas con las siguientes ecuaciones:

$$\text{Precisión} = \frac{Ntp}{Ntp + Nfp} \quad (2)$$

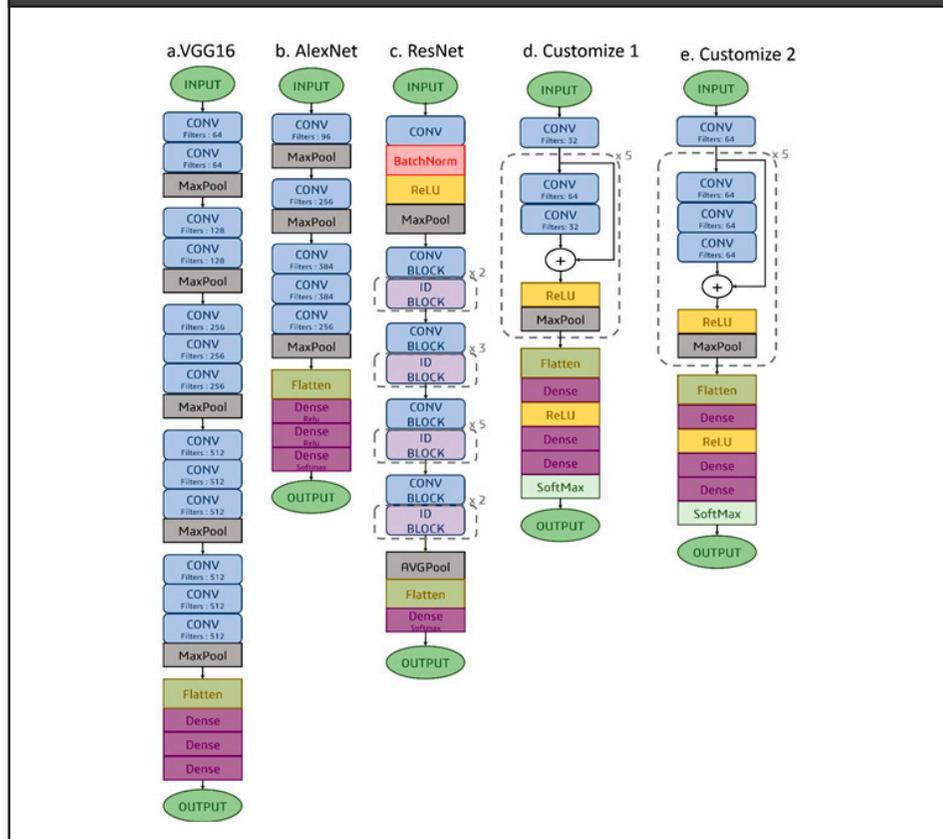
$$\text{Recall} = \frac{Ntp}{Ntp + Nfn} \quad (3)$$

$$\text{F1Score} = 2 \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (4)$$

$$\text{Exactitud} = \frac{Ntp + Ntn}{Ntp + Nfp + Ntn + Nfn} \quad (5)$$

Donde, Ntp representan los verdaderos positivos, Nfp falsos positivos, Nfn falsos negativos y Ntn verdaderos negativos.

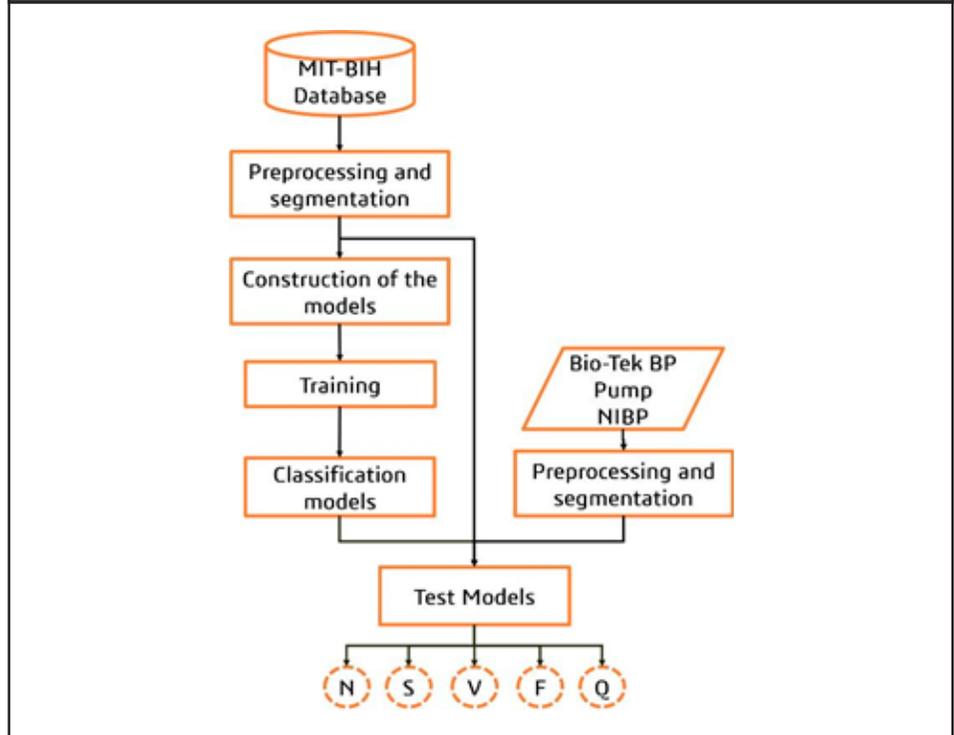
Figura 1: Arquitecturas de red propuestas: a. VGG16, b. AlexNet, c. ResNet, d. Customize 1, e. Customize 2. Elaboración Propia



Pruebas de desempeño de los modelos

Los clasificadores se probaron utilizando dos fuentes de datos: La base de datos de PhysioNet MIT-BIH y datos obtenidos de un simulador de arritmias (Bio-Tek BP Pump NIBP). El simulador se divide en dos etapas: generación de la señal y adquisición. Se utilizó un controlador ATMEGA 328P con un ADC de 10 bits de resolución y un tiempo de muestreo de 8 ms. Del simulador se obtuvo la derivación II para asegurar la concordancia con el conjunto de datos de MIT-BIH. Se aplicó la metodología descrita en la sección de procesamiento de datos para preprocesar los registros de ECG, ver Figura 2.

Figura 2. Diagrama de las etapas del método propuesto. Elaboración Propia



3. Resultados y Discusion

Procesamiento de los datos

En primer lugar, se llevó a cabo el procesamiento y la segmentación de la base de datos de PhysioNet MIT-BIH. En la Figura 3.a se muestra la señal original con una ventana de tiempo de 10 segundos, que luego se normalizó en el rango de [0-1] —ver Figura 3.b— para detectar los picos R de la señal. La extracción de los intervalos R-R se realizó utilizando la ubicación de dos picos R sucesivos, Figura 3.c. Todas las muestras se ajustaron a una longitud de 187 datos. La Figura 3.d muestra en detalle un intervalo R-R.

Esta metodología fue aplicada a todas las clases de arritmias, como se puede observar en la Figura 4, donde se segmentó el complejo QRS debido a que refleja la mayor parte de la actividad eléctrica del corazón. Una vez segmentado el complejo QRS, es posible obtener información fisiológica, como la señal de frecuencia cardiaca.

Figura 3: Señal procesada y segmentada por latidos.

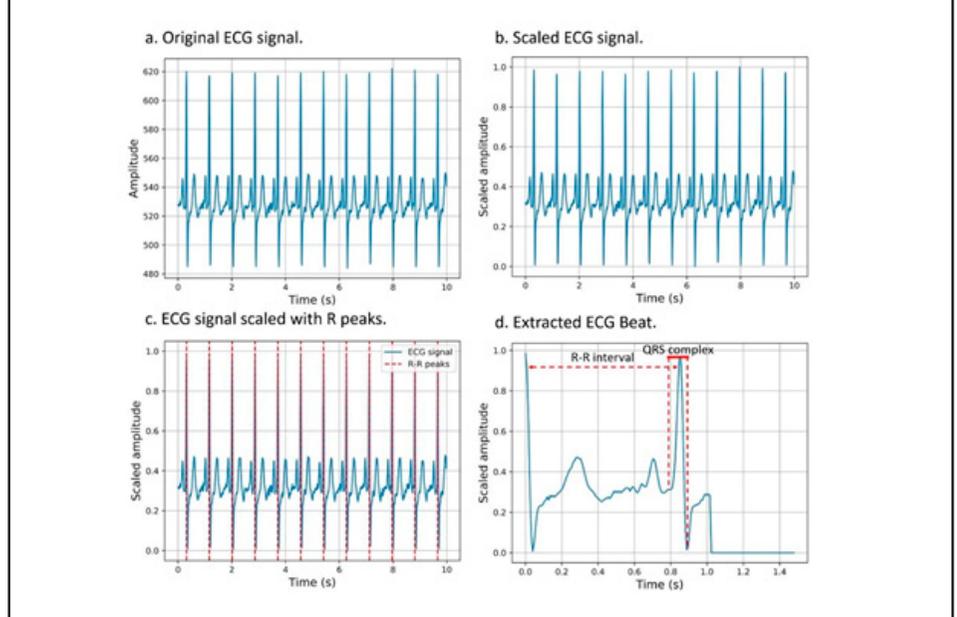
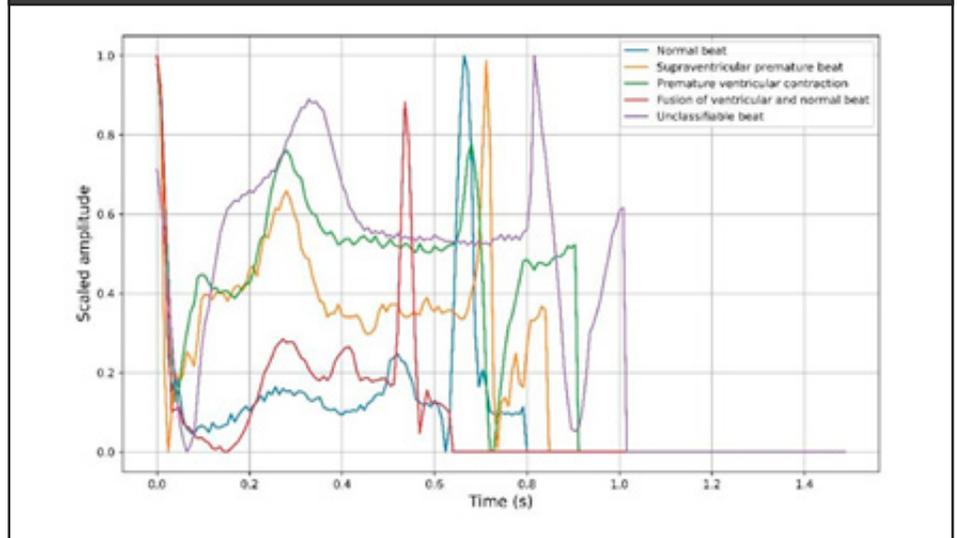


Figura 4: Latidos de cada clase en un complejo QRS. Azul (N: Normal beat); Amarillo (S: Supraventricular premature beat.); Verde (V: Premature ventricular contraction); Rojo (F: Fusion of ventricular and normal beat) y Morado (Q: Unclassifiable beat).

Elaboración Propia



4. Desempeño de los modelos

Dataset PhysioNet MIT-BIH

Se evaluaron los cinco modelos de las arquitecturas descritas anteriormente. En el proceso de entrenamiento se utilizaron 800 muestras por clase. La Figura 5 presenta las matrices de confusión de cada modelo. Como se puede ver en la Figura 5, los modelos son capaces de hacer predicciones y distinguir diferentes clases de arritmias cardiacas, las clases con el mayor número de verdaderos positivos para los cinco modelos escogidos corresponde a las clases N “latidos normales” y Q “ritmo inclasificable”. Además, obtuvieron el menor número de falsos positivos, y la clase con menor número de verdaderos positivos corresponden a las clases V “Contracción ventricular prematura” y F “Fusión de latido ventricular y normal”. Además, estas dos clases son las que obtuvieron el mayor número de falsos positivos, ya que las evaluaciones incorrectas de los modelos clasificaron las muestras que corresponden a estas clases en su mayor proporción como parte de la clase N “latidos normales”.

En la tabla 2 se muestran en detalle las métricas obtenidas para cada modelo y clase. Se observa que los cinco modelos lograron un *recall* superior al 99% para la clase N (latido normal). Esta métrica es especialmente relevante en aplicaciones médicas, ya que es importante que el modelo no clasifique a pacientes enfermos como sanos. El modelo que alcanzó la mayor exactitud fue la arquitectura VGG16, lo que significa que este modelo clasificará las muestras en una mayor proporción de acuerdo con la clase correcta. Además, la arquitectura VGG16 obtuvo el *recall* más alto para las clases de latidos normales (N) y latidos con arritmias (S, V y F), lo que indica que identificará en mayor proporción los casos positivos que fueron correctamente identificados por el modelo, y tendrá el menor número de falsos negativos.

Figura 5: Matriz de confusión para la clasificación de los latidos del corazón: a. VGG16, b. ResNet-50, c. AlexNet, d. Customize 1, e. Customize 2. Elaboración Propia

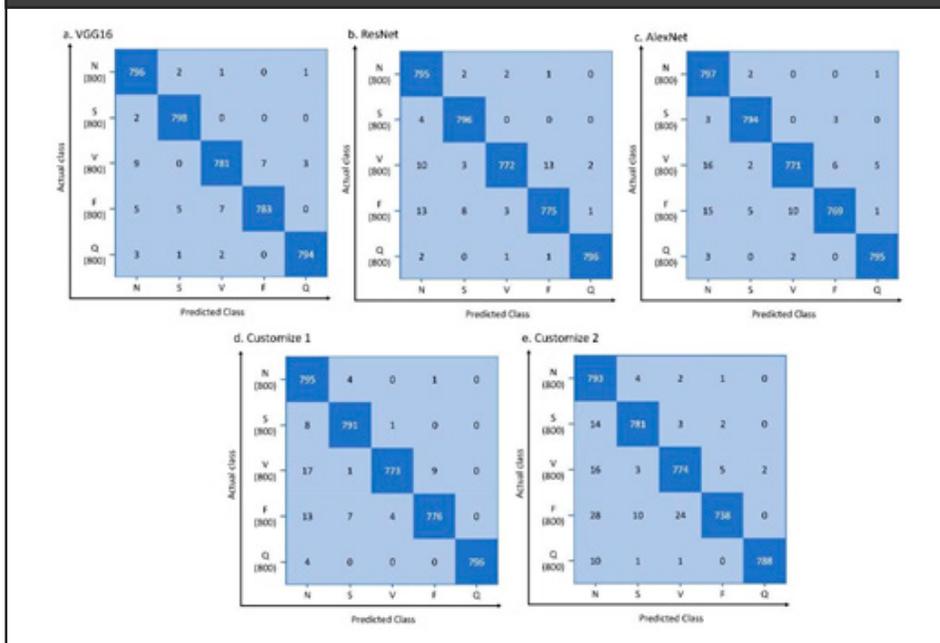


Tabla 2: Métricas de desempeño por clases utilizando el Dataset PhysioNet MIT-BIH.

Arquitectura	Clases	Métricas de Desempeño			
		Precisión (%)	Recall (%)	F1 Score (%)	Exactitud clasificación total (%)
VGG16	N	97,7	99,5	98,6	98,8
	S	99,0	99,8	99,4	
	V	98,7	97,6	98,2	
	F	99,1	97,9	98,5	
	Q	99,5	99,3	99,4	
ResNet-50	N	96,5	99,4	97,9	98,4
	S	98,4	99,5	98,9	
	V	99,2	96,5	97,8	
	F	98,1	96,9	97,5	
	Q	99,6	99,5	99,6	

Arquitectura	Clases	Métricas de Desempeño			
		Precisión (%)	Recall (%)	F1 Score (%)	Exactitud clasificación total (%)
AlexNet	N	95,6	99,6	97,6	98,2
	S	98,9	99,3	99,1	
	V	98,5	96,4	97,4	
	F	98,8	96,1	97,5	
	Q	99,1	99,4	99,3	
Customize 1	N	95,0	99,4	97,1	98,2
	S	98,5	98,9	98,7	
	V	99,4	96,6	98,0	
	F	98,7	97,0	97,9	
	Q	99,8	99,5	99,7	
Customize 2	N	92,1	99,1	95,5	97,0
	S	97,7	97,6	97,7	
	V	96,3	96,8	96,5	
	F	98,9	92,2	95,5	
	Q	99,7	98,5	99,1	

La tabla 3 compara la exactitud del método propuesto para la clasificación de arritmias cardiacas y otros trabajos en la literatura. Kachuee, Fazeli y Sarrafzadeh (2018) implementaron su propia arquitectura mediante redes neuronales convolucionales utilizando dos dataset: dataset MIT-BIH y el dataset PTB de PhysionNet. Realizaron un primer entrenamiento con el dataset PTB haciendo “transfer learning” de los pesos obtenidos en el entrenamiento que serán utilizados como pesos iniciales para el segundo entrenamiento con el dataset MIT-BIH. Así mismo Huang *et al.* (2019) implementaron CNN con el dataset MIT-BIH utilizando diferentes *batch-size* y *learning rate* en el proceso de entrenamiento. Este estudio logró el mayor nivel de exactitud —*accuracy*— reportado en la literatura hasta la fecha para los conjuntos de datos utilizados. Sin embargo, es importante destacar que el número de imágenes de prueba en este estudio fue menor en comparación con otros

trabajos previos (2520). Además, no se realizaron pruebas del modelo utilizando conjuntos de datos externos que no se utilizaron en el entrenamiento y la validación del modelo. Kojuri *et al.* (2015) utilizaron dos dataset: Datos ECG y Datos cuantitativo (antecedentes, examen físico y datos de pruebas de laboratorio). Los datos ECG se registraron con un dispositivo Cardiax conectado a un ordenador, mientras que los datos cuantitativos de ECG se obtuvieron a partir de la historia clínica, el examen físico y las pruebas de laboratorio. Sobre estos datos se implementaron dos redes neuronales artificiales diferentes: función de base radial (RBF) y perceptrón multicapa (MLP). Como resultado, el modelo con RBF tuvo una exactitud del 83% para el dataset 2 y una exactitud del 78% para el dataset 1. Con la red MLP se obtuvo una exactitud del 84.5% para el dataset 2 y una exactitud de 96% para el dataset 1. Safdarian, Jafarnia y Attarodi (2014) propusieron varios modelos: Red Neuronal Probabilística (PNN), K-Vecinos más cercanos (KNN), Perceptrón Multicapa (MLP) y Clasificación de Naive Bayes usando el dataset de PhysioNet PTB. La red que más se destacó fue Clasificación de Naive Bayes con una exactitud del 94.7%. Liu *et al.* (2015) propusieron una nueva característica de ECG ajustando una señal de ECG con una función polinómica de orden 20, definida como PoliECG-S y obtuvieron una exactitud del 94,4%. La exactitud obtenida por los modelos propuestos en este trabajo —mayor o igual al 97%— es superior a los reportados en la literatura. El rendimiento alcanzado por los modelos propuestos podría estar influido por la técnica de aumento de datos aplicada a las clases con menor número de muestras, el uso de redes neuronales convolucionales y la profundidad de las redes.

Simulador Bio-Tek BP Pump NIBP

Se utilizaron 590 muestras obtenidas del simulador, que corresponden a las clases N “latido normal” con diferentes rangos de latidos por minuto (BPM) —60-65-70— y V “contracción ventricular prematura”. Para esta prueba de desempeño se probaron dos de las cinco clases que pueden clasificar los modelos, debido a que el simulador solo genera las clases N y V.

La tabla 3 se presenta la métrica de exactitud de los cinco modelos al clasificar las muestras del simulador. Las pruebas mostraron que el mejor desempeño lo presentaron los modelos de las arquitecturas: Customize 2, VGG16, ResNet y Customize 1, en estos modelos la exactitud para la clasificación de las dos clases fue superior al 90%. Se destacó la arquitectura customize 2 que logró el mejor exactitud, identificando que la red puede abstraer mejor las características y generalizar diferentes muestras de latidos normales, debido a que las muestras del dataset obtenido por el simulador tienen diferentes amplitudes y diferentes rangos de BPM. La clase V, presentó mayor dificultad en la clasificación para los modelos, sin embargo, los resultados demuestran que los modelos pueden clasificar de manera correcta pacientes que padecen este tipo de arritmia.

Tabla 3: Métricas de desempeño (Accuracy): *Dataset MIT-BIH, ** Simulador "Bio-Tek BP Pump NIBP, ***Dataset PhysioNet PTB. Elaboración Propia

Modelos	Exactitud (%)	Conjunto de pruebas	Referencias
VGG16	98,8* 94,0**	4.000	Este trabajo
ResNet-50	98,4* 93,0**	4.000	Este trabajo
AlexNet	98,2* 82,2**	4.000	Este trabajo
Customize 1	98,2* 90,6**	4.000	Este trabajo
Customize 2	97,0* 96,3**	4.000	Este trabajo
CNN (filters=32)	95,9***	4.079	Kachuee, Fazeli y Sarrafzadeh, 2018
CNN (filters=34)	99,0*	2.520	Huang <i>et al.</i> , 2019
Clasificador MLP con una capa oculta y un algoritmo de propagación	95,6	94 pacientes	Kojuri <i>et al.</i> , 2015
Clasificador Naive Bayes	94,7***	137 registros de ECG	Safdarian, Jafarnia y Attarodi, 2014
Función polinómica de orden 20 (PoliECG-S)	94,4	--0--	

5. Conclusiones

En esta investigación se presentaron cinco modelos con diversas arquitecturas para la clasificación de cinco tipos de arritmias cardíacas. Entre estos modelos, se encontró que la arquitectura VGG16 demostró el mejor rendimiento en términos de exactitud promedio, alcanzando un 98,8%. Además, esta arquitectura obtuvo un alto valor de *recall*, superando el 99% para los latidos normales y más del 97% para los latidos con arritmias (S, V y F).

Adicionalmente, la aplicación de técnicas de *data augmentation*, para aumentar el número de muestras en clases con pocos, datos resultó en una mejora significativa en el rendimiento de la clasificación de dichas clases. Esto demuestra la efectividad de estas técnicas para abordar la escasez de datos y mejorar la capacidad del modelo para clasificar correctamente las muestras pertenecientes a esas clases.

Se evaluaron los modelos utilizando muestras generadas por el simulador Bio-Tek BP Pump NIBP, y se obtuvo un desempeño satisfactorio para cuatro de los cinco modelos propuestos: Customize 2, VGG16, ResNet y Customize 1. Estos resultados indican que el uso de redes neuronales convolucionales para la clasificación de arritmias cardíacas puede ser beneficioso y brindar apoyo a los médicos en la interpretación de los electrocardiogramas para la detección de arritmias. Aunque el sistema de clasificación aún no ha sido probado en tiempo real, se continúa investigando para su implementación en un sistema integrado con capacidad de procesamiento en tiempo real.

6. Referencias

- Chazal, P.; O'Dwyer, M.; Reilly, R. (2004). Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering*, 51(7), 1196-1206. doi:10.1109/TBME.2004.827359
- Goldberger, A.L.; Amaral, L.A.; Glass, L.; Hausdorff, J.M.; Ivanov, P.C.; Mark, R.G.; Mietus, J.E.; Moody, G.B.; Peng, C.K.; Stanley, H.E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 101(23), 215-220. doi:https://doi.org/10.1161/01.CIR.101.23.e215
- Gómez Herrero, G.; Gotchev, A.; Christov, I.; Egiazarian, K. (2005). Feature extraction for heartbeat classification using independent component analysis and matching pursuits. *Proceedings. (ICASSP '05). IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005. Philadelphia, PA, USA 4*, pp.725-728. doi:10.1109/ICASSP.2005.1416111
- Huang, J.; Chen, B.; Yao, B.; He, W. (2019). ECG Arrhythmia Classification Using STFT-Based Spectrogram and Convolutional Neural Network. *IEEE Access*, 7, 92871-92880. doi: https://doi.org/10.1109/ACCESS.2019.2928017
- Kachuee, M.; Fazeli, S.,; Sarrafzadeh, M. (2018). ECG Heartbeat Classification: A Deep Transferable Representation. *IEEE International Conference on Healthcare Informatics, 2018 IEEE International Conference on Healthcare Informatics. (ICHI). New York City, NY, USA pp. 443-444*. doi:10.1109/ICHI.2018.00092
- Khorrami, H.; Moavenian, M. (2010). A comparative study of DWT, CWT and DCT transformations in ECG arrhythmias classification. *Expert Systems with Applications*, 37(8), 5751-5757. doi: https://doi.org/10.1016/j.eswa.2010.02.033
- Kojuri, J.; Boostani, R.; Dehghani, P.; Nowroozipour, F.; Saki, N. (2015). Prediction of acute myocardial infarction with artificial neural networks in patients with nondiagnostic electrocardiogram. *Journal of Cardiovascular Disease Research*, 6(2), 51-59. doi:10.5530/jcdr.2015.2.2
- Laguna, P.; Jane, R.; Olmos, S.; Thakor, N.; Rix, H.; Caminal, P. (1996). Adaptive estimation of QRS complex wave features of ECG signal by the Hermite model. *Medical & biological engineering & computing*, 34(1), 58-88. doi: https://doi.org/10.1007/BF02637023
- Lanata, A.; Valenza, G.; Mancuso, C.; Scilingo, E. (2011). Robust multiple cardiac arrhythmia detection through bispectrum analysis. *Expert Systems with Applications*, 38(6), 6798-6804. doi: https://doi.org/10.1016/j.eswa.2010.12.066
- Li, T.; Zhou, M. (2016). ECG Classification Using Wavelet Packet Entropy and Random Forests. *Entropy*, 18(8), 285. doi:10.3390/e18080285
- Lin, S.W.; Ying, K.C.; Chen, S.C.; Lee, Z. J. (2008). Particle swarm optimization for parameter determination and feature selection of support vector machines. *Expert Systems with Applications*, 32(4), 1817-1824. doi: https://doi.org/10.1016/j.eswa.2007.08.088

- Liu, B.; Liu, J.; Wang, G.; Huang, K.; Li, F.; Zheng, Y.; Luo, Y.; Zhou, F. (2015). A novel electrocardiogram parameterization algorithm and its application in myocardial infarction detection. *Computers in Biology and Medicine*, 61, 178-184. doi: <https://doi.org/10.1016/j.combiomed.2014.08.010>
- Luz, E.; Nunes, T.; de Albuquerque, V.; Papa, J.; Menotti, D. (2013). ECG arrhythmia classification based on optimum-path forest. *Expert Systems with Applications*, 40(9), 3561-3573. doi: <https://doi.org/10.1016/j.eswa.2012.12.063>
- Moavenian, M.; Khorrami, H. (2010). A qualitative comparison of Artificial Neural Networks and Support Vector Machines in ECG arrhythmias classification. *Expert Systems with Applications*, 37(4), 3088-3093. doi: <https://doi.org/10.1016/j.eswa.2009.09.021>
- Moody, G.; Mark, R. (2001). The Impact of the MIT-BIH Arrhythmia Database. *IEEE engineering in medicine and biology*, 20(3), 45-50. doi: <https://doi.org/10.13026/C2F305>
- Moody, G.; Mark, R. (1989). QRS morphology representation and noise estimation using the Karhunen-Loeve transform. *Proceedings. Computers in Cardiology*, 269-272. doi:10.1109/CIC.1989.130540
- National Library of Medicine. (10 de 12 de 2020). MedlinePlus. Recuperado el 24 de 02 de 2022, de MedlinePlus: <https://medlineplus.gov/lab-tests/electrocardiogram/>
- Pal, S. (2019). ECG Monitoring: Present Status and Future Trend. En *Encyclopedia of Biomedical Engineering*. University of Calcutta, Kolkata, India. pp. 363-379. doi: <https://doi.org/10.1016/B978-0-12-801238-3.10892-X>
- Pyakillya, B.; Kazachenko, N.; Mikhailovsky, N. (2017). Deep Learning for {ECG} Classification. *Journal of Physics: Conference Series*, IOP Publishing. 913, 012004. doi: <https://doi.org/10.1088/1742-6596/913/1/012004>
- Revelo Luna, D. A.; Mejía Manzano, J. E.; Muñoz Chaves, J. A. (2021). Effect of Pre-processing of CT Images on the Performance of Deep Neural Networks Based Diagnosis of COVID-19. *Journal of Scientific & Industrial Research*, 80(11), 992-1000
- Safdarian, N.; Jafarnia D.N.,; Attarodi, G. (2014). A New Pattern Recognition Method for Detection and Localization of Myocardial Infarction Using T-Wave Integral and Total Integral as Extracted Features from One Cycle of ECG Signal. *Journal of Biomedical Science and Engineering*, 07, 818-824. doi:10.4236/jbise.2014.710081
- Song, M.H.; Lee, J.; Cho, S.P.; Lee, K.J.; Yoo, S.K. (2005). Support vector machine based arrhythmia classification using reduced features. *International journal of control automation and systems*, 3(4), 571-579. doi: <http://dx.doi.org/OAK-2005-06773>
- Verma, K. K. (2021). Deep Learning Approach to Recognize COVID-19, SARS and Streptococcus. *Journal of Scientific & Industrial Research*, 80(01), 51-59.
- Wiggins, M.; Saad, A.; Litt, B.; Vachtsevanos, G. (2008). Evolving a Bayesian classifier for ECG-based age classification in medical applications. *Applied Soft Computing*, 8(1), 599-608. doi: <https://doi.org/10.1016/j.asoc.2007.03.009>

World Health Organization. (11 de 06 de 2021). World Health Organization. Obtenido de [https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))

Ye, C.; Coimbra, M. T.; Kumar, V. (2010). Arrhythmia detection and classification using morphological and dynamic features of ECG signals. Annual International Conference of the IEEE Engineering in Medicine and Biology 2010, Buenos Aires, Argentina, pp.1918-1921. doi:10.1109/IEMBS.2010.5627645

Yu, S. N.; Chen, Y. H. (2007). Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. Pattern Recognition Letters, 28(10), 1142-1150. doi: <https://doi.org/10.1016/j.patrec.2007.01.017>

Yu, S. N. and Chou, K.T. (2009). Selection of significant independent components for ECG beat classification. Expert Systems with Applications, 36(2), 2088-2096. doi: <https://doi.org/10.1016/j.eswa.2007.12.016>

Zhang, L.; Karimzadeh, M.; Welch, M.; McIntosh, C. and Wang, B. (2021). Chapter 7 - Analytics methods and tools for integration of biomedical data in medicine. Xing, L.; Giger, M.L., and Min, J.K. Artificial Intelligence in Medicine. Academic Press, pp. 113-129. doi: <https://doi.org/10.1016/B978-0-12-821259-2.00007-7>