

Clasificación de Arritmias Cardíacas mediante Redes Neuronales Convolucionales y Optimización por Enjambre de Partículas

Classification of Cardiac Arrhythmias using Convolutional Neural Networks and Particle Swarm Optimization

F. Santander-Baños ^{a,*}, N. Hernández-Romero ^a, I. Barragán-Vite ^a, O. Karelín ^a, J. Medina-Marín ^a

^aÁrea Académica de Ingeniería y Arquitectura, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

Resumen

El electrocardiograma es una herramienta que permite conocer el estado de salud del corazón, a través de la representación del comportamiento de los impulsos eléctricos de este órgano. Una arritmia cardíaca ocurre cuando estos impulsos no funcionan correctamente, y comúnmente es clasificada según su patrón de comportamiento. La presente investigación propone una nueva implementación del modelo híbrido entre Redes Neuronales Convolucionales y el algoritmo metaheurístico de Optimización por Enjambre de Partículas; para la clasificación de arritmias cardíacas. El metaheurístico se encargó de optimizar el número y tipo de capas de la red neuronal, a través de la minimización en la pérdida durante el entrenamiento. Este trabajo utilizó cinco diferentes categorías de arritmias conforme al estándar AAMI EC57. Los resultados logrados demostraron que el modelo es capaz de encontrar una adecuada arquitectura de capas de una red neuronal convolucional y con ello obtener una precisión del 97 % en la clasificación de estas arritmias.

Palabras Clave: Redes Neuronales Convolucionales, Optimización por Enjambre de Partículas, Modelo Computacional, Clasificación de Arritmias Cardíacas, Electrocardiogramas.

Abstract

The electrocardiogram is a tool that allows knowing the state of health of the heart, through the representation of the behavior of the electrical impulses of this organ. A cardiac arrhythmia occurs when these impulses do not work properly, and is commonly classified according to its pattern of behavior. This research proposes a new implementation of the hybrid model between Convolutional Neural Networks (CNN) and the Particle Swarm Optimization (PSO) metaheuristic algorithm; for the classification of cardiac arrhythmias. The metaheuristic was in charge of optimizing the number and type of layers of the neural network, through the minimization of loss during training. This work used five different categories of arrhythmias according to the AAMI EC57 standard. The results achieved showed that the model is capable of finding an adequate layer architecture of a convolutional neural network and thereby obtaining an accuracy of 97 % in the classification of these arrhythmias.

Keywords: Convolutional Neural Networks, Particle Swarm Optimization, Computational Model, Cardiac Arrhythmias Classification, Electrocardiograms.

1. Introducción

Un electrocardiograma (ECG) es una representación completa de la actividad eléctrica del corazón, que se adquiere mediante la realización de una prueba no invasiva, es decir, mediante la conexión de electrodos en el torso del cuerpo humano. Uno de los objetivos del ECG se centra en la detección oportuna de problemas en los impulsos eléctricos que cada latido

cardíaco genera (Biel et al., 2001; Agrafioti et al., 2011; Li et al., 2017).

Las arritmias cardíacas (AC) son trastornos causados por la formación o conducción del impulso eléctrico, o por ambos. Entre los trastornos de la formación del impulso están el aumento o la disminución del automatismo, actividad parasistólica y actividad desencadenada (Aparicio Morales et al., 2018). Las

* Autor para correspondencia: mtic.fsantander@gmail.com

Correo electrónico: mtic.fsantander@gmail.com (Fredy Santander-Baños), nhromero@uaeh.edu.mx (Norberto Hernández-Romero), irvingb@uaeh.edu.mx (Irving Barragán-Vite), karelín@uaeh.edu.mx (Oleksandr Karelín Anatolyevich), jmedina@uaeh.edu.mx (Joselito Medina-Marín).

AC conforman un amplio y heterogéneo grupo de anomalías eléctricas del corazón. Pueden ser inocuas; y suelen predisponer al desarrollo de accidentes cerebrovasculares, embolias o constituir una urgencia de riesgo vital que dé lugar a una muerte súbita cardíaca (Braunwald, 2016). Una arritmia cardíaca se caracteriza por tener un comportamiento irregular del corazón que afecta el ritmo y duración de la señal propiamente, por lo que cada arritmia es clasificable según su comportamiento (Huikuri et al., 2001; Chazal et al., 2004; Zhang et al., 2014). Las AC pueden causar síntomas que incluyen sensación de mareo, palpitaciones, desmayos y dificultad para respirar (Huikuri et al., 2001). Una arritmia cardíaca puede estar relacionada con ciertas enfermedades cardiovasculares (ECV), y suele ser utilizada como una primera evidencia, que determina la decisión de realizar más estudios al paciente, con la finalidad de diagnosticar la enfermedad cardiovascular. Algunas de las ECV que pueden estar asociadas con las AC son: enfermedad de las arterias coronarias, hipertensión arterial, miocardiopatía, trastornos valvulares y falta de equilibrio de electrolitos en sangre como lo son el sodio y potasio (Chen et al., 2019).

De acuerdo con la Organización Mundial de la Salud (OMS), las ECV son la principal causa de muerte en todo el mundo. Se calcula que en 2015 murieron por esta causa 17,7 millones de personas, lo cual representa un 31 % de todas las muertes registradas, y se estima que para el 2030 el número de defunciones provocadas por las ECV ascenderá a 23.6 millones (WHO, 2019).

En México, las ECV se encuentran entre las principales causas de muerte desde 1990 (Dávila, 2017). El 19 % de mujeres y hombres con edades entre los 30 y 69 años muere a causa de alguna enfermedad cardiovascular, y se estima que el 70.3 % de la población adulta vive con al menos un factor de riesgo cardiovascular (Sánchez-Arias et al., 2016). El número de mexicanos que fallecen cada año por alguna de las ECV, asciende aproximadamente a 140 mil personas, más de 20 millones de adultos tienen hipertensión arterial y 13 millones viven con diabetes; dos de las principales causas de los problemas cardíacos. Se suman otros factores de riesgo como el tabaquismo, la obesidad, el sedentarismo, el colesterol alto y los factores hereditarios (Rosas-Peralta et al., 2016). Algunos expertos como lo es el Dr. Enrique Gómez Álvarez afirma que las ECV son una pandemia permanente a diferencia del COVID-19 (UNAM, 2020).

En la mayoría de los casos, el paradigma de diagnóstico tradicional de las AC, es posible gracias al análisis de la señal del ECG por parte de un especialista médico; comúnmente suele ser un cardiólogo. Sin embargo, esto resulta ser ineficaz ante la gran cantidad de población heterogénea que actualmente México tiene con alguna enfermedad cardiovascular. De acuerdo con la Secretaría de Salud en México, existen 0.8 especialistas en cardiología por cada 1000 habitantes, lo que implica una alta demanda de personal en esta área (Heinze et al., 2018). El problema se vuelve más pronunciado en lugares donde faltan expertos médicos y equipo clínico, especialmente en zonas rurales de México.

Lo anterior motiva el requerimiento de un sistema confiable, automático y asequible para el monitoreo y/o diagnóstico de las AC mediante el análisis de las señales del ECG obtenidas en los pacientes. Este requerimiento se está volviendo cada vez

más demandado por parte de los especialistas médicos, al tratarse de una herramienta tecnológica que les permitirá monitorear pacientes de forma remota, es decir, sin la necesidad de estar físicamente en el mismo espacio de revisión médica. Estas revisiones médicas se pueden vincular a la utilización de Sistemas de Diagnóstico Asistido por Computadora (SDAC). Un SDAC está compuesto por procedimientos automáticos de monitorización de las condiciones de salud de un determinado paciente, se basan en el procesamiento y análisis de señales fisiológicas obtenidas por medio de sensores. Estas señales sirven para monitorizar y evaluar la funcionalidad del órgano de interés. Algunos SDAC de última generación suelen utilizar algoritmos de inteligencia artificial para lograr dicho objetivo (Shiraishi et al., 2011).

El uso de los algoritmos de aprendizaje profundo (en inglés, deep learning algorithms (DLA)), ha incrementado a lo largo de los últimos 10 años. Su principal objetivo radica en la clasificación y predicción en diferentes campos de la ciencia. Recientemente, se ha observado que los DLA se están desarrollando de manera importante con un efecto significativo en la precisión y en la clasificación para una amplia gama de tareas médicas. Los SDAC modernos aprovechan los DLA para detectar las AC de la señal del ECG, lo que reduce el costo de la monitorización cardíaca continua, y mejora la calidad en las predicciones (Lugo-Reyes et al., 2014). No obstante, una clasificación automática de AC basada en un ECG, generalmente se enfrenta a varios desafíos importantes: uno de ellos es la reducción de la precisión ante el incremento del número de AC, para su clasificación.

En el presente trabajo de investigación, se propone la implementación de un modelo híbrido computacional compuesto por redes neuronales convolucionales y el algoritmo metaheurístico de optimización por enjambre de partículas (PSO-CNN); para la clasificación de cinco categorías de arritmias cardíacas, definidas bajo el estándar AAMI EC57, y las cuales se pueden apreciar en la Tabla 1. La fuente de datos, se obtuvo del MIT-BIH Arrhythmia dataset (Goldberger et al., 2000; Moody and Mark, 2001); el cual es típicamente utilizado para el desarrollo de DLA o algoritmos de aprendizaje automático (AAA), y está avalado por la Asociación para el Avance de la Instrumentación Médica (AAIM) (ANSI/AAMI, 2012).

Este modelo originalmente fue desarrollado por (Fernandes Junior and Yen, 2019), y trabajaron en la clasificación de imágenes digitales en dos dimensiones, y su fuente de información proviene de la base de datos modificada del Instituto Nacional de Estándares y Tecnología (por su siglas en inglés: MNIST database).

Por lo tanto, las aportaciones de este trabajo se resumen en:

- **Preprocesamiento de la base de datos:** La base de datos al ser de una sola dimensión, vuelve necesario crear un método que permita realizar el preprocesamiento de esa información, con el objetivo de ser utilizada por una red neuronal convolucional (RNC). Se dividen los datos en: entrenamiento y prueba.
- **Ajuste de la CNN de 2D a 1D:** El modelo original PSO-CNN, contempla la clasificación de imágenes digitales 2D. Los datos provenientes del MIT-BIH Arrhythmia dataset se encuentran definidos de manera vectorial 1D, por

lo qué, resulta indispensable adaptar el núcleo de la RNC con la finalidad de que pueda trabajar en la clasificación de datos vectoriales.

- **Obtención de métricas:** La clasificación de las AC requiere el cálculo de métricas que se encuentran definidas por: precisión, sensibilidad y valor-F; y que permiten evaluar su rendimiento.
- **Implementación del PSO-CNN para la clasificación de las AC:** El modelo PSO-CNN no había sido utilizado en ninguna área relacionada con la medicina, específicamente, para la clasificación de arritmias.

Los resultados logrados con la implementación de este modelo demostraron que la hibridación entre el PSO y las CNN: incrementa satisfactoriamente la precisión en la clasificación de las cinco categorías de arritmias, provenientes del MIT-BIH Arrhythmia dataset. La precisión obtenida, puede tomarse como referencia para considerar la adecuación de esta técnica híbrida en un SDAC. Hasta ahora, los SDAC suelen estar equipados con software que tienen como núcleo algoritmos matemáticos o en su defecto de aprendizaje profundo, que permiten el funcionamiento en el diagnóstico de algunas enfermedades. Cabe mencionar que el alcance del presente trabajo, no incluye la adaptación del modelo a un SDAC.

El resto del artículo está organizado de la siguiente manera: la sección 2 presenta los Antecedentes y el Trabajo relacionado, en la sección 3 se explica el modelo PSO-CNN, mientras que en la sección 4 se describe la Metodología que se utilizó para el Diseño Experimental planteado en la sección 5, los Resultados se reportan en la sección 6 y se discuten en la sección 7. Finalmente, la sección 8 presenta las Conclusiones.

2. Antecedentes y Trabajo relacionado

La clasificación de las AC ha recibido demasiada importancia durante los últimos 20 años. Esta clasificación está fundamentada en tres pasos esenciales que tienen que realizarse para que tenga éxito: preprocesamiento, extracción de características y clasificación (Essam et al., 2017).

La fase de preprocesamiento, no es más que asegurarse que la señal de un ECG esté en las mejores condiciones y que no contenga factores externos como el ruido que pueda afectar su posterior extracción de características y clasificación (Essam et al., 2017). Los métodos tradicionales de extracción de características regularmente son hechos de manera artesanal, tal es el caso de: morfología matemática (Chazal et al., 2004; Zhang et al., 2014; Shi et al., 2019; Mondéjar-Guerra et al., 2019), intervalos entre los látidos del corazón (Chazal et al., 2004; Zhang et al., 2014), intervalos R-R (Chazal et al., 2004; Ye et al., 2012; Zhang et al., 2014; Shi et al., 2019; Mondéjar-Guerra et al., 2019), transformadas Wavelet-Fourier (Ince et al., 2009; Ye et al., 2012; Sharma et al., 2019), técnicas estadísticas (Rajesh and Dhuli, 2018) y a través de los coeficientes de Hermite (Osowski et al., 2004; Lannoy et al., 2011). Sin embargo, estos métodos tradicionales resultan ser poco eficaces cuando existe una heterogeneidad entre las AC y la fisiología cardiovascular de cada paciente. Lo que resulta en que las *metodologías tradicionales* sean ineficientes en la diferenciación

correcta de las arritmias. La extracción de características es un proceso fundamental para garantizar el éxito en la clasificación de las arritmias, en su época estos métodos fueron los mejores. No obstante, en la actualidad se está amplificando el uso de los DLA para tal fin. Estos algoritmos han demostrado ser mucho mayor eficientes cuando se trata de clasificación o predicción (Abdar et al., 2021; Piccialli et al., 2021). Por lo que, a lo largo de estos 20 años, su uso se ha incrementado exponencialmente y ha dado oportunidad a la creación de nuevos DLA; con el simple objetivo de mejorar la clasificación en las AC (Murat et al., 2020; Ebrahimi et al., 2020).

El tema de los DLA; se refiere a los estudios sobre extracción de conocimiento, predicciones y toma de decisiones de una manera inteligente, es decir, al reconocimiento de patrones intrincados utilizando un conjunto de datos, que suelen llamarse datos de entrenamiento. Los DLA comparados con las técnicas de aprendizaje tradicionales, resultan ser más escalables, ya que usualmente se logra una mayor precisión aumentando la profundidad de la red neuronal o el conjunto de datos de entrenamiento. Los AAA, no son malos del todo, al final sirven para un propósito. Sin embargo, resultan ser improductivos para la mayoría de las demandas que exigen las aplicaciones modernas, y si a esto le agregamos la cantidad de información digital que se produce día a día, estos en definitiva requieren de una gran cantidad de observaciones para lograr la generalización (Goodfellow et al., 2016; Loni et al., 2020). AAA como: máquinas de vectores de soporte (MVS) (Polat et al., 2008; Dutta et al., 2010; Rajesh and Dhuli, 2017), bosques aleatorios (Kumar et al., 2012; Zabihi et al., 2017; Kropf et al., 2017), vecino más cercano (Rajani Kumari et al., 2021; Touluni et al., 2021) y regresión logística (Shimpi et al., 2017), se han utilizado en estudios previos para la clasificación de diferentes tipos de arritmias. Los trabajos previamente mencionados no representa a todo el universo de AAA que se han utilizado con la finalidad de clasificar AC, por lo que en (Parveen et al., 2021; Sraitih et al., 2021; Jain et al., 2021) puede encontrar mayor información sobre cada uno de estos algoritmos.

Por otro lado, en los últimos 10 años se han propuesto varios DLA con el objetivo de mejorar la precisión o clasificación de diferentes tareas de aprendizaje. Entre los más emblemáticos se incluye al perceptrón multicapa (PM), la RNC, la red neuronal recurrente (RNR), memoria a corto plazo (MCP) y red de creencias profundas (Gharehbaghi and Khatibinia, 2015). Siendo la RNC la más preferida para el trabajo de clasificación de AC; con un 52 % de participación, un 10.6 % en modalidad híbrida (RNC+MCP) y finalmente un 6.6 % utilizando (RNC+RNR) (Ebrahimi et al., 2020).

Entre los trabajos de investigación que se han propuesto para la clasificación de AC y que hacen uso de los DLA, destacan los siguientes: (Triqui and Benyettou, 2018; Savalia and Emamian, 2018; Kumar et al., 2019; Valupadasu and Chunduri, 2019; Ramkumar et al., 2021; Borghi et al., 2021) propusieron el uso de PM para el objetivo en común. Por otra parte, (Schwab et al., 2017; Limam and Precioso, 2017; Singh et al., 2018; Mostayed et al., 2018; Banerjee et al., 2019; Park and Yun, 2019; Simanjuntak et al., 2020) hicieron uso de la RNR, la MCP fue utilizada por (Gao et al., 2019; Hou et al., 2019; Yildirim et al., 2019; Saadatnejad et al., 2019; Kim and Pyun, 2020; Wang, 2021). Finalmente, como ya se había mencionado

con anterioridad las CNN tienen una mayor aportación con los trabajos realizados por (Kachuee et al., 2018b; Yıldırım et al., 2018; Jun et al., 2018; Salem et al., 2018; Şen and Özkurt, 2019; Izci et al., 2019; Liu et al., 2019; Rohmantri and Surantha, 2020; Wang et al., 2020; Atal and Singh, 2020; Ferretti et al., 2021; Mathunjwa et al., 2021; Zhang et al., 2021). Surgen también la combinación entre dos ADL, es decir, la creación de modelos híbridos. Tal es el caso de (Chen et al., 2020; Ma et al., 2020; Rai and Chatterjee, 2021) con RNC+MCP y (Zihlmann et al., 2017; Limam and Precioso, 2017; Van Zaen et al., 2019; Sigurthorsdottir et al., 2020) quienes utilizaron las CNN+RNR. Cada uno de los aportes descritos previamente, en conjunto, tienen algo en común: la arquitectura o los hiperparámetros necesarios para el correcto funcionamiento y la obtención de los resultados publicados; fueron seleccionados de manera artesanal.

Lo anterior, abre una oportunidad a los trabajos de investigación que en definitiva hacen uso de modelos híbridos. Ya mencionamos al menos dos ejemplos que combinan dos ADL. No obstante, la combinación de los ADL sigue teniendo el mismo problema: la selección de los hiperparámetros artesanalmente, lo que en algunas ocasiones representa depreciar la mejor configuración.

Por ello, han surgido modelos híbridos que combinan el uso de algoritmos metaheurísticos (AM) con DLA. Estos han tenido resultados interesantes; en esencia, cada AM busca optimizar parámetros primordiales para el funcionamiento de los DLA. Los hay desde los que se encargan optimizar los pesos en las capas de profundidad, hasta los AM que se encargan de optimizar hiperparámetros propios de la naturaleza de los ADL.

La cantidad de publicaciones disponibles usando este tipo de estrategia es muy mínima comparada con las que hacen uso de cualquier técnica de aprendizaje profundo. Por ejemplo, (Houssein et al., 2021b) proponen el uso de el AM depredadores marinos y las CNN, obteniendo precisiones que oscilan entre el 99.31 % al 99.76 % en la clasificación de arritmias. Dentro de las técnicas clásicas de aprendizaje automático, (Ayar and Sabamoniri, 2018) desarrollaron un modelo híbrido basado en los algoritmos genéticos para la optimización de características de un árbol de decisiones. Otro ejemplo, es el propuesto por (Houssein et al., 2018), quien utiliza el algoritmo de máquinas de vectores de soporte gemelos combinados (MVSGC) con un modelo híbrido de AM compuesto por el PSO y el algoritmo de búsqueda gravitacional; estos últimos dos para la optimización de los parámetros del MVSGC. Existen las propuestas de otros modelos híbridos entre los AM y los DLA, pero su aplicación es distinta a la clasificación de AC. En particular solo mencionaremos dos; el desarrollado por (Navaneeth and Suchetha, 2019), que se fundamenta en el uso del PSO-CNN-MVS con el objetivo de clasificar enfermedades renales crónicas, y finalmente, (Houssein et al., 2021a) quienes propusieron un modelo híbrido compuesto por el algoritmo optimizador de apareamiento de percebes con MVS, para la selección de genes en la clasificación de cáncer.

Podemos observar que, tanto la implementación como la aparición de modelos de redes neuronales y técnicas metaheurísticas en el campo de la salud, ha adquirido relevancia entre distintos investigadores de diferentes partes del mundo. La mayoría de los trabajos mencionados con anterioridad se centra en el uso de técnicas de aprendizaje profundo. La apa-

rición de modelos híbridos que incluye a los AM y los DLA, es un suceso que se está volviendo más frecuente en distintos campos de la ciencia, la medicina no es la excepción.

3. Modelo PSO-CNN

A continuación se describe de manera muy breve la teoría matemática que hay detrás de cada una de las técnicas implementadas: se comienza con el PSO, posteriormente las CNN, y finalmente el modelo híbrido PSO-CNN.

3.1. Optimización por Enjambre de Partículas

La optimización por enjambre de partículas estándar, fue originalmente propuesta por (Kennedy and Eberhart, 2006); y es un algoritmo metaheurístico que se utiliza a menudo en problemas de optimización discretos, continuos y combinatorios. A pesar de que existe una gran cantidad de modificaciones e hibridaciones, los operadores básicos de este algoritmo metaheurístico se conservan. La propuesta original del PSO está inspirada en el comportamiento que tienen las bandadas de aves o los bancos de peces. De forma general, para este algoritmo se tiene una población de partículas, las cuales operan sobre un espacio de búsqueda acotado. Para cada iteración se generan nuevas posiciones para las partículas, las cuales son obtenidas usando una velocidad que se calcula considerando la mejor posición global y la mejor posición actual de cada partícula. La velocidad de cada partícula del enjambre se actualiza empleando la Ecuación (1).

Para determinar la calidad de población se requiere de una función objetivo, donde se evalúan los individuos cada vez que toman una nueva posición (Ver Ecuación (2)). En la selección de los miembros de la población se debe saber si se trata de un problema de maximización o minimización, de esta forma los operadores del PSO serán empleados correctamente. En cada iteración los elementos de la población comparten información, la cual les permite acercarse con mayor o menor rapidez a la solución global del problema.

$$\mathbf{v}_i(t+1) = w * \mathbf{v}_i(t) + c_1 * r_1[\hat{x}_i(t) - x_i(t)] + c_2 * r_2[g(t) - x_i(t)] \quad (1)$$

Dónde:

- $\mathbf{v}_i(t+1)$: velocidad de la partícula i en el momento $t+1$.
- $\mathbf{v}_i(t)$: velocidad de la partícula i en el momento t .
- w : coeficiente de inercia, reduce o aumenta a la velocidad de la partícula.
- c_1, c_2 : coeficiente cognitivo y social.
- r_1, r_2 : vector de valores aleatorios entre 0 y 1 de longitud igual a la del vector velocidad.
- $\hat{x}_i(t)$: mejor posición en la que ha estado la partícula i hasta el momento.
- $x_i(t)$: posición de la partícula i en el momento t .
- $g(t)$: posición de todo el enjambre en el momento t , el mejor valor global.

$$x_i(t + 1) = x_i(t) + v_i(t + 1) \quad (2)$$

Dónde $x_i(t + 1)$ es el vector que contiene las nuevas posiciones obtenidas en la iteración $t + 1$, $x_i(t)$ corresponde a las posiciones previas de las partículas que se calcularon en la iteración t . Finalmente, $v_i(t + 1)$ es el vector de velocidad que se obtuvo usando la Ecuación (1). Es importante mencionar que la mayoría de las modificaciones del PSO que se pueden encontrar en la literatura, realizan alteraciones al cálculo de la velocidad y la forma en que las partículas son desplazadas.

3.2. Red Neuronal Convolutiva

Las CNN son un tipo de algoritmo de aprendizaje profundo basado en estructuras de redes neuronales artificiales, donde las *neuronas* corresponden a campos receptivos de una manera muy similar a las neuronas en la corteza visual primaria de un cerebro biológico. Una RNC suele trabajar muy bien con matrices bidimensionales; lo que resulta en una buena efectividad para tareas de visión artificial, en la clasificación y segmentación de imágenes, entre otras (Kachuee et al., 2018b).

Las CNN están conformadas por múltiples capas de filtros convolucionales de una o más dimensiones. Después de cada capa, por lo general se añade una función para realizar un mapeo causal no-lineal. A diferencia de los AAA convencionales, las arquitecturas de las CNN, no necesitan extraer características hechas a mano de los datos sin procesar. Tanto la extracción de características como las partes de clasificación están integradas en la arquitectura y, por lo tanto, identifican automáticamente las características sólidas a partir de los datos de entrada (Yıldırım et al., 2018). Cualquier RNC tiene tres tipos de capas que la distinguen: convolución, agrupación y totalmente conectada.

En la capa de convolución, las muestras de entrada se convolucionan con un kernel específico. Se proporcionan muchas características moviendo el kernel específico (Kim et al., 2019). La ecuación de la función de convolución discreta se define como:

$$(f * g)(x) = \sum_t f(t) * g(x+t) \quad (3)$$

Dónde f y g son dos funciones. Para señales 2D como imágenes, la Ecuación (3) se cambia por la siguiente:

$$K * G_{(i,j)} = \sum_{m,n} K_{(m,n)} * G_{(i+m,j+n)} \quad (4)$$

Dónde K es un núcleo de convolución y G es una señal 2D. El proceso de convolución permite extraer características efectivas de la entrada. La capa de agrupación se utiliza para reducir la dimensión de la muestra de entrada manteniendo las características óptimas.

En la capa totalmente conectada, todas las neuronas de la capa actual están interconectadas con las neuronas de la siguiente capa. Como tal, los resultados de las capas de convolución y agrupación se utilizan para la clasificación. Entre las capas de convolución y totalmente conectadas, hay una capa aplanada donde los vectores de características multidimensionales se transforman en vectores de salida 1D (Faust et al., 2018).

Además, en la capa totalmente conectada, los datos se proporcionan desde la capa plana y el proceso de aprendizaje se realiza a través de la red neuronal.

3.3. PSO - CNN

El modelo híbrido PSO-CNN propuesto por (Fernandes Junior and Yen, 2019), se centra en la optimización de arquitecturas que garanticen buenos resultados en la clasificación de imágenes digitales por medio de una RNC.

El autor de este modelo, estableció sus propios operadores que le permitieron calcular la velocidad y posición de cada una de las partículas que conforman al PSO; siguiendo la filosofía del metaheurístico. Pero, el cálculo de estas variables lo logra de una manera muy diferente a la que tradicionalmente se ha publicado. Cada partícula que conforma a la población del PSO, se encuentra definida por una determinada configuración que representa a una arquitectura de cierto número de capas tanto convolucionales, de agrupación y totalmente conectadas; cada tipo de capa recibe hiperparámetros de entrada según su naturaleza. Por ejemplo: las capas convolucionales reciben el tamaño de kernel, mientras que las totalmente conectadas el número de neuronas. Estas variables forman parte de una partícula, la cual representa una arquitectura de capas que toda RNC requiere para su correcto funcionamiento. La función objetivo del PSO se encuentra definida por el valor de la pérdida obtenida en la clasificación, durante la fase de entrenamiento.

Es indispensable dividir el conjunto de datos en: datos de entrenamiento y de prueba, para que el PSO-CNN se encargue de entrenar y probar la clasificación que le sea encomendada.

En este modelo, la mejor partícula global se obtiene mediante el uso de los mejores bloques de arquitecturas encontrados en el enjambre. Por lo tanto, no es necesario optimizar manualmente los hiperparámetros de cada bloque. Los mejores bloques de arquitecturas se transmiten a la siguiente generación como la mejor partícula global.

A continuación, se proporcionan mayores detalles sobre el marco que usa el PSO-CNN para su correcto funcionamiento, el cual está conformado por seis procedimientos.

- Representación de una RNC eficiente:** Este procedimiento resulta ser de suma importancia, por que define la arquitectura que la RNC debe tener para su correcto funcionamiento y optimización por parte del PSO. Dicha arquitectura de capas es utilizada para la fase de entrenamiento de la propia red neuronal. Se describe como una matriz que incluye los detalles de cada arquitectura, que a su vez contiene la información del tipo de capa con sus correspondientes hiperparámetros. Hay cuatro tipos de capas: convolucional, agrupación máxima, agrupación media y totalmente conectada. Por ejemplo, una sola posición en esta lista contendrá: el tipo de capa, el número de mapas de características de salida, el número de neuronas y el tamaño del kernel. La Figura 1 ilustra la representación utilizada en el algoritmo PSO-CNN, donde C , P y FC representan a capas convolucionales, agrupadas y completamente conectadas, respectivamente.

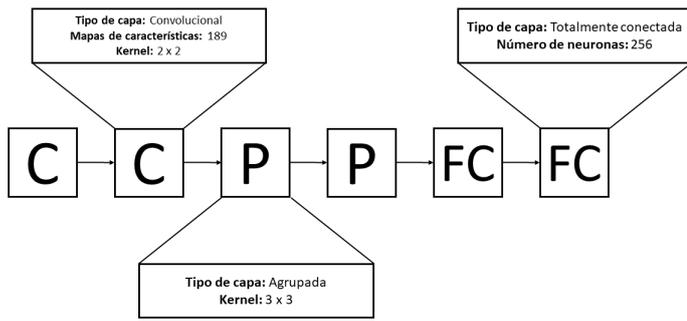


Figura 1: Representación de una partícula: arquitectura de capas e hiperparámetros de la red neuronal.

Una característica destacable de este modelo es la representación no numérica de cada una de las partículas que conforman a la población del PSO, lo que lo lleva a replantear la forma en cómo se realiza el cálculo tanto de la velocidad como de la posición, metodología que será explicada en los siguientes párrafos.

- Población inicial:** El establecer la población inicial es el primer procedimiento que el PSO-CNN lleva a cabo mediante la filosofía de la *Representación de una RNC eficiente*, este paso crea N partículas, y cada una de ellas posee cierta arquitectura de capas aleatoria. El autor de este modelo establece que la primer capa de toda arquitectura debe ser siempre de tipo convolutiva, y de igual forma la última capa de dicha arquitectura deberá ser totalmente conectada; con igual número de neuronas que corresponda al número de categorías a clasificar. Otra restricción que el autor establece en su modelo, se refiere a que las capas totalmente conectadas no se pueden colocar entre las convolucionales o las capas agrupadas, sólo al final de estas. Normalmente, las capas totalmente conectadas se utilizan para clasificar las características extraídas por las convolucionales y las agrupadas. El uso de capas totalmente conectadas entre convolucionales y agrupadas, aumentaría el número de parámetros que la red neuronal requeriría. Los hiperparámetros necesarios para las capas convolucionales, agrupadas y totalmente conectadas, como lo es: el tamaño del kernel, el mapa de características y el número de neuronas, son valores aleatorios que se generan de manera distinta para cada arquitectura. La función de activación de todas las capas es siempre una unidad lineal rectificadora (ReLU), mientras que la función Softmax es utilizada en la última capa de cada arquitectura.
- Evaluación de aptitud:** La evaluación de la aptitud para cada partícula se hace compilando la arquitectura de partículas en una RNC completa y entrenándola para un total de épocas de entrenamiento. La evaluación en sí se realiza comparando la función de pérdida de cada partícula. En este modelo, se logra a través de la pérdida de entropía cruzada categórica. Por tanto, el objetivo del algoritmo es encontrar una arquitectura de partículas con la menor pérdida, independientemente del número de parámetros u otros criterios. El entrenamiento se realiza

con Adam (Kingma and Ba, 2014) y los pesos se inicializan con Xavier (Glorot and Bengio, 2010). Además, también es posible añadir abandonos y normalización de lotes entre capas evitando el problema del sobreajuste (Ioffe and Szegedy, 2015).

- Medida de la diferencia entre dos partículas:** Para calcular la velocidad de una partícula, el PSO-CNN requiere como un paso previo obtener la diferencia entre dos partículas, esta diferencia solo toma en consideración el tipo de capa de cada partícula, la comparación siempre es con respecto a la primer partícula y sólo es posible obtener tres resultados. Si ambas partículas tienen diferente tipo de capas, se mantienen las capas de la primer partícula. Si la primer partícula tiene menos capas que la segunda, se elimina dicha capa. Y por último, si la primer partícula tiene más capas que la segunda, se agregará una capa nueva, misma que puede ser de tipo convolutiva, agrupada o totalmente conectada.
- Cálculo de velocidad:** A diferencia del cálculo matemático tradicional de la velocidad en la mayoría de los PSO, en este modelo el cálculo se realiza de manera muy distinta a las que se conocen hoy en día. Para calcular la velocidad, es indispensable realizar el procedimiento que se describió con anterioridad. La diferencia entre dos partículas, permite al modelo obtener tanto el mejor global y el mejor local, cada uno de ellos representa una partícula, que a su vez contiene toda una arquitectura de capas. Entonces, la velocidad de cualquier partícula se calcula mediante la diferencia entre dicha partícula con respecto al mejor global y el mejor local. Sólo que, en este procedimiento, la decisión de conservar, eliminar o agregar una capa en la actualización de la partícula, depende de un factor de decisión que funcionará de manera aleatoria para cada diferencia.
- Actualización de las partículas:** El modelo sigue la velocidad de una partícula dada en busca de capas que deban modificarse. Las capas se agregan o eliminan de la arquitectura de partículas de acuerdo con su velocidad. No obstante, el PSO-CNN necesita realizar un seguimiento del número de capas de agrupación en la arquitectura. Dependiendo del tamaño de las entradas de entrenamiento, solo se permite un número finito de capas de agrupación. Si, después de la actualización, la partícula termina con más capas agrupadas de las permitidas, las capas agrupadas en exceso se eliminan de la arquitectura de la partícula desde la última hasta la primera capa, una por una.

Si el lector requiere de un mayor entendimiento sobre cada uno de los procedimientos descritos con anterioridad, se sugiere consultar el trabajo de investigación del autor de este modelo.

4. Metodología

En este apartado se describe la metodología e instrumentación utilizados para la clasificación de las AC, mediante la implementación del modelo híbrido PSO-CNN.

La metodología consta de los siguientes pasos:

- Preprocesamiento del MIT-BIH Arrhythmia database: esta primera etapa consiste en preparar la base de datos de las AC, de tal forma que su información pueda ser entendida y procesada por la RNC.
- Configuración de los parámetros iniciales: se establecen los valores necesarios para el funcionamiento tanto del PSO como la RNC.
- Generación de la población inicial: se crea la población inicial con el número de partículas establecido dentro de los parámetros iniciales, cada partícula contiene una arquitectura de capas que es generada de manera aleatoria.

- Cálculo de operadores del PSO: tomando en cuenta la aptitud de cada partícula se calcula la diferencia y velocidad entre dos partículas, estos operadores determinan la siguiente etapa de la metodología.
- Actualización de las partículas: en esta fase se realizan las modificaciones a cada una de las partículas que conforman a toda la población, es en esta etapa dónde se optimizan tanto el número como tipo de capas.
- Obtención del mejor global: aquella partícula con un valor de pérdida mínimo entre toda la población, es considerada como la mejor global.
- Evaluación del desempeño de la RNC con los datos de prueba: se considera la arquitectura de capas del mejor global y se evalúa el rendimiento de la RNC con los datos de prueba, se obtienen las métricas correspondientes y la matriz de confusión.

El flujo de estos pasos se pueden observar en la Figura 2.

5. Diseño Experimental

5.1. Conjunto de datos y Entorno de desarrollo

5.1.1. Conjunto de datos

El MIT-BIH Arrhythmia dataset (Goldberger et al., 2000; Moody and Mark, 2001) es un estándar de referencia y de libre acceso con contenido de investigación regular para todas las tareas de clasificación. Este conjunto de datos es considerado el primer material de prueba estándar para la evaluación de los electrocardiogramas, con el objetivo de la detección y clasificación de las AC. De igual manera, para la investigación de la dinámica cardiovascular (Moody and Mark, 2001). Contiene 48 extractos de electrocardiogramas ambulatorios de dos canales, con una duración de 30 minutos cada uno de ellos, los cuales fueron obtenidos de un total de 47 pacientes, estudiados por el Laboratorio de Arritmias del BIH entre 1975 y 1979. De los cuales, veintitrés son registros al azar de un conjunto de 4000 24-registros de electrocardiogramas ambulatorios de una hora, recopilados de una población mixta de pacientes hospitalizados (alrededor del 60%) y pacientes ambulatorios (alrededor del 40%) en el Hospital Beth Israel de Boston. Las 25 grabaciones restantes que pertenecen al mismo conjunto incluyen arritmias menos comunes, pero clínicamente significativas que no estarían bien representadas en una pequeña muestra aleatoria.

Las grabaciones se digitalizaron a 360 muestras por segundo por canal, con una resolución de 11 bits en un rango de 10 mV. Dos o más cardiólogos anotaron de forma independiente cada registro; los desacuerdos se resolvieron para obtener las anotaciones de referencia legibles por computadora para cada latido (aproximadamente 110 000 anotaciones en total) incluidas en la base de datos.

Usando Physionet ATM Bank, es posible obtener los datos que corresponden a cada ECG del MIT-BIH Arrhythmia dataset. Sin embargo, este conjunto de datos no está listo para ser utilizado en cualquier DLA o AAA. Se tiene que llevar a cabo una fase de preprocesamiento y categorización, para que cualquier modelo de aprendizaje automático o profundo sea capaz de entrenar y obtener resultados. (Kachuee et al., 2018b) abordaron la clasificación de estas arritmias, una de sus aportaciones

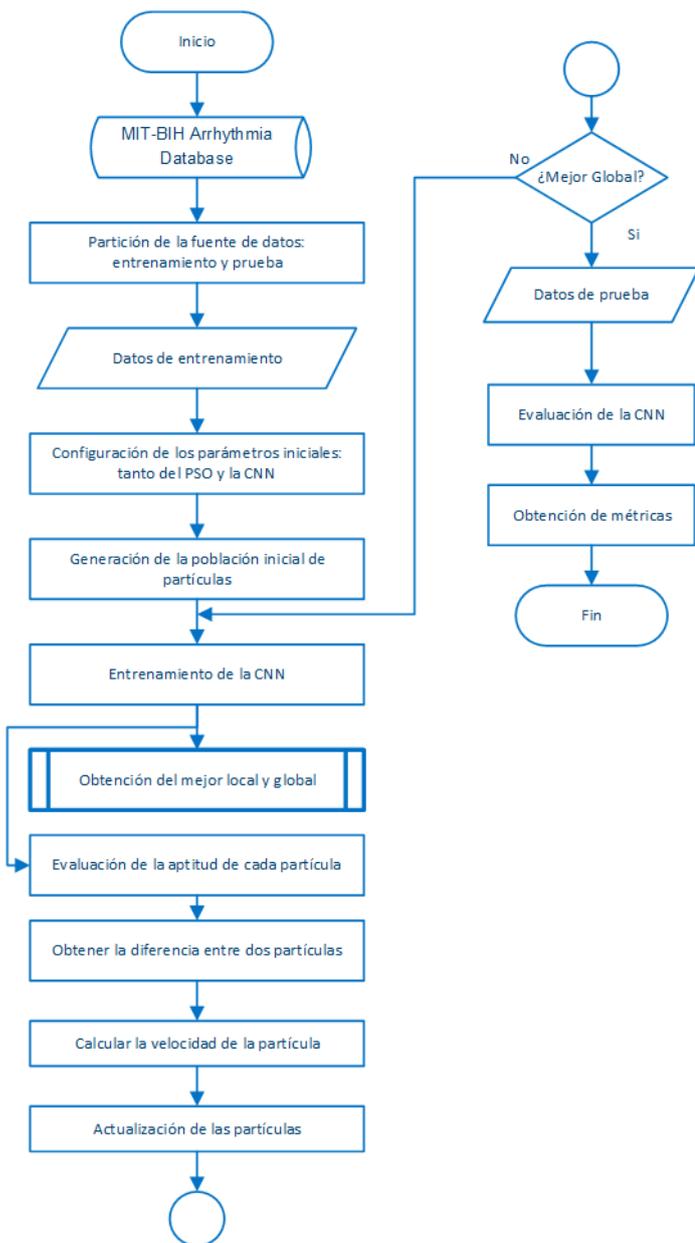


Figura 2: Diagrama de flujo de la metodología en la clasificación de arritmias cardíacas, utilizando el PSO-CNN.

- Evaluación de la aptitud: se entrena a la RNC con cada una de las partículas generadas previamente y se evalúa el valor de la pérdida obtenida con cada entrenamiento.

fue la transferencia de la base de datos original disponible en Physionet ATM Bank, a un formato fácilmente entendible para cualquier red neuronal simple o profunda. Kachuee extrajo del MIT-BIH Arrhythmia dataset, cinco categorías de arritmias cardíacas diferentes, según el estándar EC57 de la AAMI. En la Tabla 1 se pueden visualizar estas categorías, que a su vez incluyen sus correspondientes anotaciones. Las anotaciones se refieren al nombre de una determinada arritmia cardíaca, que se encuentra clasificada según corresponda la categoría a la que pertenece. Ellos realizaron 7 pasos para transferir la base de datos original a una de tipo vectorial, los cuales fueron:

1. Dividieron la señal del ECG continua en ventanas de 10 segundos.
2. Normalizaron los valores de amplitud al rango de cero a uno.
3. Calcularon el conjunto de todos los máximos locales basados en los cruces por cero de la primera derivada.
4. Calcularon el conjunto de candidatos R-peak del ECG, aplicando un umbral de 0.9 sobre el valor normalizado de los máximos locales.
5. Obtuvieron la mediana de los intervalos de tiempo R-R como el período de latido nominal de esa ventana (T).
6. Para cada pico R, seleccionaron una parte de la señal con una longitud igual a 1.2T.
7. Rellenaron cada parte seleccionada con ceros para hacer su longitud igual a una longitud fija predefinida.

El procesamiento de (Kachuee et al., 2018b) obtuvo un total de 109,446 filas; de las cuales se tomó el 80 % (87,554 muestras) para la fase de entrenamiento y el 20 % (21,892) para las pruebas. Cada fila representa a una anotación, y se encuentra compuesta por 187 columnas; la última de ellas contiene el valor de la categoría a la que pertenece la anotación. Las otras 186 columnas restantes contiene valores numéricos normalizados que pertenecen al trazo del ECG, aquellas filas que no completan las 186 columnas, sus valores numéricos son completados con ceros, tal y como lo explica (Kachuee et al., 2018b). Este autor generó dos archivos separados por comas (CSV), el primero de ellos contiene el 80 % de los datos y que corresponden a la entrada en la fase de entrenamiento de la red neuronal convolucional, mientras que el 20 % restante a los de prueba.

Los archivos previamente mencionados que contienen los resultados de este proceso los puede consultar en: (Kachuee et al., 2018a).

La morfología gráfica de cada una de las categorías que se describen en la Tabla 1, se muestran en la Figura 3, en ella se puede apreciar el comportamiento característico que cada categoría de arritmia presenta.

Estas arritmias se encuentran organizadas y clasificadas según la categoría a la que pertenecen, tal y como se puede apreciar en la Tabla 2. Donde podemos observar que el mayor número de AC se centra en las de categoría **N**, mientras que la media en las arritmias que pertenecen a la categoría **Q**, y finalmente, la categoría con menor número de datos es la **F**. La división de los datos para entrenamiento y para pruebas, se realizó mediante el principio de Pareto; cada categoría se renombró con un valor numérico de 0 a 4, es decir, el 0 para la categoría **N**, el 1 para la **S** y así sucesivamente. Con lo anterior, la RNC es

capaz de obtener como salida un valor numérico, dicho valor pertenece a una categoría en particular.

Tabla 1: Categorías y anotaciones de arritmias cardíacas, conforme a la AAMI EC57.

Categoría	Anotación
N	Latidos normales
	Bloqueo de rama Derecha/Izquierda
	Escape auricular
	Escape nodal
S	Contracción auricular prematura
	Latido auricular aberrante prematuro
	Bloqueo atrial prematuro
	Unión nodal prematura
V	Contracción ventricular prematura
	Escape ventricular
	Onda de aleteo ventricular
F	Fusion de ventricular y normal
Q	Fusion de rítmica y normal
	No clasificable

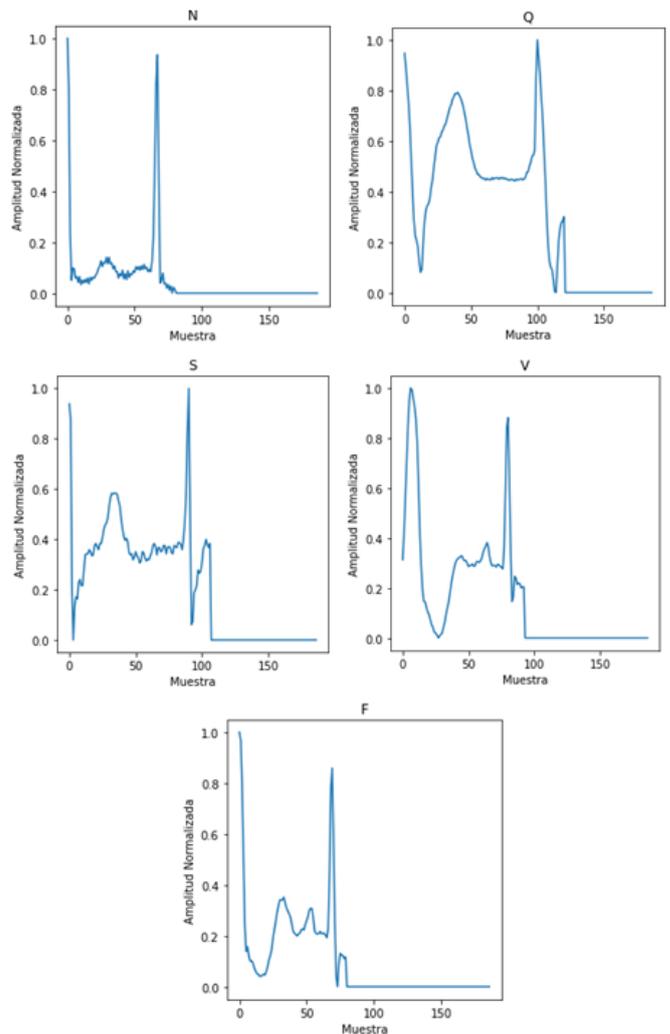


Figura 3: Representación gráfica de las arritmias cardíacas del MIT-BIH Arrhythmia dataset.

Tabla 2: Conjunto de datos para entrenamiento y pruebas

Categoría	Entrenamiento	Prueba	Total
N	72,471	18,118	90,589
S	2,223	556	2,779
V	5,788	1,448	7,236
F	641	162	803
Q	6,431	1,608	8,039
Total	87,554	21,892	109,446

5.1.2. Entorno de desarrollo

Los experimentos se realizaron utilizando principalmente dos entornos de desarrollo: software y hardware.

- Software: Python 3.7.2 como lenguaje de programación, Keras 2.4.3 y Tensorflow 2.3.0 como bibliotecas de aprendizaje profundo, y Anaconda Navigator como entorno de desarrollo integrado.
- Hardware: Mac Pro (2019), procesador a 2.7 GHz Intel Xeon W de 24 núcleos, 192 GB de memoria RAM a 2922 MHz y con una tarjeta gráfica AMD Readon Pro 580X 8 GB.

Python es un lenguaje de programación que permite el desarrollo de aplicaciones enfocadas a la inteligencia artificial, y para lograrlo hace uso de bibliotecas como lo son Keras y Tensorflow; bibliotecas que cuentan con métodos configurados para el uso de DLA o en su defecto de AAA.

Se definieron métodos que permitieron: el preprocesamiento del conjunto de datos, reconfiguración de la RNC para su funcionamiento con datos vectoriales y finalmente un método para el correspondiente cálculo de métricas. El marco original del PSO-CNN se conservó.

5.2. Parámetros de configuración

El modelo PSO-CNN requiere como todo algoritmo computacional de ciertos argumentos de entrada para lograr su correcto funcionamiento, y con ello garantizar las salidas esperadas. Las variables y sus respectivos valores para este modelo se describen en la Tabla 3, dónde se puede visualizar que estas variables se encuentran categorizadas según el algoritmo al que pertenecen. La categoría PSO controla el comportamiento del algoritmo metaheurístico y requiere conocer: el número de iteraciones que el metaheurístico realizará antes de considerar que la optimización ha finalizado, el número de partículas que contendrá la población inicial, y la probabilidad (Cg) de elegir una capa de la mejor global al calcular la velocidad de una partícula. Un Cg más alto hará que la arquitectura de las partículas se parezca a la mejor global lo más rápido posible, reduciendo la diversidad del enjambre y, en consecuencia, aumentando la probabilidad de quedar atrapado en una arquitectura óptima local.

Por otra parte, la categoría CNN contiene los hiperparámetros que la red neuronal requiere para su correcto funcionamiento, hiperparámetros como lo son: mapas de características, tamaño del kernel, número de neuronas, tamaño del lote, número de épocas, profundidad y dilución. Son valores que se generan de manera aleatoria dentro del rango especificado para cada partícula de la población. (Ver Tabla 3).

Los mapas de características y tamaño del kernel, son valores que son necesarios para el funcionamiento de las capas convolucionales y agrupadas. El número de neuronas, es un argumento que pertenece a las capas totalmente conectadas y la profundidad indica el número mínimo-máximo de capas que contiene cada partícula. Mientras que, el tamaño del lote, se refiere a la cantidad de datos que son proporcionados a la red neuronal, con la finalidad de evitar aún más el sobreajuste durante el proceso de entrenamiento. El número de épocas controla cuántas veces se entrena la partícula.

Finalmente, la dilución, se utiliza durante cualquier entrenamiento de partículas para evitar el sobreajuste al eliminar un porcentaje de las conexiones entre neuronas en capas completamente conectadas al azar.

Tabla 3: Configuración de parámetros para la clasificación de arritmias cardíacas, por medio del modelo híbrido PSO-CNN.

Categoría	Descripción	Valor
PSO	Iteraciones	10
	Población	15
	Cg	0.5
CNN	Mapas de características	[3 - 200]
	Kernel	[2 x 2 - 5 x 5]
	Número de neuronas	[5 - 256]
	Tamaño de lote	64
	Número de épocas	10
	Profundidad	[3 - 15]
	Dilución	0.5

El primer paso del modelo consiste en la inicialización de la población, y corresponde a la iteración cero del PSO. Este paso se encarga de: crear una población inicial o enjambre, de arquitecturas de capas. Esta población inicial contendrá individuos con arquitecturas elegidas al azar delimitadas por los valores que se definen en la Tabla 3. El modelo entrena, y obtiene la precisión y la pérdida para esa partícula, el primer valor que corresponde al primer individuo inicializado lo asigna como el mejor local, este paso lo repite para las demás partículas; comparando la pérdida actual con su antecesora, si ésta es mínima a la anterior, la asigna como el mejor local. Al terminar el entrenamiento y evaluación con todas las partículas de la población, durante el proceso de inicialización, el algoritmo establece como al mejor local, a aquella partícula que obtuvo el valor mínimo.

El siguiente paso, consiste en actualizar la población mediante la filosofía del PSO y, a través de los operadores de velocidad y posición definidos por el autor calcular los cambios necesarios en la arquitectura de cada partícula. Al finalizar con esta actualización, como tercer paso, se repite el proceso explicado en la inicialización de la población hasta cumplir con el número total de iteraciones asignadas a la categoría PSO descritas en la Tabla 3. Cada partícula generará un óptimo local, mientras que cada iteración un óptimo global.

Al concluir con todas las iteraciones, el modelo toma en consideración al mejor global y como último procedimiento, lo evalúa nuevamente, pero ahora con datos distintos a los utilizados en el entrenamiento. Obteniendo así, la precisión, sensibilidad y valor-F; los últimos tres valores para cada una de las categorías de arritmias.

La configuración completa de la mejor arquitectura encontrada por el PSO, es almacenada de forma persistente.

6. Resultados

En esta sección se describen los resultados que se obtuvieron a través de la implementación del modelo PSO-CNN.

El modelo computacional fue capaz de obtener la configuración de arquitectura de capas que se muestra en la Tabla 4. Se puede observar que el PSO obtuvo una arquitectura que consta de tres capas: la primera y la última corresponden a las que el autor del modelo establece como obligatorias; los hiperparámetros de la primer convolucional fueron calculados de manera aleatoria. Por otra parte, el número de neuronas de la última capa, corresponde al número de categorías de arritmias; una neurona para cada categoría. Finalmente, la capa convolucional intermedia, es aquella que fue obtenida a través de la filosofía del PSO, este AM comenzó su optimización con una población inicial de 15 partículas, cada partícula con una profundidad de 3 a 15 capas; generadas al azar.

El número de iteraciones para el PSO se describe en la Tabla 3, cada iteración obtiene la precisión y pérdida de la mejor partícula local, con los datos de entrenamiento. Al finalizar el total de iteraciones, se evalúa cada uno de las mejores arquitecturas locales obtenidas y, con ello se obtiene la mejor arquitectura global. La mejor partícula global está definida por aquella que obtuvo el valor mínimo entre todas las mejores partículas locales. La evolución de los valores en la pérdida para los mejores locales se puede visualizar en la Figura 4. Aunque el valor de la precisión no está directamente relacionado con el funcionamiento en la optimización por el AM, representa un valor que se relaciona directamente con el valor de la pérdida; a una menor pérdida una mayor precisión. Los valores numéricos de este ítem se observan en la a Figura 5.

Al concluir con las iteraciones del PSO, el modelo computacional se encarga de evaluar el rendimiento de la RNC con la mejor arquitectura global. La red neuronal se configuró a un total de 10 épocas para la fase de prueba. La evolución de los valores de la pérdida y la precisión se pueden apreciar en la Figura 6 y Figura 7, respectivamente.

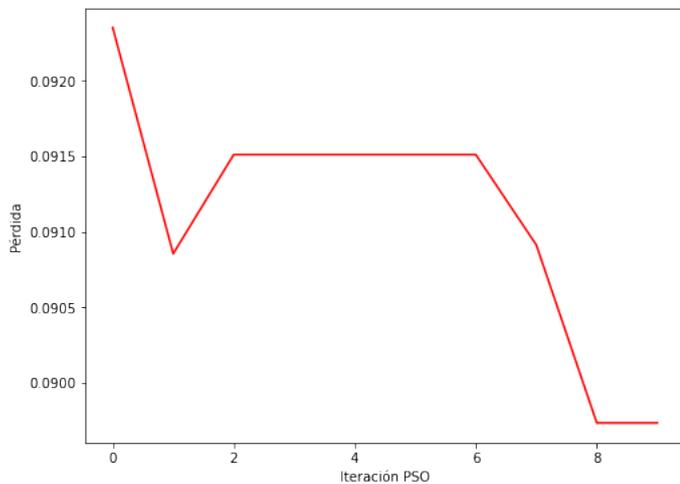


Figura 4: Optimización del valor de pérdida de la RNC, por parte del PSO.

Los resultados obtenidos con los datos de prueba se pueden visualizar en la Tabla 5. La RNC con la mejor partícula obtuvo una precisión del 97 % para la categoría **N**, 94 % para **S**, 95 % en **V**, 81 % en **F**, y finalmente un 99 % para **Q**. En esta Tabla, también se puede apreciar el Valor-F y la Sensibilidad para cada categoría.

Tabla 4: Mejor arquitectura de capas encontrada por el PSO-CNN.

Tipo de capa	Hiperparámetro	Valor
Convolutacional	Mapas de Características	196
	Kernel	4 x 4
Convolutacional	Mapas de Características	150
	Kernel	3 x 3
Totalmente Conectada	Número de neuronas	5

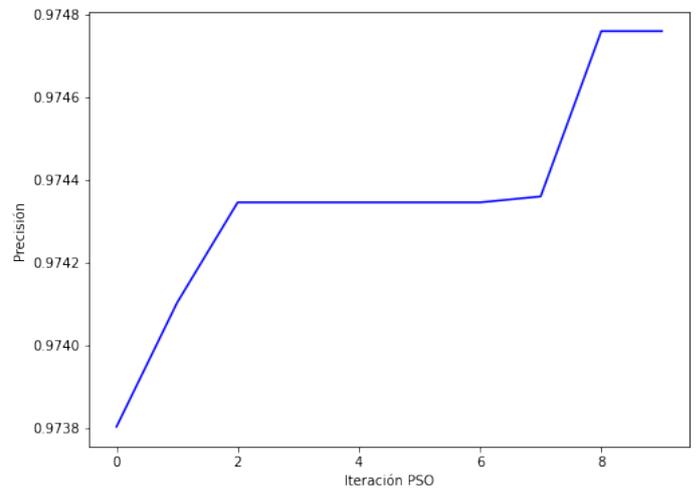


Figura 5: Evolución de la precisión de la RNC, al ser optimizada la pérdida por el PSO.

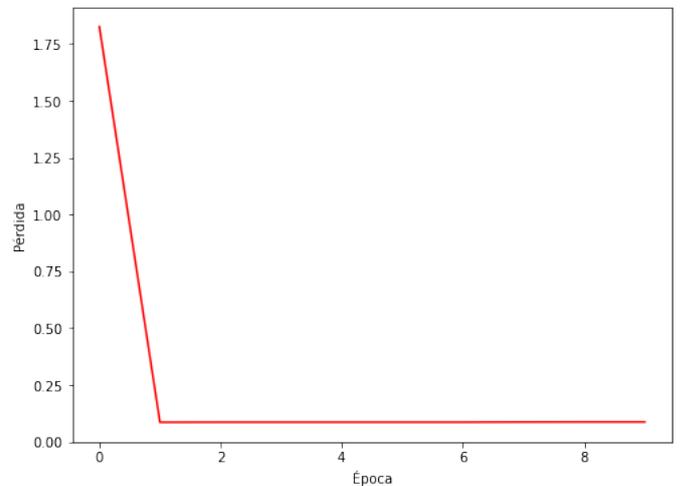


Figura 6: Evolución de la pérdida en la RNC, con los datos de prueba y la mejor partícula.

Tabla 5: Métricas en la clasificación de arritmias cardíacas.

Categoría	Precisión	Sensibilidad	Valor-F
N	0.97	1.00	0.99
S	0.94	0.57	0.71
V	0.95	0.91	0.93
F	0.81	0.48	0.60
Q	0.99	0.95	0.97

La precisión lograda fue del **97 %**. La matriz de confusión se representa en la Figura 8, y en ella se pueden observar los valores estimados de forma correcta por el modelo computacional implementado.

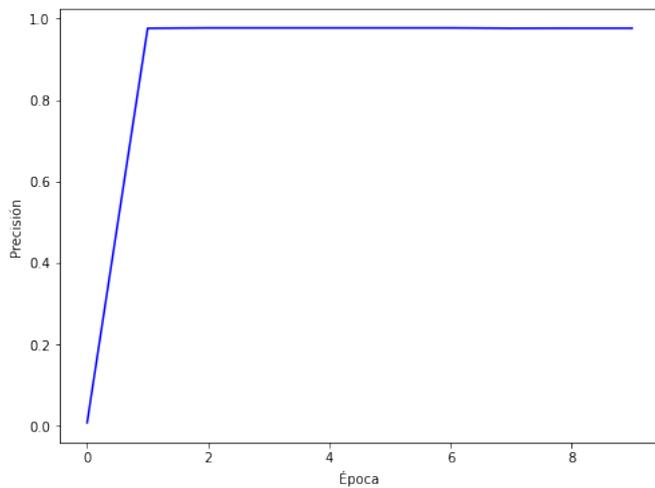


Figura 7: Evolución de la precisión en la RNC, con los datos de prueba y la mejor partícula.

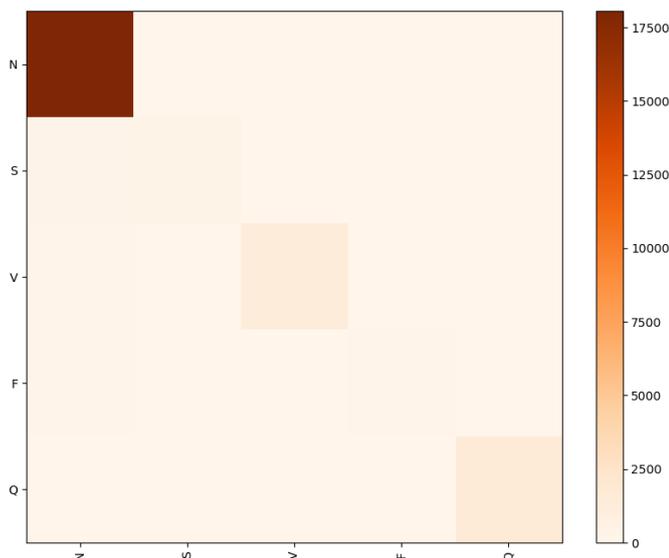


Figura 8: Matriz de confusión en la clasificación de arritmias cardíacas.

7. Discusión

El modelo PSO-CNN, es una estrategia computacional que demuestra ser una buena opción si se busca optimizar el número

de capas internas que una red neuronal convolucional requiere para su entrenamiento y prueba. Ha demostrado que, para una pequeña cantidad de datos, la complejidad de la arquitectura de capas es menor. Sin embargo, este modelo se encuentra limitado al no ser capaz de optimizar los hiperparámetros que cada una de las capas requiere, por ejemplo: mapas de características, tamaño del kernel, número de épocas y neuronas. La precisión lograda por el modelo asciende al 97 %, pero en la categoría **S** a pesar de tener una alta precisión, su sensibilidad es muy baja, lo que significa que el modelo no detecta la clase muy bien, pero cuando lo hace es altamente confiable. Por otra parte, para la clase **F** el modelo obtuvo una precisión y una sensibilidad baja, es decir, no logra clasificar la clase correctamente. En el campo de la salud ésta circunstancia es particularmente frecuente y por ello tenemos que recurrir al balanceo de clases, se puede observar que en la categoría **F** la cantidad de datos para el entrenamiento y las pruebas, es muy mínima comparada con las demás clases. Cabe mencionar que el alcance de este trabajo no incluye el balanceo de las clases.

8. Conclusiones

Este estudio demuestra que los modelos híbridos son métodos que reducen el tiempo en la búsqueda de arquitecturas, proceso que actualmente se realiza de manera artesanal en la mayoría de los modelos, y que aumentan la efectividad de los algoritmos de aprendizaje profundo al encontrar los mejores parámetros que la red requiere en un determinado dominio de problema.

De un total de **109,446** diferentes muestras de arritmias cardíacas; **87,554** se consideraron para el entrenamiento y **21,892** para las pruebas de la RNC. Se obtuvo una precisión del **97 %**, siendo **N, S, V, Q**; las categorías con un mayor valor. Se concluye que, el modelo implementado es un enfoque simple, eficaz y útil que puede ser utilizado por los expertos, para identificar de forma rápida y automática problemas cardiovasculares asociados a arritmias cardíacas. Sin embargo, para aumentar la efectividad del modelo, se requiere trabajar en el balanceo de los datos que pertenecen a cada una de las categorías de arritmias cardíacas, en las que los valores de precisión y sensibilidad no resultaron satisfactorios.

En estudios futuros, el PSO-CNN puede ser utilizado con otras bases de datos e incluir todas las arritmias cardíacas que hoy día existen, para que pueda considerarse como una implementación en sistemas de monitoreo de atención médica domiciliaria, combinando aplicaciones móviles y dispositivos de ECG portátiles, que detectarán automáticamente las arritmias en tiempo real y las compartirán con los médicos, a través de la telemedicina.

Agradecimientos

Al Consejo Nacional de Ciencia y Tecnología (CONACyT, México), le agradezco la beca recibida para estudiar el Doctorado en Ciencias en Ingeniería con Énfasis en Análisis y Modelación de Sistemas.

Esta investigación es apoyada por el proyecto CB-2017-2018-A1-S-43008 del Consejo Nacional de Ciencia y Tecnología.

Referencias

- Abdar, M., Pourpanah, F., Hussain, S., Rezazadegan, D., Liu, L., Ghavamzadeh, M., Fieguth, P., Cao, X., Khosravi, A., Acharya, U. R., Makarenkov, V., and Nahavandi, S. (2021). A review of uncertainty quantification in deep learning: Techniques, applications and challenges. *Information Fusion*, 76:243–297.
- Agrafioti, F. et al. (2011). *ECG in biometric recognition: Time dependency and application challenges*. University of Toronto.
- ANSI/AAMI (2012). Testing and reporting performance results of cardiac rhythm and st segment measure algorithms.
- Aparicio Morales, A. I., Pérez Marrero, F. E., Mederos Portal, A., Hernández Pérez, J. M., and Pérez Álvarez, V. B. (2018). Software educativo para el aprendizaje de las arritmias cardíacas en pediatría. *Edumecentro*, 10(4):72–86.
- Atal, D. K. and Singh, M. (2020). Arrhythmia classification with ecg signals based on the optimization-enabled deep convolutional neural network. *Computer Methods and Programs in Biomedicine*, 196:105607.
- Ayar, M. and Sabamoni, S. (2018). An ecg-based feature selection and heart-beat classification model using a hybrid heuristic algorithm. *Informatics in Medicine Unlocked*, 13:167–175.
- Banerjee, R., Ghose, A., and Khandelwal, S. (2019). A novel recurrent neural network architecture for classification of atrial fibrillation using single-lead ecg. In *2019 27th European Signal Processing Conference (EUSIPCO)*, pages 1–5. IEEE.
- Biel, L., Pettersson, O., Philipson, L., and Wide, P. (2001). Ecg analysis: a new approach in human identification. *IEEE Transactions on Instrumentation and Measurement*, 50(3):808–812.
- Borghi, P. H., Borges, R. C., and Teixeira, J. P. (2021). Atrial fibrillation classification based on mlp networks by extracting jitter and shimmer parameters. *Procedia Computer Science*, 181:931–939.
- Braunwald, E. (2016). Tratado de cardiología. 10maed. *España, SLU: Elsevier*.
- Chazal, P., O'Dwyer, M., and Reilly, R. B. (2004). Automatic classification of heartbeats using ecg morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering*, 51:1196–1206.
- Chen, B., Guo, Y., Chen, Y., Zheng, H., and Liu, T. (2019). Ecg classification based on unfixed-length segmentation of heartbeat. In *2019 IEEE International Conference on Consumer Electronics - Taiwan (ICCE-TW)*, pages 1–2.
- Chen, C., Hua, Z., Zhang, R., Liu, G., and Wen, W. (2020). Automated arrhythmia classification based on a combination network of cnn and lstm. *Biomedical Signal Processing and Control*, 57:101819.
- Dávila, C. A. (2017). Tendencia e impacto de la mortalidad por enfermedades cardiovasculares en México, 1990-2015. In *Revista Cubana de Salud Pública*, volume 45.
- Dutta, S., Chatterjee, A., and Munshi, S. (2010). Correlation technique and least square support vector machine combine for frequency domain based ecg beat classification. *Medical Engineering & Physics*, 32(10):1161–1169.
- Ebrahimi, Z., Loni, M., Daneshmandi, M., and Gharehbaghi, A. (2020). A review on deep learning methods for ecg arrhythmia classification. *Expert Systems with Applications: X*, 7:100033.
- Essam, H. H., Moataz, K., and Aboul, E. H. (2017). Ecg signals classification: a review. *International Journal of Intelligent Engineering Informatics*, 5(4):376–396.
- Faust, O., Hagiwara, Y., Hong, T. J., Lih, O. S., and Acharya, U. R. (2018). Deep learning for healthcare applications based on physiological signals: A review. *Computer Methods and Programs in Biomedicine*, 161:1–13.
- Fernandes Junior, F. E. and Yen, G. G. (2019). Particle swarm optimization of deep neural networks architectures for image classification. *Swarm and Evolutionary Computation*, 49:62–74.
- Ferretti, J., Randazzo, V., Cirrincione, G., and Pasero, E. (2021). 1-d convolutional neural network for ecg arrhythmia classification. In *Progresses in Artificial Intelligence and Neural Systems*, pages 269–279. Springer.
- Gao, J., Zhang, H., Lu, P., and Wang, Z. (2019). An effective lstm recurrent network to detect arrhythmia on imbalanced ecg dataset. *Journal of healthcare engineering*, 2019.
- Gharehbaghi, S. and Khatibinia, M. (2015). Optimal seismic design of reinforced concrete structures under time-history earthquake loads using an intelligent hybrid algorithm. *Earthquake Engineering and Engineering Vibration*, 14(1):97–109.
- Glorot, X. and Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pages 249–256. JMLR Workshop and Conference Proceedings.
- Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., and Stanley, H. E. (2000). Physiobank, and physionet: Components of a new research resource for complex physiologic signals. In *PhysioBank*, pages e215–e220.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.
- Heinze, M. G., Olmedo-Canchola, V., Bazán-Miranda, G., Bernard-Fuentes, N., and Guízar-Sánchez, D. (2018). Los médicos especialistas en México. *Gaceta Médica de México*, 154(3):342–351.
- Hou, B., Yang, J., Wang, P., and Yan, R. (2019). Lstm-based auto-encoder model for ecg arrhythmias classification. *IEEE Transactions on Instrumentation and Measurement*, 69(4):1232–1240.
- Houssein, E. H., Abdelminaam, D. S., Hassan, H. N., Al-Sayed, M. M., and Nabil, E. (2021a). A hybrid barnacles mating optimizer algorithm with support vector machines for gene selection of microarray cancer classification. *IEEE Access*, 9:64895–64905.
- Houssein, E. H., Abdelminaam, D. S., Ibrahim, I. E., Hassaballah, M., and Wazery, Y. M. (2021b). A hybrid heartbeats classification approach based on marine predators algorithm and convolution neural networks. *IEEE Access*.
- Houssein, E. H., Ewees, A. A., and Abd ElAziz, M. (2018). Improving twin support vector machine based on hybrid swarm optimizer for heartbeat classification. *Pattern Recognition and Image Analysis*, 28(2):243–253.
- Huikuri, H. V., Castellanos, A., and Myerburg, R. J. (2001). Sudden death due to cardiac arrhythmias. *New England Journal of Medicine*, 345(20):1473–1482. PMID: 11794197.
- Ince, T., Kiranyaz, S., and Gabbouj, M. (2009). A generic and robust system for automated patient-specific classification of ecg signals. *IEEE Transactions on Biomedical Engineering*, 56(5):1415–1426.
- Ioffe, S. and Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning*, pages 448–456. PMLR.
- Izci, E., Ozdemir, M. A., Degirmenci, M., and Akan, A. (2019). Cardiac arrhythmia detection from 2d ecg images by using deep learning technique. In *2019 Medical Technologies Congress (TIPEKNO)*, pages 1–4. IEEE.
- Jain, P., Arjun Babu, C. S., Mohandoss, S., Anisham, N., Gadade, S., Srinivas, A., and Mohan, R. (2021). A novel approach to classify cardiac arrhythmia using different machine learning techniques. In Gupta, D., Khanna, A., Bhattacharyya, S., Hassanien, A. E., Anand, S., and Jaiswal, A., editors, *International Conference on Innovative Computing and Communications*, pages 517–526, Singapore. Springer Singapore.
- Jun, T. J., Nguyen, H. M., Kang, D., Kim, D., Kim, D., and Kim, Y.-H. (2018). Ecg arrhythmia classification using a 2-d convolutional neural network. *arXiv preprint arXiv:1804.06812*.
- Kachuee, M., Fazeli, S., and Sarrafzadeh, M. (2018a). Ecg heartbeat categorization dataset.
- Kachuee, M., Fazeli, S., and Sarrafzadeh, M. (2018b). Ecg heartbeat classification: A deep transferable representation. In *2018 IEEE International Conference on Healthcare Informatics (ICHI)*, pages 443–444. IEEE.
- Kennedy, J. and Eberhart, R. (2006). Swarm intelligence. In *Handbook of nature-inspired and innovative computing*, pages 187–219. Springer.
- Kim, B.-H. and Pyun, J.-Y. (2020). Ecg identification for personal authentication using lstm-based deep recurrent neural networks. *Sensors*, 20(11):3069.
- Kim, M.-G., Ko, H., and Pan, S. B. (2019). A study on user recognition using 2d ecg image based on ensemble networks for intelligent vehicles. *Wireless Communications and Mobile Computing*, 2019.
- Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kropf, M., Hayn, D., and Schreier, G. (2017). Ecg classification based on time and frequency domain features using random forests. In *2017 Computing in Cardiology (CinC)*, pages 1–4. IEEE.
- Kumar, G., Pawar, U., and O'Reilly, R. (2019). Arrhythmia detection in ecg signals using a multilayer perceptron network. In *AICS*, pages 353–364.
- Kumar, R. G., Kumaraswamy, Y., et al. (2012). Investigating cardiac arrhythmia in ecg using random forest classification. *Int. J. Comput. Appl.*, 37(4):31–34.
- Lannoy, G., François, D., Delbeke, J., and Michel, V. (2011). Weighted svms and feature relevance assessment in supervised heart beat classification. In Fred, A., Filipe, J., and Gamboa, H., editors, *Biomedical Engineering Systems and Technologies*, pages 212–223, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Li, H., Yuan, D., Ma, X., Cui, D., and Cao, L. (2017). Genetic algorithm for the optimization of features and neural networks in ecg signals classification. *Scientific Reports*, 7:2045–2322.
- Limam, M. and Precioso, F. (2017). Atrial fibrillation detection and ecg classification based on convolutional recurrent neural network. In *2017 Computing in Cardiology (CinC)*, pages 1–4. IEEE.

- Liu, J., Song, S., Sun, G., and Fu, Y. (2019). Classification of ecg arrhythmia using cnn, svm and lda. In *International Conference on Artificial Intelligence and Security*, pages 191–201. Springer.
- Loni, M., Sinaei, S., Zoljodi, A., Daneshtalab, M., and Sjödin, M. (2020). Deep-maker: A multi-objective optimization framework for deep neural networks in embedded systems. *Microprocessors and Microsystems*, 73:102989.
- Lugo-Reyes, S. O., Maldonado-Colón, G., and Murata, C. (2014). Inteligencia artificial para asistir el diagnóstico clínico en medicina. *Revista Alergia México*, 61(2):110–120.
- Ma, F., Zhang, J., Chen, W., Liang, W., and Yang, W. (2020). An automatic system for atrial fibrillation by using a cnn-lstm model. *Discrete Dynamics in Nature and Society*, 2020.
- Mathunjwa, B. M., Lin, Y.-T., Lin, C.-H., Abbod, M. F., and Shieh, J.-S. (2021). Ecg arrhythmia classification by using a recurrence plot and convolutional neural network. *Biomedical Signal Processing and Control*, 64:102262.
- Mondéjar-Guerra, V., Novo, J., Rouco, J., Penedo, M., and Ortega, M. (2019). Heartbeat classification fusing temporal and morphological information of ecgs via ensemble of classifiers. *Biomedical Signal Processing and Control*, 47:41–48.
- Moody, G. and Mark, R. (2001). The impact of the mit-bih arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3):45–50.
- Mostayed, A., Luo, J., Shu, X., and Wee, W. (2018). Classification of 12-lead ecg signals with bi-directional lstm network. *arXiv preprint arXiv:1811.02090*.
- Murat, F., Yildirim, O., Talo, M., Baloglu, U. B., Demir, Y., and Acharya, U. R. (2020). Application of deep learning techniques for heartbeats detection using ecg signals-analysis and review. *Computers in Biology and Medicine*, 120:103726.
- Navaneeth, B. and Suchetha, M. (2019). Pso optimized 1-d cnn-svm architecture for real-time detection and classification applications. *Computers in Biology and Medicine*, 108:85–92.
- Oowski, S., Hoai, L., and Markiewicz, T. (2004). Support vector machine-based expert system for reliable heartbeat recognition. *IEEE Transactions on Biomedical Engineering*, 51(4):582–589.
- Park, Y. and Yun, I. D. (2019). Arrhythmia detection in electrocardiogram based on recurrent neural network encoder-decoder with lyapunov exponent. *IEEE Transactions on Electrical and Electronic Engineering*, 14(8):1273–1274.
- Parveen, A., Vani, R. M., Hunagund, P. V., and Soher-wardy, M. A. (2021). Classification of ecg arrhythmia using different machine learning approach. In Gao, X.-Z., Kumar, R., Srivastava, S., and Soni, B. P., editors, *Applications of Artificial Intelligence in Engineering*, pages 319–325, Singapore. Springer Singapore.
- Picciali, F., Somma, V. D., Giampaolo, F., Cuomo, S., and Fortino, G. (2021). A survey on deep learning in medicine: Why, how and when? *Information Fusion*, 66:111–137.
- Polat, K., Akdemir, B., and Güneş, S. (2008). Computer aided diagnosis of ecg data on the least square support vector machine. *Digital Signal Processing*, 18(1):25–32.
- Rai, H. M. and Chatterjee, K. (2021). Hybrid cnn-lstm deep learning model and ensemble technique for automatic detection of myocardial infarction using big ecg data. *Applied Intelligence*, pages 1–19.
- Rajani Kumari, L., Padma Sai, Y., et al. (2021). Classification of arrhythmia beats using optimized k-nearest neighbor classifier. In *Intelligent Systems*, pages 349–359. Springer.
- Rajesh, K. N. and Dhuli, R. (2017). Classification of ecg heartbeats using non-linear decomposition methods and support vector machine. *Computers in Biology and Medicine*, 87:271–284.
- Rajesh, K. N. and Dhuli, R. (2018). Classification of imbalanced ecg beats using re-sampling techniques and adaboost ensemble classifier. *Biomedical Signal Processing and Control*, 41:242–254.
- Ramkumar, M., Babu, C. G., Kumar, K. V., Hepsiba, D., Manjunathan, A., and Kumar, R. S. (2021). ECG cardiac arrhythmias classification using DWT, ICA and MLP neural networks. *Journal of Physics: Conference Series*, 1831(1):012015.
- Rohmantri, R. and Surantha, N. (2020). Arrhythmia classification using 2d convolutional neural network. *Int. J. Adv. Comput. Sci. Appl*, 11:201–208.
- Rosas-Peralta, M., Palomo-Piñón, S., Borrayo-Sánchez, G., Madrid-Miller, A., Almeida-Gutiérrez, E., Galván-Oseguera, H., Magaña-Serrano, J. A., Saturno-Chiu, G., Ramírez-Arias, E., Santos-Martínez, E., et al. (2016). Consenso de hipertensión arterial sistémica en México. *Revista Médica del Instituto Mexicano del Seguro Social*, 54(S1):6–51.
- Saadatejad, S., Oveysi, M., and Hashemi, M. (2019). Lstm-based ecg classification for continuous monitoring on personal wearable devices. *IEEE journal of biomedical and health informatics*, 24(2):515–523.
- Salem, M., Taheri, S., and Yuan, J.-S. (2018). Ecg arrhythmia classification using transfer learning from 2-dimensional deep cnn features. In *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, pages 1–4. IEEE.
- Sánchez-Arias, A., Bobadilla-Serrano, M., and Dimas-Altamirano, B. (2016). Enfermedad cardiovascular: primera causa de morbilidad en un hospital de tercer nivel. In *Revista Mexicana de Cardiología*, pages 98–102.
- Savalia, S. and Emamian, V. (2018). Cardiac arrhythmia classification by multi-layer perceptron and convolution neural networks. *Bioengineering*, 5(2):35.
- Schwab, P., Scabba, G. C., Zhang, J., Delai, M., and Karlen, W. (2017). Beat by beat: Classifying cardiac arrhythmias with recurrent neural networks. In *2017 Computing in Cardiology (CinC)*, pages 1–4. IEEE.
- Şen, S. Y. and Özkurt, N. (2019). Ecg arrhythmia classification by using convolutional neural network and spectrogram. In *2019 Innovations in Intelligent Systems and Applications Conference (ASYU)*, pages 1–6. IEEE.
- Sharma, R. R., Kumar, M., and Pachori, R. B. (2019). Joint time-frequency domain-based cad disease sensing system using ecg signals. *IEEE Sensors Journal*, 19(10):3912–3920.
- Shi, H., Wang, H., Huang, Y., Zhao, L., Qin, C., and Liu, C. (2019). A hierarchical method based on weighted extreme gradient boosting in ecg heartbeat classification. *Computer Methods and Programs in Biomedicine*, 171:1–10.
- Shimpi, P., Shah, S., Shroff, M., and Godbole, A. (2017). A machine learning approach for the classification of cardiac arrhythmia. In *2017 international conference on computing methodologies and communication (ICCMC)*, pages 603–607. IEEE.
- Shiraishi, J., Li, Q., Appelbaum, D., and Doi, K. (2011). Computer-aided diagnosis and artificial intelligence in clinical imaging. *Seminars in Nuclear Medicine*, 41(6):449–462. Image Perception in Nuclear Medicine.
- Sigurthorsdottir, H., Van Zaen, J., Delgado-Gonzalo, R., and Lemay, M. (2020). Ecg classification with a convolutional recurrent neural network. In *2020 Computing in Cardiology*, pages 1–4. IEEE.
- Simanjuntak, J. E. S., Khodra, M. L., and Manullang, M. C. T. (2020). Design methods of detecting atrial fibrillation using the recurrent neural network algorithm on the arduino ad8232 ecg module. In *IOP Conference Series: Earth and Environmental Science*, volume 537, page 012022. IOP Publishing.
- Singh, S., Pandey, S. K., Pawar, U., and Janghel, R. R. (2018). Classification of ecg arrhythmia using recurrent neural networks. *Procedia computer science*, 132:1290–1297.
- Sraitih, M., Jabrane, Y., and Atlas, A. (2021). An overview on machine learning methods for ecg heartbeat arrhythmia classification. In *2021 International Conference on Digital Age Technological Advances for Sustainable Development (ICDATA)*, pages 8–14.
- Toulni, Y., Belhoussine Drissi, T., and Nsiri, B. (2021). Ecg signal diagnosis using discrete wavelet transform and k-nearest neighbor classifier. In *Proceedings of the 4th International Conference on Networking, Information Systems & Security*, pages 1–6.
- Triqui, B. and Benyettou, A. (2018). Cardiac arrhythmia classification by neuronal networks (mlp). *The Online Journal of Science and Technology-January*, 8(1).
- UNAM (2020). Enfermedades del corazón, pandemia permanente.
- Valupadasu, R. and Chunduri, B. R. R. (2019). Automatic classification of cardiac disorders using mlp algorithm. In *2019 Prognostics and System Health Management Conference (PHM-Paris)*, pages 253–257. IEEE.
- Van Zaen, J., Chételat, O., Lemay, M., Calvo, E. M., and Delgado-Gonzalo, R. (2019). Classification of cardiac arrhythmias from single lead ecg with a convolutional recurrent neural network. *arXiv preprint arXiv:1907.01513*.
- Wang, H., Shi, H., Lin, K., Qin, C., Zhao, L., Huang, Y., and Liu, C. (2020). A high-precision arrhythmia classification method based on dual fully connected neural network. *Biomedical Signal Processing and Control*, 58:101874.
- Wang, J. (2021). An intelligent computer-aided approach for atrial fibrillation and atrial flutter signals classification using modified bidirectional lstm network. *Information Sciences*, 574:320–332.
- WHO (2019). Cardiovascular diseases (cvs).
- Ye, C., Vijaya Kumar, B. V. K., and Coimbra, M. T. (2012). Heartbeat classification using morphological and dynamic features of ecg signals. *IEEE Transactions on Biomedical Engineering*, 59(10):2930–2941.
- Yildirim, O., Baloglu, U. B., Tan, R.-S., Ciaccio, E. J., and Acharya, U. R. (2019). A new approach for arrhythmia classification using deep coded features and lstm networks. *Computer methods and programs in biomedicine*, 176:121–133.
- Yildirim, Ö., Pławiak, P., Tan, R.-S., and Acharya, U. R. (2018). Arrhythmia detection using deep convolutional neural network with long duration ecg signals. *Computers in biology and medicine*, 102:411–420.

- Zabihi, M., Rad, A. B., Katsaggelos, A. K., Kiranyaz, S., Narkilahti, S., and Gabbouj, M. (2017). Detection of atrial fibrillation in ecg hand-held devices using a random forest classifier. In *2017 Computing in Cardiology (CinC)*, pages 1–4. IEEE.
- Zhang, D., Chen, Y., Chen, Y., Ye, S., Cai, W., and Chen, M. (2021). An ecg heartbeat classification method based on deep convolutional neural network. *Journal of Healthcare Engineering*, 2021.
- Zhang, Z., Dong, J., Luo, X., Choi, K.-S., and Wu, X. (2014). Heartbeat classification using disease-specific feature selection. *Computers in Biology and Medicine*, 46:79–89.
- Zihlmann, M., Perekrestenko, D., and Tschannen, M. (2017). Convolutional recurrent neural networks for electrocardiogram classification. In *2017 Computing in Cardiology (CinC)*, pages 1–4. IEEE.