

Deep Learning for Cardiac Rhythm Assessment: Evaluating CNN Models on ECG Data.

Aprendizaje profundo para la evaluación del ritmo cardiaco: Evaluación de modelos CNN en datos de ECG.

Victor Manuel Astudillo Delgado ¹ , David Armando Revelo Luna ² , Javier Andrés Muñoz Chaves ³ 

¹ Corporación Universitaria Comfacauca; victorastudillo@unicomfacauca.edu.co

² Corporación Universitaria Comfacauca; drevelo@unicomfacauca.edu.co

³ Corporación Universitaria Comfacauca; jmunoz@unicomfacauca.edu.co

* Correspondencia: victorastudillo@unicomfacauca.edu.co

Citación: Astudillo, V. ; Revelo, D.; Muñoz, J. Aprendizaje profundo para la evaluación del ritmo cardiaco: Evaluación de modelos CNN en datos de ECG. I + T + C Investigación, Tecnología y Ciencia. Vol 1. Num. 17. 2023.



Derechos de autor: © 2023 por los autores. Presentado para posible publicación en acceso abierto bajo los términos y condiciones de la licencia Creative Commons Attribution (CC BY NC SA) (https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es_ES)

Nota del editor: El Sello editorial Unicomfacauca se mantiene neutral con respecto a los reclamos que se generen en esta publicación.

Resumen:

El electrocardiograma (ECG) es una técnica para detectar problemas en el ritmo cardíaco y evaluar el sistema cardiovascular. Tradicionalmente, los médicos confiaban en observaciones manuales, pero esto tenía limitaciones en términos de precisión. En esta investigación, se utilizaron redes neuronales convolucionales para la identificación de arritmias cardiacas en pacientes. Se entrenaron tres modelos diferentes, usando arquitecturas: VGG16 y ResNet-50, así mismo una propuesta por los investigadores. Todos los modelos se entrenaron con el *dataset* (PhysioNet MIT-BIH), con la misma cantidad de datos y configuración. La evaluación de los modelos se realizó utilizando métricas: *precisión*, *recall*, *F1Score* y *accuracy*. El modelo VGG16 demostró ser el más efectivo, logrando una *accuracy* del 98,8%. Los resultados de la investigación pueden llegar a mejorar la detección de arritmias cardiacas, lo que podría llevar a diagnósticos más precisos y un mejor cuidado de la salud cardiovascular en pacientes.

Palabras clave: Clasificación de ECG, segmentación de latidos, redes neuronales convolucionales.

Abstract: The electrocardiogram (ECG) is a technique for detecting heart rhythm problems and evaluating the cardiovascular system. Traditionally, physicians relied on manual observations, but this had limitations in terms of accuracy. In this research, convolutional neural networks were used for the identification of cardiac arrhythmias in patients. Three different models were trained, using architectures: VGG16 and ResNet-50, as well as one proposed by the researchers. All models were trained with the dataset (PhysioNet MIT-BIH), with the same amount of data and configuration. The evaluation of the models was performed using the following metrics: precision, recall, F1Score and accuracy. The VGG16 model proved to be the most effective, achieving an accuracy of 98.8%. The results of the research may lead to improved detection of cardiac arrhythmias, which could lead to more accurate diagnoses and better cardiovascular health care for patients.

Keywords: ECG classification, beat segmentation, convolutional neural networks.

DOI: 10.57173/ritc.v1n17a1

1. Introducción

El electrocardiograma (ECG) es una técnica no invasiva que mide las señales eléctricas producidas por el corazón. Esta herramienta se basa en la detección de cambios en el potencial bioeléctrico a lo largo del ciclo cardíaco, utilizando electrodos situados en la superficie de la piel del paciente [1]. El análisis del ECG permite la detección de diversas enfermedades que pueden afectar su funcionamiento normal, como arritmias cardíacas, ataques cardíacos, insuficiencia cardíaca y obstrucción de las arterias [2].

Una estrategia para detectar estas arritmias es analizar las señales de ECG [3]. En el pasado, este análisis se dividía en dos etapas: la extracción de características y la clasificación de patrones. Los médicos empleaban características heurísticas diseñadas manualmente o utilizan arquitecturas de aprendizaje superficial para interpretar los ECG [4]. Sin embargo, este enfoque tenía limitaciones, ya que a menudo no identificaba las características más relevantes para lograr un diagnóstico preciso a partir de las señales.

Ha surgido un creciente interés en la aplicación de métodos computacionales en el campo de la salud [5, 6]. En investigaciones previas relacionadas con el análisis y la categorización de señales de electrocardiograma (ECG) utilizando técnicas de aprendizaje automático [7, 8], se ha establecido generalmente un marco de trabajo que se divide en cuatro categorías fundamentales: Procesamiento, esta etapa se enfoca en la captura de las señales ECG y en la reducción del ruido introducido por la actividad muscular del paciente o por factores externos; Segmentación, implica la delimitación de la parte de la señal que contiene la información de mayor relevancia, que suele ser el complejo QRS; Extracción de características, en esta fase se obtienen características específicas de la señal que son relevantes para el análisis subsiguiente; Clasificación, es el proceso mediante el cual, utilizando las características previamente obtenidas, se lleva a cabo la clasificación en categorías predefinidas [9]. Este enfoque estructurado y secuencial proporciona un marco sólido para el análisis de señales de ECG, lo que resulta fundamental para la detección y diagnóstico de enfermedades cardíacas y la mejora de la atención médica.

Se han empleado diversas estrategias para extraer información relevante de las señales de electrocardiograma (ECG), centrándose especialmente en el análisis del complejo QRS a través del reconocimiento de patrones. Por ejemplo, De Chazal et al. [7] identificaron cuatro características relacionadas con el intervalo RR en las señales de ECG, como el intervalo entre latidos consecutivos y promedios de intervalos RR. Otros investigadores propusieron un método de análisis de ECG para abordar la teoría de aproximación en espacios de Hilbert. El enfoque se basa en transformaciones afines de sistemas Hermite ortogonales y optimiza dos parámetros libres para lograr la mejor aproximación de la señal ECG utilizando un número fijo de coeficientes de Fourier. Se emplean técnicas de optimización como Particle Swarm Optimization (PSO), Nelder-Mead (NM) y Monte Carlo (MC) en un marco de búsqueda de coincidencias. El método propuesto logra una buena relación de compresión y alta precisión [10]. En ese sentido también se usaron en transformaciones ortogonales, incluyendo el Polinomios de Legendre (LPT) y en la Transformación de Karhunen-Loève (KLT), que representan de manera efectiva los cambios en la morfología del segmento ST. También se utilizó un clasificador de k-Nearest Neighbors [11].

También se han empleado transformaciones como la Transformada de Coseno Discreta (DCT), la Transformada Wavelet Continua (CWT) y la Transformada Wavelet Discreta (DWT) para analizar las señales de ECG en diferentes dominios y extraer características relevantes.

Por ejemplo, Khorrami & Moavenian [12] utilizaron la CWT para mejorar la clasificación de arritmias ECG, mientras que Song, et al. [13] aplicaron la transformada wavelet y el análisis discriminante lineal (LDA) para la clasificación. Además, se han utilizado técnicas como la transformación wavelet discreta junto con redes neuronales probabilísticas (PNN) [14] y combinaciones de características morfológicas y dinámicas, incluyendo la transformada de wavelet (WT) y el análisis de componentes independientes (ICA) [15]. Li y Zhou [16] propusieron un enfoque que empleaba la entropía de paquetes wavelet (WPE) y bosques aleatorios (RF) para clasificar las señales de ECG.

En la etapa final de clasificación, se emplean varios clasificadores populares, como la máquina de soporte vectorial (SVM), redes neuronales artificiales (ANN), k-vecinos más cercanos (KNN) y probabilidades bayesianas.

En ese sentido Lin, et al. [17] y Moavenian & Khorrami [18], utilizaron SVM con la base de datos MIT-BIH para clasificar arritmias, obtuvieron un máximo MSE (mean square error) 0,15. Song et al. [13] identificaron seis tipos de arritmias con un 98,49% de accuracy, mientras que Ye et al. [15] reconocieron 15 clases de latidos con un 99,66% de accuracy en un grupo de prueba de 85.945 muestras. Yu y Chou [19] consideraron ocho tipos de latidos y obtuvieron un 98,71% de accuracy.

Kachuee et al. [20] utilizaron ANN para identificar cinco tipos de arritmias con un 93,4% y 95,9% accuracy en el conjunto de datos MIT-BIH y PTB de PhysionNet, respectivamente. Además, Lanatá, et al. [8] emplearon KNN para reconocer seis clases de arritmias mediante análisis espectral de orden superior.

Wiggins et al. [21] utilizaron probabilidades bayesianas para clasificar a los pacientes por edad a partir de la información extraída de sus electrocardiogramas (ECG), con la red bayesiana evolucionada lograron 86,25% de AUC. La mayoría de las investigaciones en este campo se basan en técnicas de aprendizaje automático supervisado, aunque algunos estudios han explorado enfoques no supervisados y métodos estadísticos.

Destaca que solo unos estudios han utilizado redes neuronales convolucionales para la clasificación de arritmias cardíacas [3, 20]. El estudio actual propone explorar estas redes y comparar diversas arquitecturas. En este estudio, se busca evaluar un clasificador de arritmias en señales de ECG mediante la implementación de diversas arquitecturas de redes neuronales convolucionales. Además, se compararán los resultados obtenidos con las arquitecturas: VGG16, ResNet-50 y la propuesta por los investigadores. La investigación se desarrolló en cuatro etapas clave: procesamiento de señales, segmentación, extracción de características y clasificación, con el objetivo principal de identificar cinco tipos de arritmias en pacientes.

Para llevar a cabo este análisis, se entrenaron las redes utilizando el conjunto de datos de arritmias de PhysionNet MIT-BIH y se evaluaron utilizando una porción de este conjunto de datos. El rendimiento de los modelos se evaluó mediante métricas de desempeño, que incluyen la exactitud (accuracy), la sensibilidad (recall), la precisión (precision) y el puntaje F1 (F1score).

2. Materiales y métodos

El conjunto de datos utilizado en esta investigación proviene de la base de datos de ECG de diagnóstico de arritmia (PhysioNet MIT-BIH). Este conjunto de datos comprende 48 grabaciones, cada una de ellas con una duración de 30 minutos, obtenidas de un grupo de 47 sujetos cuyas edades oscilan entre los 23 y los 89 años. Esta diversidad en las edades y condiciones de los pacientes brinda una muestra representativa que permite llevar a cabo un análisis exhaustivo y preciso en la clasificación de arritmias cardíacas. Las mediciones se realizaron en la derivación II (MLII) y en una de las derivaciones modificadas (V1, V2, V4 o V5), y cada latido fue anotado por al menos dos cardiólogos [22, 23]. El conjunto de datos se adquirió con una frecuencia de muestreo de 360 Hz y una resolución de 11 bits en un rango de 10 mV. El formato en el que se obtuvo este dataset fue en CSV, a través de la plataforma abierta KAGGLE.

En cuanto al procesamiento y la segmentación de los datos ECG, se aplicó la metodología propuesta por [20], empleando la derivación II del ECG en todos los experimentos y ajustando la frecuencia de entrada a 125 Hz. El enfoque principal de esta investigación se centró en la clasificación de cinco clases de arritmias, las cuales representan el 95% de todos los datos de arritmias presentes en la base de datos de MIT-BIH, como se detalla en la Tabla 1.

Tabla 1. Anotaciones de las clases seleccionadas.

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

Con el propósito de aumentar el tamaño de la muestra, se aplicaron técnicas de aumento de datos (data augmentation) específicamente en las clases S y F. Se seleccionaron 1000 muestras para el conjunto de validación y 800 para las pruebas en cada una de las clases. Esta estrategia permitió expandir el conjunto de datos y mejorar la capacidad de generalización del modelo en la tarea de clasificación de arritmias.

2.1. Procesamiento datos

El procesamiento de los datos ECG y la segmentación de latidos se llevan a cabo en varios pasos. Inicialmente, se divide la señal continua en ventanas de 10 segundos y se calculan los valores máximos y mínimos en cada ventana. Luego, los valores de la señal se escalan para estar en un rango de 0 a 1 usando la ecuación 1. A continuación, se detectan los picos R en cada ventana utilizando el cruce por cero de la primera derivada y se verifica si cada pico R es al menos el 80% del valor máximo. Se calcula el intervalo R-R como el tiempo promedio entre picos en cada ventana.

Se segmentan muestras independientes comenzando desde un pico R y extendiéndose hasta 1.2 veces el tiempo promedio calculado. Para asegurar una longitud uniforme, se establece una longitud predefinida de 187 datos para cada muestra, rellenando con ceros si es

necesario. Estos pasos son fundamentales en el procesamiento de datos ECG para su posterior análisis y clasificación de arritmias cardíacas.

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

2.3. Arquitectura de la CNN

Esta investigación se enfocó en el uso de redes neuronales convolucionales (CNN) para clasificar arritmias cardíacas, explorando tres arquitecturas diferentes, incluyendo ResNet-50, VGG16 y la propuesta por los autores (customize 1). Se adaptaron las capas de entrada y salida para acomodarse a datos de entrada de 187x1. El entrenamiento se realizó con TensorFlow y Keras, utilizando 100 epochs y un batch-size de 64 para todas las arquitecturas. La figura 1, muestra la arquitectura de las redes propuestas.

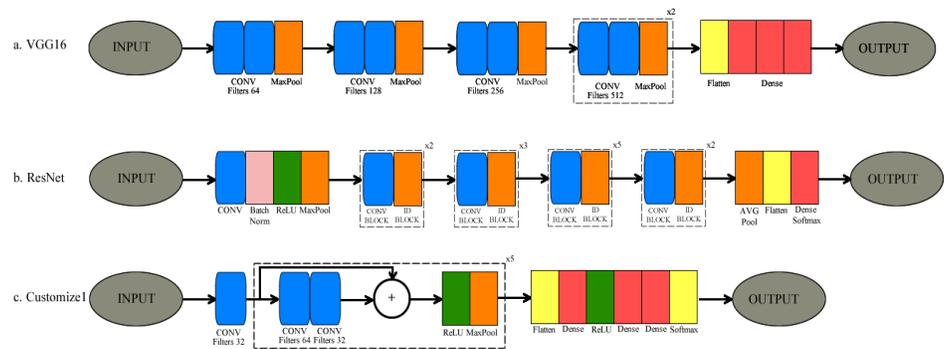


Figura 1. Arquitecturas de red propuestas: a. VGG16, b. ResNet, c. Customize 1.

2.4. Métricas de desempeño

Para evaluar el rendimiento de las redes neuronales convolucionales entrenadas, se utilizaron métricas, tales como: *precisión*, *recall*, *F1Score* y *accuracy*. Estas métricas se calcularon utilizando las siguientes fórmulas:

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

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

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

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

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

3. Resultados y Discusión

3.1. Procesamiento de los datos

Se realizó el procesamiento y segmentación de la base de datos de PhysioNet MIT-BIH. La señal original se mostró en una ventana de 10 segundos y luego se normalizó en el rango de [0-1] para facilitar la detección de picos R. Los intervalos R-R se calcularon a partir de la ubicación de los picos R sucesivos. Todas las muestras se ajustaron a una longitud de 187 datos. Este enfoque se aplicó a todas las clases de arritmias, centrándose en la segmentación del complejo QRS debido a su reflejo de la actividad eléctrica del corazón y la información de la frecuencia cardíaca. La figura 2 muestra gráficamente el procesamiento de los datos para su posterior evaluación con los modelos.

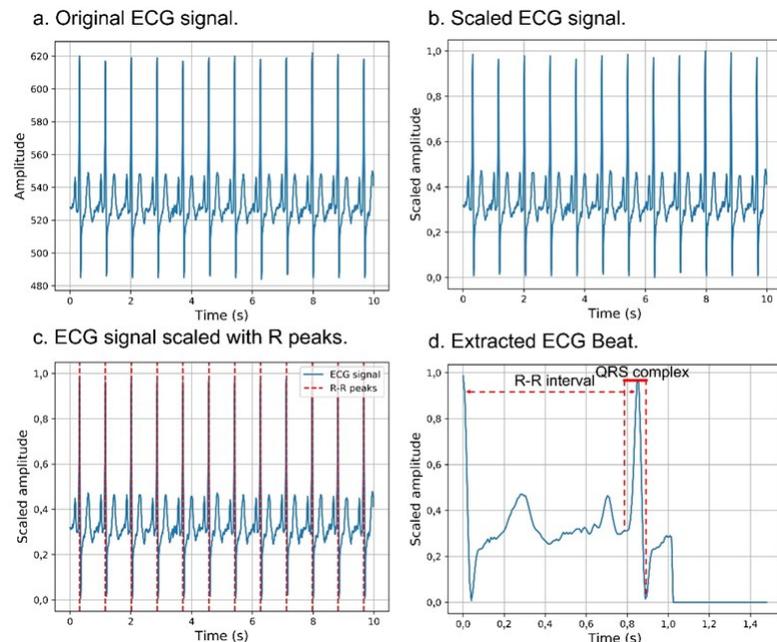


Figura 2. (a) Señal ECG original (b) Señal ECG normalizada (c) Señal ECG con los picos R identificados (d) Detalle de un intervalo R-R con su respectivo complejo QRS.

3.2. Desempeño de los modelos

Se llevaron a cabo las evaluaciones de los tres modelos basados en las arquitecturas previamente mencionadas, utilizando 800 muestras por clase durante el proceso de entrenamiento. A partir de las matrices de confusión (Figura 3), se puede identificar que los modelos son capaces de predecir y distinguir diferentes clases de arritmias cardíacas. Las clases N (latidos normales) y Q (ritmo inclasificable) destacan por tener el mayor número de verdaderos positivos en los cinco modelos, con un bajo número de falsos positivos. Por otro lado, las clases V (contracción ventricular prematura) y F (fusión de latido ventricular y normal) presentan un menor número de verdaderos positivos y un mayor número de falsos positivos, ya que los modelos a menudo clasifican erróneamente estas clases como parte de la clase N.

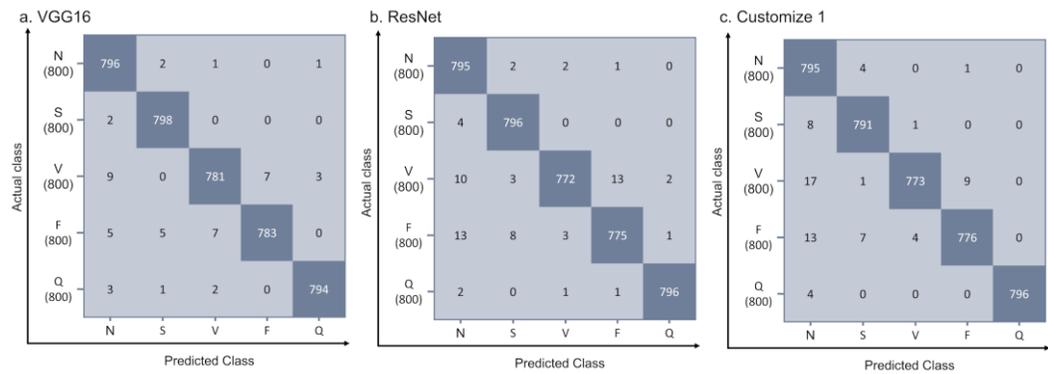


Figura 3. Matriz de confusión para la clasificación de los latidos del corazón: a. VGG16, b. ResNet-50, c. Customize 1.

La Tabla 2, presenta las métricas de accuracy obtenidas por los modelos correspondientes: 98,8% VGG16, 98,4% ResNet-50 y 98,2% Customize 1. La arquitectura VGG16 obtuvo el mayor accuracy, indicando que este modelo clasifica las muestras con mayor precisión en la clase correcta. Además, la arquitectura VGG16 logró el recall más alto para las clases de latidos normales (N) y latidos con arritmias (S, V y F), lo que sugiere una identificación más efectiva de casos positivos y una menor tasa de falsos negativos.

La comparación entre el rendimiento del método propuesto para la clasificación de arritmias cardíacas con otros estudios previos en la literatura. Varios enfoques se han utilizado en investigaciones anteriores para abordar este problema. Kachuee et al. [20] desarrollaron una arquitectura de redes neuronales convolucionales utilizando dos conjuntos de datos, MIT-BIH y PTB de Physionet. Su enfoque incluyó un proceso de entrenamiento previo con el conjunto de datos PTB, seguido de la inicialización de pesos mediante "transfer learning" para el segundo entrenamiento con MIT-BIH. En otro estudio [3], se implementaron redes neuronales convolucionales utilizando el conjunto de datos MIT-BIH, con variaciones en el batch-size y learning rate durante el proceso de entrenamiento. Este enfoque logró la mayor precisión registrada hasta la fecha en la literatura para los conjuntos de datos utilizados, pero tuvo limitaciones en términos de tamaño de muestra de prueba. Kojuri et al. [24] utilizaron dos conjuntos de datos, uno basado en datos ECG y otro en datos cuantitativos. Implementaron dos tipos de redes neuronales artificiales, función de base radial (RBF) y perceptrón multicapa (MLP). El accuracy más alto de 96% se logró usando la MLP con el dataset 1. Safdarian et al. [25] 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 clasificación de Naive Bayes se destacó con un accuracy del 94,7%. Liu et al. [26] introdujeron una nueva característica de ECG llamada PoliECG-S y lograron un accuracy del 94,4%.

El método propuesto en este estudio supera el rendimiento de los modelos anteriores, alcanzando una precisión superior ($\geq 97\%$) posiblemente debido a técnicas como data augmentation, el uso de redes neuronales convolucionales y la profundidad de las redes.

Tabla 2. Métricas de desempeño (Accuracy): *Dataset MIT-BIH, **Dataset PhysioNet PTB.

Modelos	Accuracy (%)	Conjunto de pruebas	Referencias
VGG16	98,8	4.000	Este trabajo
ResNet-50	98,4	4.000	Este trabajo
Customize 1	98,2	4.000	Este trabajo
CNN (filters=32)	95,9**	4.079	[20]
CNN (filters=34)	99,0*	2.520	[3]
Clasificador MLP con una capa oculta y un algoritmo de propagación	95,6	94 pacientes	[24]
Clasificador Naive Bayes	94,7**	137 registros de ECG	[25]
Función polinómica de orden 20 (PolIECG-S)	94,4	--o--	[26]
Clasificador Naive Bayes	94,7**	137 registros de ECG	[25]
Función polinómica de orden 20 (PolIECG-S)	94,4	--o--	[26]

5. Conclusiones

En este estudio, se evaluaron tres modelos con diferentes arquitecturas para la clasificación de arritmias cardíacas. La arquitectura VGG16 sobresalió como el modelo más efectivo, logrando un promedio de accuracy del 98,8%, superando a las otras arquitecturas evaluadas.

La aplicación de técnicas de data augmentation para abordar la escasez de datos en clases como la S y F, contribuyó a equilibrar la representación de clases subrepresentadas y permitió que los modelos aprendieran de manera más efectiva las características distintivas de estas clases, dando como resultado una mejora significativa en el rendimiento de clasificación de las mismas.

Aunque el sistema de clasificación aún no se ha probado en tiempo real, este estudio establece una base sólida para investigaciones futuras y desarrollos. La implementación de un sistema integrado con capacidad de procesamiento en tiempo real podría tener un impacto significativo en el diagnóstico y la atención médica relacionados con las arritmias cardíacas.

Contribuciones de autor: Conceptualización, V. Astudillo, D. Revelo, J. Munoz; metodología, V. Astudillo, D. Revelo; software, V. Astudillo; validación, V. Astudillo; análisis formal, V. Astudillo, D. Revelo, J. Munoz; investigación, V. Astudillo; curación de datos, V. Astudillo; redacción — preparación

del borrador original, V. Astudillo; redacción: revisión y edición, D. Revelo, J. Muñoz; supervisión, D. Revelo, J. Muñoz;

Todos los autores han leído y aceptado la versión publicada del manuscrito.

Fondos: Esta investigación fue financiada por el proyecto de Jóvenes Investigadores e Innovadores en el Departamento del Cauca.

Agradecimientos: El joven investigador Victor Manuel Astudillo Delgado y su tutor Javier Muñoz Chaves de la Corporación Universitaria Comfacauca, agradecen al proyecto de Jóvenes Investigadores e Innovadores en el Departamento del Cauca. Así mismo, al Mg. David Revelo Luna por su aporte en las discusiones y desarrollos, en torno a esta área del conocimiento.

Conflictos de interés: Los autores declaran no tener ningún conflicto de intereses.

Referencias

- [1] L. Zhang, M. Karimzadeh, M. Welch, C. McIntosh y B. Wang, "Chapter 7 - Analytics methods and tools for integration of biomedical data in medicine," en *Artificial Intelligence in Medicine*, 2021, pp. 113-129. <https://doi.org/10.1016/B978-0-12-821259-2.00007-7>.
- [2] National Library of Medicine, "MedlinePlus," 10 de diciembre de 2020. [En línea]. Disponible en: <https://medlineplus.gov/lab-tests/electrocardiogram/>. [Último acceso: 24 de febrero de 2022].
- [3] J. Huang, B. Chen, B. Yao y W. He, "ECG Arrhythmia Classification Using STFT-Based Spectrogram and Convolutional Neural Network," *IEEE Access*, vol. 7, pp. 92871-92880, 2019. <https://doi.org/10.1109/ACCESS.2019.2928017>.
- [4] B. Pyakillya, N. Kazachenko y N. Mikhailovsky, "Deep Learning for ECG Classification," *Journal of Physics: Conference Series*, vol. 913, p. 012004, 2017. <https://doi.org/10.1088/1742-6596/913/1/012004>.
- [5] D. A. Revelo Luna, J. E. Mejía Manzano y J. A. Muñoz Chaves, "Effect of Pre-processing of CT Images on the Performance of Deep Neural Networks Based Diagnosis of COVID-19," *Journal of Scientific & Industrial Research*, vol. 80, n° 11, pp. 992-1000, 2021. <http://nopr.niscpr.res.in/handle/123456789/58523>.
- [6] K. K. Verma, "Deep Learning Approach to Recognize COVID-19, SARS and Streptococcus," *Journal of Scientific & Industrial Research*, vol. 80, n° 01, pp. 51-59, 2021. <http://nopr.niscpr.res.in/handle/123456789/55855>.
- [7] P. Chazal, M. O'Dwyer y R. Reilly, "Automatic classification of heartbeats using ECG morphology and heartbeat interval features," *IEEE Transactions on Biomedical Engineering*, vol. 51, n° 7, pp. 1196-1206, 2004. <https://doi.org/10.1109/TBME.2004.827359>.
- [8] A. Lanatá, G. Valenza, C. Mancuso y E. Scilingo, "Robust multiple cardiac arrhythmia detection through bispectrum analysis," *Expert Systems with Applications*, vol. 38, n° 6, pp. 6798-6804, 2011. <https://doi.org/10.1016/j.eswa.2010.12.066>.
- [9] E. J. Luz, T. Nunes, V. H. de Albuquerque, J. Papa y D. Menotti, "ECG arrhythmia classification based on optimum-path forest," *Expert Systems with Applications*, vol. 40, n° 9, pp. 3561-3573, 2013. <https://doi.org/10.1016/j.eswa.2012.12.063>.
- [10] T. Dózsa and P. Kovács, "ECG Signal Compression Using Adaptive Hermite Functions," in *ICT Innovations 2015*, S. Loshkovska and S. Koceski, Eds. Cham: Springer International Publishing, 2016, pp. 245-254. https://doi.org/10.1007/978-3-319-25733-4_25.
- [11] M. Amon and F. Jager, "Electrocardiogram ST-Segment Morphology Delineation Method Using Orthogonal Transformations," *PLOS ONE*, vol. 11, no. 2, pp. 1-18, Feb. 2016. <https://doi.org/10.1371/journal.pone.0148814>.
- [12] H. Khorrami y M. Moavenian, "A comparative study of DWT, CWT and DCT transformations in ECG arrhythmias classification," *Expert Systems with Applications*, vol. 37, n° 8, pp. 5751-5757, 2010. <https://doi.org/10.1016/j.eswa.2010.02.033>.

- [13] M. H. Song, J. Lee, S. P. Cho, K. J. Lee y S. K. Yoo, "Support vector machine based arrhythmia classification using reduced features," *INTERNATIONAL JOURNAL OF CONTROL AUTOMATION AND SYSTEMS*, vol. 3, n° 4, pp. 571-579, 2005. <https://ir.ymlib.yonsei.ac.kr/handle/22282913/149913>.
- [14] S. N. Yu y Y. H. Chen, "Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network," *Pattern Recognition Letters*, vol. 28, n° 10, pp. 1142-1150, 2007. <https://doi.org/10.1016/j.patrec.2007.01.017>.
- [15] C. Ye, M. T. Coimbra y V. Kumar, "Arrhythmia detection and classification using morphological and dynamic features of ECG signals," *Annual International Conference of the IEEE Engineering in Medicine and Biology*, pp. 1918-1921, 2010. doi: 10.1109/IEMBS.2010.5627645.
- [16] T. Li y M. Zhou, "ECG Classification Using Wavelet Packet Entropy and Random Forests," *Entropy*, vol. 18, n° 8, 2016. <https://doi.org/10.3390/e18080285>.
- [17] S.-W. Lin, K.-C. Ying, S.-C. Chen y Z.-J. Lee, "Particle swarm optimization for parameter determination and feature selection of support vector machines," *Expert Systems with Applications*, vol. 32, n° 4, pp. 1817-1824, 2008. <https://doi.org/10.1016/j.eswa.2007.08.088>.
- [18] M. Moavenian y H. Khorrami, "A qualitative comparison of Artificial Neural Networks and Support Vector Machines in ECG arrhythmias classification," *Expert Systems with Applications*, vol. 37, n° 4, pp. 3088-3093, 2010. <https://doi.org/10.1016/j.eswa.2009.09.021>.
- [19] S.-N. Yu y K.-T. Chou, "Selection of significant independent components for ECG beat classification," *Expert Systems with Applications*, vol. 36, n° 2, pp. 2088-2096, 2009. <https://doi.org/10.1016/j.eswa.2007.12.016>.
- [20] M. Kachuee, S. Fazeli y M. Sarrafzadeh, "ECG Heartbeat Classification: A Deep Transferable Representation" *IEEE International Conference on Healthcare Informatics*, p. 2018 IEEE International Conference on Healthcare Informatics, 2018. <https://doi.org/10.1109/ICHI.2018.00092>.
- [21] M. Wiggins, A. Saad, B. Litt y G. Vachtsevanos, "Evolving a Bayesian classifier for ECG-based age classification in medical applications," *Applied Soft Computing*, vol. 8, n° 1, pp. 599-608, 2008. <https://doi.org/10.1016/j.asoc.2007.03.009>.
- [22] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. Ivanov, R. Mark, J. Mietus, G. Moody, C.-K. Peng y E. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, n° 23, p. 215-220, 2000. <https://doi.org/10.1161/01.CIR.101.23.e215>.
- [23] G. Moody y R. Mark, "The Impact of the MIT-BIH Arrhythmia Database," *IEEE engineering in medicine and biology*, vol. 20, n° 3, pp. 45-50, 2001. <https://doi.org/10.13026/C2F305>.
- [24] J. Kojuri, R. Boostani, P. Dehghani, F. Nowroozipour y N. Saki, "Prediction of acute myocardial infarction with artificial neural networks in patients with nondiagnostic electrocardiogram," *Journal of Cardiovascular Disease Research*, vol. 6, n° 2, pp. 51-59, 2015. <http://dx.doi.org/10.5530/jcdr.2015.2.2>.
- [25] N. Safdarian, N. Jafarnia Dabanloo y G. Attarodi, "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*, vol. 07, pp. 818-824, 2014. <http://dx.doi.org/10.4236/jbise.2014.710081>.
- [26] B. Liu, J. Liu, G. Wang, K. Huang, F. Li, Y. Zheng, Y. Luo y F. Zhou, "A novel electrocardiogram parameterization algorithm and its application in myocardial infarction detection," *Computers in Biology and Medicine*, vol. 61, pp. 178-184, 2015. <https://doi.org/10.1016/j.combiomed.2014.08.01>.