

Detección de arritmias con fotopletismografía utilizando dos métodos de aprendizaje automático

Detection of arrhythmias with photoplethysmography using two machine learning methods

Arianna Carralero Paredes ^{1*} <https://orcid.org/0000-0003-1169-2375>

Alexander Alexeis Suárez León ¹ <https://orcid.org/0000-0002-9393-4552>

Ramón Arturo Rodríguez Hecharría ² <https://orcid.org/0000-0001-9233-7011>

Enrique Gómez Villariño ² <https://orcid.org/0000-0002-0896-5080>

Alexander Sónora Mengana ³ <https://orcid.org/0000-0003-1649-3383>

Juan Carlos García Naranjo ³ <https://orcid.org/0000-0001-7872-6758>

¹ Departamento de Ingeniería Biomédica, Facultad de Ingeniería en Telecomunicaciones, Informática y Biomédica, Universidad de Oriente.

² Sala de Cardiología, Hospital Provincial Saturnino. Avenida de Los Libertadores s/n entre 4ta y 6ta, Reparto Sueño.

³ Centro de Biofísica Médica. Patricio Lumumba s/n Santiago de Cuba.

* Autor para la correspondencia. (arianna.carralero@uo.edu.cu)

RESUMEN

En la actualidad nuevos estudios señalan las potencialidades de la señal fotopleletismográfica para detectar arritmias cardíacas. La adquisición de la señal fotopleletismográfica es menos compleja en comparación con la adquisición del electrocardiograma y requiere de un único sensor, superándolo en sencillez y reducción de costos. El presente estudio tiene como objetivo desarrollar dos algoritmos de aprendizaje automático para detectar arritmias, específicamente: fibrilación auricular, bradicardia sinusal y taquicardia sinusal. Los dos algoritmos utilizan técnicas diferentes, uno está basado en Máquinas de Vectores Soporte y el otro en redes neuronales Perceptrón Multicapa. Para el entrenamiento y evaluación de los algoritmos se utilizaron 117 registros de la base de datos del PhysioNet/Computing in Cardiology Challenge 2015. Estos registros fueron reanotados por dos especialistas en cardiología. El algoritmo basado en Máquinas de Vectores Soporte mostró una sensibilidad del 73% para fibrilación auricular, 77% para bradicardia y 93% para taquicardia, mientras que para el algoritmo basado en Perceptrón Multicapa fue de 74%, 87% y 89% respectivamente. El modelo basado en Máquinas de Vectores Soporte durante el proceso de evaluación obtuvo una exactitud global del 75%, mientras que el basado en Perceptrón Multicapa logró una exactitud global del 77%. Los algoritmos propuestos demandan pocos recursos de cómputo por lo que pueden ser implementados en dispositivos portátiles. Los resultados son similares a varios estudios reportados en la literatura orientados a la detección de arritmias basándose únicamente en la señal fotopleletismográfica.

Palabras clave: fotopleletismografía; arritmias; Máquinas de Vectores Soporte; redes neuronales Perceptrón Multicapa.

ABSTRACT

Currently new studies point out the potential of photoplethysmographic signal to detect arrhythmias. The acquisition of the photoplethysmographic signal is less complex compared to the acquisition of the electrocardiogram and requires a single sensor, surpassing it in simplicity and cost reduction. The objective of this work is to develop two machine learning algorithms to detect arrhythmias, specifically: atrial fibrillation, sinus bradycardia, and sinus tachycardia. The two algorithms use different techniques, one is

based on Support Vector Machines and the other on Multilayer Perceptron neural networks. For the training and evaluation of the algorithms, 117 records from the PhysioNet/Computing in Cardiology Challenge 2015 database were used. These records were annotated by two cardiology specialists. The Support Vector Machines based algorithm showed a sensitivity of 73% for atrial fibrillation, 77% for bradycardia and 93% for tachycardia, while for the Multilayer Perceptron based algorithm it was 74%, 87% and 89% respectively. The Support Vector Machines based model during the evaluation process achieved an overall accuracy of 75%, while the Multilayer Perceptron based model achieved an overall accuracy of 77%. The proposed algorithms require few computing resources so they can be implemented on portable devices. The results are similar to several studies reported in the literature aimed at detecting arrhythmias based solely on the photoplethysmographic signal.

Keywords: photoplethysmography; arrhythmias; Support Vector Machines; Multilayer Perceptron neural networks.

Recibido: 21/06/2024

Aceptado: 18/12/2024

Introducción

Las enfermedades cardiovasculares (ECV) son la primera causa de muerte a nivel mundial. Un tercio de las muertes causadas por enfermedades no transmisibles se deben a ECV (Revueltas-Agüero et al., 2021). En 2022, en Cuba, las ECV cobraron la vida de unas 11428 personas, posicionándola como la principal causa de muerte en el país (Sánchez-Padrón et al., 2023). Entre los tipos de ECV destacan la insuficiencia cardíaca, la hipertensión arterial, el infarto del miocardio y las arritmias. En Cuba, las arritmias fueron responsables en 2022 de 1262 defunciones (Sánchez-Padrón et al., 2023).

El término arritmia implica, además de una alteración del ritmo cardíaco, cualquier cambio de lugar en el inicio o en la secuencia de la actividad eléctrica del corazón que se aparte de lo normal (Khan et al., 2021). En la mayoría de los casos suponen una alteración del ritmo sinusal (Yildirim et al., 2020). El método de diagnóstico estándar de las arritmias es el electrocardiograma (ECG), sin embargo, desde hace varios años, nuevos estudios han destacado las potencialidades de la onda fotopletismográfica para detectar esta condición (Eerikäinen et al., 2019), (Liu et al., 2022), (Kulkarni and Dushyanth, 2021). La fotopletismografía (FPG) es una técnica de monitorización no invasiva, simple y de bajo costo que permite medir las fluctuaciones inducidas por la actividad cardíaca en el volumen de sangre del tejido (Park et al., 2022).

Numerosos estudios para la detección y clasificación de arritmias en los últimos años incorporan la señal de FPG además de la señal de ECG (Fallet et al., 2015), (Sadr et al., 2015), (Väliaho et al., 2021), (Kudo et al., 2023). Algunos autores utilizan además de la señal de ECG, la señal de FPG y de presión de sangre arterial (ABP, por sus siglas en inglés) para la identificación de 5 tipos de arritmias: asistolia, bradicardia, taquicardia, taquicardia ventricular y fibrilación ventricular (Fallet et al., 2015), (Sadr et al., 2015). En uno de estos estudios cada tipo de arritmia se procesa individualmente, este enfoque emplea indicadores de calidad de las señales, umbrales y técnicas de procesamiento para extraer la frecuencia cardíaca. En el caso de la taquicardia ventricular y la fibrilación ventricular se emplea además una estimación del índice de pureza espectral (Fallet et al., 2015). Por otra parte, el otro estudio propone un método para calcular los intervalos entre latidos, a continuación se detectan los puntos de inicio de las ondas en las señales pulsátiles (FPG y ABP) y se determina un índice de calidad (SQI) para todas las señales. A partir de los intervalos calculados y el SQI se establecen umbrales para la detección de las cinco arritmias (Sadr et al., 2015). Aunque ambos estudios usan la señal de FPG, sólo se emplean para mejorar el rendimiento de los algoritmos propuestos y no como método de detección o clasificación en sí.

Aunque la señal de FPG no puede caracterizar completamente la actividad cardíaca subyacente con la fidelidad de un ECG, muchas arritmias cardíacas modifican el ritmo y la morfología de la forma de onda de la señal de FPG. Esto ha permitido el desarrollo de estudios para la detección de arritmias basándose en la señal de FPG (Paradkar and Chowdhury, 2017), (Bashar et al., 2019), (Ahmed et al., 2019). En un método basado en análisis espectral se detectan cinco tipos de arritmias utilizando solo la señal de FPG. El método

está basado en modelos gaussianos y representación residual del espectro (Paradkar and Chowdhury, 2017). Por otra parte, otro estudio propone un algoritmo para detectar la fibrilación auricular usando la señal de FPG registrada por un reloj inteligente. El algoritmo utiliza los datos de un acelerómetro para eliminar los artefactos de movimiento. Este enfoque usa demodulación compleja de frecuencia, la raíz cuadrada media de diferencias sucesivas de la frecuencia cardíaca y entropía para detectar la fibrilación auricular (Bashar et al., 2019).

Un problema subyacente con las técnicas de monitoreo continuo es que el análisis de la señal es una tarea intensiva en tiempo y recursos por la gran cantidad de datos generados en el proceso de adquisición. En los últimos años se han desarrollado algoritmos de clasificación automática que emplean técnicas de inteligencia artificial para detectar arritmias, facilitando el análisis de grandes volúmenes de datos (Eerikäinen et al., 2019), (Aschbacher et al., 2020), (Castiñeira Pérez, 2020).

En (Eerikäinen et al., 2019) se propone un método de aprendizaje automático para clasificación de FA, aleteo auricular y otros ritmos, utilizando datos de aceleración y la señal de FPG medidos en la muñeca. Este estudio emplea un modelo de Bosques Aleatorios para realizar la clasificación. En (Aschbacher et al., 2020), proponen tres algoritmos para detectar FA, el primero es una aproximación convencional basada en la raíz cuadrática media de los intervalos sucesivos, el segundo utiliza una red neuronal LSTM (*long short-term memory*) y el tercero emplea una red neuronal convolucional recurrente. Los dos últimos algoritmos muestran los mejores resultados, pero el algoritmo LSTM requiere 4385 parámetros y el basado en la red neuronal convolucional recurrente utiliza 10,000 parámetros.

La detección de arritmias con FPG permanece como un tema abierto. En este estudio se desarrollan dos algoritmos de aprendizaje automático orientados a identificar tres tipos de arritmias: Taquicardia Sinusal, Bradicardia Sinusal y Fibrilación Auricular. Estos algoritmos utilizan características extraídas de la señal de FPG.

Materiales y Métodos

En este estudio se proponen dos algoritmos para la detección de arritmias cardíacas usando únicamente la señal de FPG. Un algoritmo (**ALG-A**) está basado en Máquinas de Vectores Soporte (SVM) y el otro (**ALG-B**) en Perceptrón Multicapa (MLP). En la Figura 1 se muestra el esquema general de ambos algoritmos.

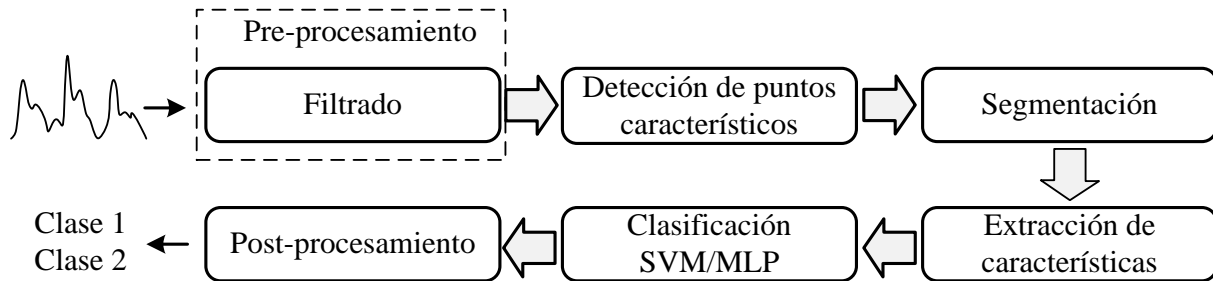


Fig.1 - Esquema general de los algoritmos de detección automática de arritmias con FPG.

Para el entrenamiento y evaluación de los algoritmos se utilizaron registros de la base de datos del PhysioNet/Computing in Cardiology Challenge 2015 (Clifford et al., 2015). Esta base de datos es, hasta Agosto de 2023, la única disponible en PhysioNet que contiene múltiples arritmias anotadas y que incorpora la señal de FPG. La base de datos incluye 750 registros de alarmas potencialmente mortales registradas en monitores de cabecera en las Unidades de Cuidados Intensivos de hospitales de Estados Unidos y Europa. Cada registro tiene una duración entre 300 s y 330 s y frecuencia de muestreo de 250 Hz. Un registro contiene dos derivaciones de ECG y al menos una forma de onda pulsátil (FPG o ABP). Las alarmas anotadas en los registros se encuentran en los últimos 10 s de la grabación. No obstante, no se descarta que existan eventos de arritmias no anotados en los minutos anteriores a la alarma. La anotación indica si una alarma originada por cinco tipos de arritmias (Asistolia, Bradicardia, Taquicardia, Taquicardia Ventricular y Fibrilación Ventricular) es verdadera o falsa.

Del total de registros, solo 221 contienen FPG y corresponden a eventos reales, es decir, un total de 37 minutos anotados. Esto es insuficiente para entrenar algoritmos de aprendizaje automático, por lo que dos

especialistas en cardiología anotaron completamente 117 registros. En las nuevas anotaciones cada especialista trabajó de forma independiente. Se tomó como anotación definitiva aquellas en las que ambos concordaron en el tipo de arritmia. De este proceso resultaron un total de 19 tipos de eventos distintos. Del total de anotaciones, las clases más representativas resultaron Fibrilación Auricular (**FA**), Bradicardia Sinusal (**BS**), Taquicardia Sinusal (**TS**), Ritmo Sinusal Normal (**RSN**) y Artefactos (**A**).

En este estudio se emplean 5 clases: **FA**, **TS**, **BS**, **A** y **O**. La clase **O** incorpora todas las anotaciones que no correspondan a las otras cuatro clases a identificar. Del total de datos se utiliza el 80% (93 registros) para entrenar los algoritmos y el 20% (24 registros) para evaluación. La selección del conjunto de entrenamiento y evaluación se realizó de forma aleatoria.

Las señales fueron filtradas con un filtro Butterworth pasa-banda de cuarto orden y fase cero, con frecuencias de corte inferior y superior de 0.5 Hz y 15 Hz respectivamente. Para la extracción de características primeramente se determinaron dos puntos característicos de la señal de FPG: pico sistólico e inicio de la onda. La detección del pico sistólico se realizó empleando el algoritmo propuesto en (Carralero-Paredes et al., 2021). Para la detección del inicio de la onda se emplean los picos sistólicos detectados y un procedimiento basado en la mínima área bajo la curva. El algoritmo calcula las áreas entre dos picos consecutivos delimitando cada área por una ventana deslizante de 80 ms. El pie de la señal corresponde al mínimo de la señal en la ventana donde el área es mínima.

La señal en cada registro se segmenta utilizando ventanas deslizantes de 10 s con solapamiento de 9 s. En dependencia de la duración del registro este proceso resulta en un total de 291 o 321 ventanas respectivamente. De cada ventana se calcularon 46 características formando una matriz por registro. La matriz global fue normalizada usando normalización gaussiana. El proceso de extracción y selección de características, así como el código utilizado se encuentra disponible en [Github](#).

La estrategia de validación cruzada empleada es K-vías para series temporales (K=5). Esta estrategia permite evaluar el modelo para datos de series temporales sobre las observaciones "futuras" menos

parecidas a las utilizadas para entrenar el modelo. Durante el proceso de validación cruzada se empleó un enfoque de prueba y error para ajustar las características e hiperparámetros de los clasificadores. En este enfoque se tuvieron en cuenta dos aspectos, (1) que en la matriz de confusión el algoritmo no clasifique incorrectamente **BS** como **TS** y viceversa, y (2) favorecer el algoritmo de mayor rendimiento para un menor número de características.

Para mejorar el rendimiento en la clasificación se utilizan dos enfoques, uno orientado al análisis morfológico de la señal y otro centrado en las variaciones del ritmo. La **FA** se caracteriza por tener un ritmo caótico e irregular, que puede ser rápido, lento o controlado, por lo que desde la perspectiva del ritmo cardíaco puede confundirse con la **BS**, **TS** y **RSN**. De esta forma, se diseñaron dos clasificadores, uno que utiliza características morfológicas y de entropía para detectar **FA**, **A** y **O2**, donde $O2 \equiv \{OUBSUTS\}$ y otro que incluye características temporales para identificar las clases **BS**, **TS** y **O3**, donde $O3 \equiv \{FAUAUO\}$. Finalmente se diseña una regla de decisión y una etapa de post-procesamiento para obtener la clasificación final. La Figura 2 muestra la estructura de los algoritmos.

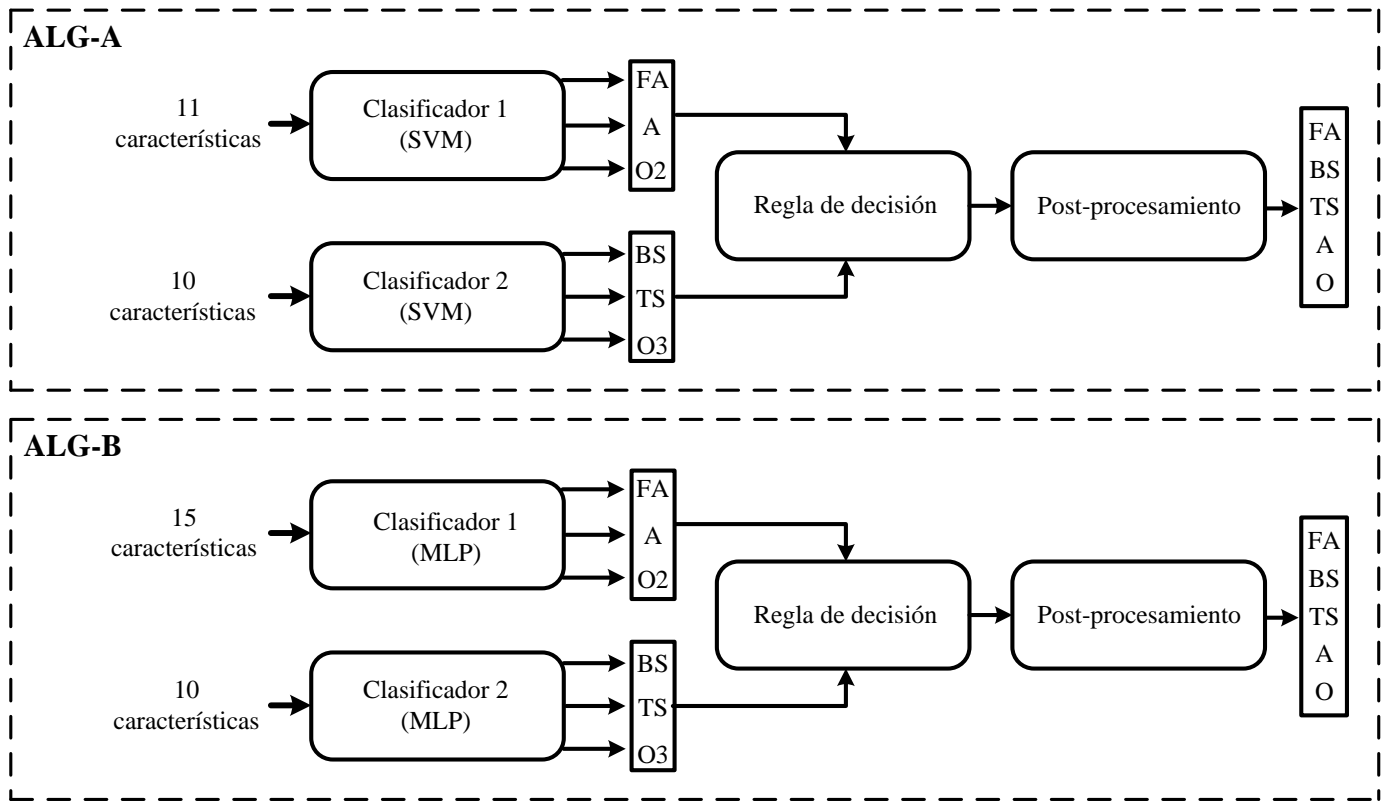


Fig. 2 - Estructura general de los algoritmos.

Cada algoritmo (ALG-A y ALG-B) implementa dos clasificadores basados en el mismo método de aprendizaje automático, SVM o MLP. Cada clasificador se construye con vectores de características diferentes. Para cada algoritmo, los hiperparámetros de ambos clasificadores fueron ajustados evaluando los índices de rendimiento luego de varias validaciones cruzadas, tomándose los valores donde el rendimiento del modelo fue superior.

Para los dos clasificadores de ALG-A el kernel que mostró mejor rendimiento fue el Gaussiano (RBF). El valor del hiperparámetro C se ajustó en 15 para el Clasificador 1 y en 14 para el Clasificador 2. La estrategia de decisión para la cual se obtuvieron los mejores resultados en la validación cruzada fue la de one-versus-all. El Clasificador 1 utiliza las siguientes 11 características: 38, 41, 23, 6, 18, 22, 24, 27, 28, 29

y 37. El Clasificador 2 utiliza 10 características: 46, 36, 4, 38, 22, 28, 37, 29, 6 y 27. En el resto de los hiperparámetros del clasificador se usaron los valores por defecto.

Para **ALG-B** se evaluaron redes de una y dos capas ocultas, la variante con dos capas obtuvo los mejores resultados. Para la selección de la cantidad de neuronas de las capas ocultas se adoptó un esquema N:2N:N:3, donde N es el número de neuronas en cada capa. En **ALG-B** la función de activación se ajustó a 'ReLU', y el algoritmo de optimización de mejor rendimiento fue 'adam'. El número máximo de épocas fue fijado en 1000. La fracción del conjunto de entrenamiento utilizada como conjunto de validación fue 2/10. En el resto de los parámetros de la red se utilizaron los valores por defecto. La estructura del Clasificador 1 es 15:30:15:3. El vector de características seleccionado fue: 46, 38, 41, 23, 6, 18, 22, 24, 27, 28, 29, 37, 34, 40 y 35. La estructura del Clasificador 2 es 10:20:10:3 y usa las características: 11, 36, 3, 32, 15, 28, 37, 6, 29 y 27.

Para la regla de decisión se favoreció la salida del primer clasificador, debido a que en este contexto la **FA** es la arritmia que mayores complicaciones puede suponer para la salud del paciente (Morales-Bacas et al., 2022). La Tabla 1 muestra la regla de decisión del algoritmo. Las filas corresponden a la salida del Clasificador 1 y las columnas al Clasificador 2, los valores de la Tabla 1 corresponden a las clases a identificar: **FA-0**, **BS-1**, **TS-2**, **A-3**, **O-4**.

Tabla 1 - Regla de decisión.

	BS	TS	O3
FA	0	0	0
A	3	3	3
O2	1	2	4

El post-procesamiento filtra la salida del bloque de regla de decisión como sigue: si a la salida del algoritmo aparece una etiqueta de menos de 3 s, no corresponde a la clase **A** y está rodeada de una misma clase, esta asume el valor de su entorno. La Figura 3 muestra la etapa de post-procesamiento.

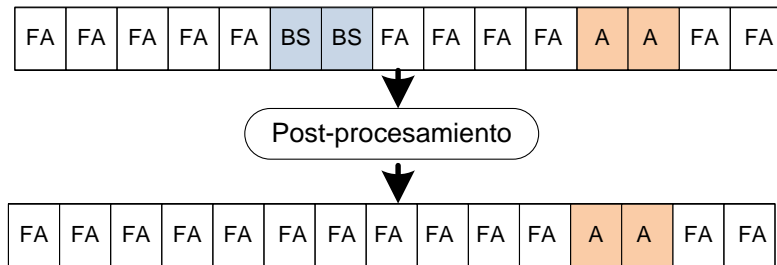


Fig. 3 - Etapa de post-procesamiento.

Resultados y discusión

El algoritmo **ALG-A** durante el proceso de evaluación obtuvo una Acc del 75%, mientras **ALG-B** logró un 77%. La Tabla 2 muestra un resumen de las matrices de confusión e índices de rendimiento en la evaluación de cada uno de los algoritmos.

Tabla 2 - Resumen de la evaluación de los dos algoritmos propuestos

	ALG-A					ALG-B				
	FA	BS	TS	A	O	FA	BS	TS	A	O
FA	1286	94	34	20	283	1288	35	33	20	317
BS	228	896	0	4	525	232	1009	0	4	406
TS	0	0	758	2	129	0	0	720	0	125
A	15	34	5	102	54	22	37	12	121	93
O	223	141	15	35	2371	210	84	47	18	2421
Se (%)	73	77	93	63	71	74	87	89	74	72

+P (%)	75	54	85	49	85	76	61	85	42	87
F1 (%)	74	64	89	55	77	75	72	87	54	79

Los resultados de la matriz de confusión muestran desbalance entre las clases en el conjunto de evaluación, lo que afecta el rendimiento del algoritmo fundamentalmente en la clase **A**. Como resultado, una clasificación incorrecta afecta considerablemente los índices de rendimiento de los algoritmos para esa clase. Esto se evidencia en los bajos resultados obtenidos en la detección de **A** en los 2 algoritmos evaluados, mostrando el peor índice de rendimiento de manera general. Por otra parte, la superclase **O** contiene múltiples anotaciones de diversas arritmias con baja representatividad, lo que dificulta el aprendizaje de los algoritmos.

En la literatura no se encontraron estudios que detecten con un mismo algoritmo **FA**, **BS** y **TS**. En la Tabla 3 se muestran los resultados de 9 algoritmos de detección de arritmias: el algoritmo 1 propuesto en (Fallet et al., 2015), el algoritmo 2 propuesto en (Sadr et al., 2015), el algoritmo 3 propuesto en (Paradkar and Chowdhury, 2017), el algoritmo 4 propuesto en (Bashar et al., 2019) y los algoritmos 5, 6 y 7 todos propuestos en el estudio (Aschbacher et al., 2020). Los dos últimos algoritmos, **ALG-A** y **ALG-B**, corresponden a los presentados en este estudio. Los algoritmos mostrados en la Tabla 3 no son directamente comparables con los métodos propuestos en esta investigación debido a que utilizan otros conjuntos de datos. No obstante, muestran algunos de los resultados actuales en la detección de arritmias utilizando FPG.

Tabla 3 - Resultados de estudios de detección de arritmias

Algoritmos	Señal	BD	Bradicardia				Taquicardia				Fibrilación auricular			
			Se	Sp	+P	F1	Se	Sp	+P	F1	Se	Sp	+P	F1
1	1,2,3	(73)	96	66	60	74	96	60	69	80	-	-	-	-
2	1,2,3	(73)	100	52	55	71	100	80	98	99	-	-	-	-
3	2	(73)	88	73	53	66	98	78	80	88	-	-	-	-
4	2,4	P	-	-	-	-	-	-	-	-	98	97	96	97

5	2	P	-	-	-	-	-	-	-	-	74	58	80	77
6	2	P	-	-	-	-	-	-	-	-	81	92	96	88
7	2	P	-	-	-	-	-	-	-	-	98	88	96	97
ALG-A	2	(73)*	77	63	54	64	93	89	85	89	73	74	75	74
ALG-B	2	(73)*	87	72	61	72	89	87	85	87	74	75	76	75

Nota: Todos los valores de la tabla están expresados en %.
 Señales: 1(ECG), 2(FPG), 3(ABP), 4(accel),
 BD(Base de Datos), P(Propia), *(reanotada)

Los algoritmos 1, 2 y 3 están orientados a la detección de múltiples arritmias, entre ellas Bradicardia y Taquicardia. Los dos primeros potencian la detección de verdaderos positivos, de ahí que la precisión y la especificidad de los algoritmos se vea penalizada. De estos métodos solo 3 utiliza únicamente la señal de FPG, y aunque no muestra resultados superiores, su rendimiento es similar a 1 y 2. El algoritmo 3 a diferencia de los propuestos en el presente estudio (**ALG-A** y **ALG-B**), no emplea técnicas de aprendizaje automático para la identificación de las arritmias, por lo que demanda menos recursos de cómputo. No obstante, los autores eliminan del análisis los segmentos corruptos por artefactos utilizando umbrales y dos índices de calidad de la señal. Si bien la eliminación de los artefactos mejora el rendimiento de los algoritmos, también limita su alcance, ya que los mismos no han sido evaluados en monitorización ambulatoria.

Los algoritmos 4, 5, 6 y 7 están orientados a la detección de **FA**. El primero de ellos muestra los mejores resultados pero emplea además de la señal de FPG un acelerómetro para eliminar artefactos de la señal. Los algoritmos 5, 6 y 7 son métodos diferentes para detectar **FA** recogidos en un mismo estudio (Aschbacher et al., 2020). Los dos últimos algoritmos, aunque muestran mejores resultados son algoritmos de *deep learning*, para su ejecución ambos demandan gran costo computacional.

Para el algoritmo 4 los autores eliminan del análisis los segmentos afectados por artefactos de movimiento y ruido, constituyendo esto una de las limitaciones del estudio. En (Aschbacher et al., 2020), si bien no se eliminan artefactos en las señales, los datos utilizados en el estudio son de pacientes en estado de sedación,

por lo que la incidencia de artefactos de movimiento es más limitada. Los autores de (Aschbacher et al., 2020) reconocen como limitación de su estudio que los datos se obtuvieron en entornos controlados, por lo que los algoritmos pueden no ser aplicables en condiciones ambulatorias.

Los algoritmos **ALG-A** y **ALG-B** muestran un rendimiento comparable al resto de los estudios mostrados en la Tabla 3, inclusive a los que usan 3 señales (ECG, ABP y FPG). La detección de **FA** tiene resultados similares al algoritmo 5 pero inferiores al resto de los algoritmos mostrados en la tabla.

A diferencia de los algoritmos 2, 3 y 4 de la Tabla 3, en la presente investigación los artefactos identificados por los especialistas no son retirados del análisis por lo que los algoritmos se enfrentan a condiciones reales. Por otro lado, los algoritmos desarrollados en este estudio utilizan una etapa de preprocesamiento simple y pueden operar en ambientes con recursos de cómputo limitados. El algoritmo **ALG-A** emplea 23 parámetros mientras que **ALG-B** utiliza 1456, valores inferiores a los algoritmos 6 y 7 que emplean 4385 y 10000 parámetros respectivamente. La menor complejidad de los algoritmos diseñados en este estudio permite que puedan ser adaptados e implementados en dispositivos portátiles.

Conclusiones

Las tecnologías que emplean la fotopleitismografía para detectar arritmias han cobrado auge en los últimos años debido al creciente avance tecnológico y a la fácil adquisición de la señal; es por ello que el desarrollo de algoritmos que faciliten la identificación de estas patologías cardíacas continúa siendo un reto para los investigadores. En este estudio se diseñaron dos algoritmos basados en técnicas de aprendizaje automático supervisado diferentes, SVM y MLP, para la detección de tres tipos arritmias cardíacas utilizando solamente la señal de FPG. Los algoritmos desarrollados (**ALG-A** y **ALG-B**) muestran un rendimiento comparable al de estudios actuales que utilizan únicamente la señal de FPG para detectar arritmias. Los clasificadores propuestos en este estudio son de baja complejidad computacional, esto permite que puedan ser adaptados e implementados en dispositivos portátiles como relojes o pulseras inteligentes.

Referencias

- ahmed, Y., Uddin, M. N., Masud, S. M. & Imam, M. H. Design Of An Arrhythmia Detection System Using Wearable Ppg Sensor. 2019 Ieee International Conference On Biomedical Engineering, Computer And Information Technology For Health (Becithcon), 2019. Ieee, 73-76.
- Aschbacher, K., Yilmaz, D., Kerem, Y., Crawford, S., Benaron, D., Liu, J., Eaton, M., Tison, G. H., Olgin, J. E. & Li, Y. 2020. Atrial Fibrillation Detection From Raw Photoplethysmography Waveforms: A Deep Learning Application. *Heart Rhythm O2*, 1, 3-9.
- Bashar, S. K., Han, D., Hajeb-Mohammadipour, S., Ding, E., Whitcomb, C., Mcmanus, D. D. & Chon, K. H. 2019. Atrial Fibrillation Detection From Wrist Photoplethysmography Signals Using Smartwatches. *Scientific Reports*, 9, 15054.
- Carralero-Paredes, A., Suárez-León, A. A., Sónora-Mengana, A. & García-Naranjo, J. C. 2021. Detección De Arritmias A Partir De La Determinación De La Frecuencia Cardíaca Con Fotoplethysmografía. *Orange Journal*, 3, 42-52.
- Castiñeira Pérez, D. 2020. *Desig, Implementation And Validation Of N Atrial Fibrillation Screening System Through Ppg Signals And Machine Learning Techniques*.
- Clifford, G. D., Silva, I., Moody, B. & Mark, R. 2015. Reducing False Arrhythmia Alarms In The Icu: The Physionet/Computing In Cardiology Challenge 2015. *Computing In Cardiology*, 42, 273-276.
- Eerikäinen, L. M., Bonomi, A. G., Schipper, F., Dekker, L. R., De Morree, H. M., Vullings, R. & Aarts, R. M. 2019. Detecting Atrial Fibrillation And Atrial Flutter In Daily Life Using Photoplethysmography Data. *Ieee Journal Of Biomedical And Health Informatics*, 24, 1610-1618.
- Fallet, S., Yazdani, S. & Vesin, J.-M. A Multimodal Approach To Reduce False Arrhythmia Alarms In The Intensive Care Unit. 2015 Computing In Cardiology Conference (Cinc), 2015. Ieee, 277-280.
- Khan, A. H., Hussain, M. & Malik, M. K. 2021. Arrhythmia Classification Techniques Using Deep Neural Network. *Complexity*, 2021, 1-10.

- Kudo, S., Chen, Z., Zhou, X., Izu, L. T., Chen-Izu, Y., Zhu, X., Tamura, T. & Huang, M. 2023. A Training Pipeline Of An Arrhythmia Classifier For Atrial Fibrillation Detection Using Photoplethysmography Signal. *Frontiers In Physiology*, 14, 1084837.
- Kulkarni, T. R. & Dushyanth, N. 2021. Performance Evaluation Of Deep Learning Models In Detection Of Different Types Of Arrhythmia Using Photo Plethysmography Signals. *International Journal Of Information Technology*, 13, 2209-2214.
- Liu, Z., Zhou, B., Jiang, Z., Chen, X., Li, Y., Tang, M. & Miao, F. 2022. Multiclass Arrhythmia Detection And Classification From Photoplethysmography Signals Using A Deep Convolutional Neural Network. *Journal Of The American Heart Association*, 11, E023555.
- Morales-Bacas, E., Duque-Holguera, M., Portilla-Cuenca, J. C. & Casado-Naranjo, I. 2022. Fibrilación Auricular Y Deterioro Cognitivo: Una Revisión Narrativa. *Revista De Neurología*, 75, 311.
- Paradkar, N. & Chowdhury, S. R. Cardiac Arrhythmia Detection Using Photoplethysmography. 2017 39th Annual International Conference Of The Ieee Engineering In Medicine And Biology Society (Embc), 2017. Ieee, 113-116.
- Park, J., Seok, H. S., Kim, S.-S. & Shin, H. 2022. Photoplethysmogram Analysis And Applications: An Integrative Review. *Frontiers In Physiology*, 12, 808451.
- Revueltas-Agüero, M., Benítez-Martínez, M., Hinojosa-Álvarez, M. D. C., Venero-Fernández, S., Molina-Esquivel, E. & Betancourt-Bethencourt, J. A. 2021. Caracterización De La Mortalidad Por Enfermedades Cardiovasculares: Cuba, 2009-2018. *Revista Archivo Médico De Camagüey*, 25.
- Sadr, N., Huvanandana, J., Nguyen, D. T., Kalra, C., Mcewan, A. & De Chazal, P. Reducing False Arrhythmia Alarms In The Icu By Hilbert Qrs Detection. 2015 Computing In Cardiology Conference (Cinc), 2015. Ieee, 1173-1176.
- Sánchez-Padrón, G., Alonso-Alomá, I., Sánchez-Sordo, E., Martínez-Morames, M., Alonso Expósito, I. & Pérez Leyva, M. 2023. Anuario Estadístico De Salud. La Habana: Dirección De Registros Médicos Y Estadísticos De Salud.
- Väliaho, E.-S., Kuoppa, P., Lipponen, J. A., Hartikainen, J. E., Jäntti, H., Tarvainen, M. P. & Martikainen, T. J. 2021. Wrist Band Photoplethysmography Autocorrelation Analysis Enables Detection Of Atrial Fibrillation Without Pulse Detection. *Frontiers In Physiology*, 12, 654555.

Yildirim, O., Talo, M., Ciaccio, E. J., San Tan, R. & Acharya, U. R. 2020. Accurate Deep Neural Network Model To Detect Cardiac Arrhythmia On More Than 10,000 Individual Subject Ecg Records. *Computer Methods And Programs In Biomedicine*, 197, 105740.

Conflicto de interés

Los autores declaran que no existen conflictos de intereses con otros autores o instituciones.

Contribuciones de los autores

Conceptualización: Arianna Carralero Paredes y Alexander Alexeis Suárez León.

Curación de datos: Ramón Arturo Rodríguez Hecharría y Enrique Gómez Villariño

Investigación: Arianna Carralero Paredes

Metodología: Alexander Alexeis Suárez León

Administración del proyecto: Alexander Alexeis Suárez León, Juan Carlos García Naranjo, Alexander Sónora Mengana

Recursos: Arianna Carralero Paredes, Ramón Arturo Rodríguez Hecharría y Enrique Gómez Villariño

Software: Arianna Carralero Paredes

Supervisión: Alexander A. Suárez León, Juan Carlos García Naranjo y Alexander Sónora Mengana

Validación: Arianna Carralero Paredes

Redacción – Arianna Carralero Paredes

Redacción – Alexander Alexeis Suárez León, Arianna Carralero Paredes, Juan Carlos García Naranjo y Alexander Sónora Mengana