



## Multclasificación de arritmias cardíacas usando una red neuronal y la tarjeta *MyRio-1900*

Marco Flores-Calero <sup>[1,2,A]</sup>, Bruno Leppe <sup>[1]</sup>, Melisa Pilla <sup>[1]</sup>, Marco Gualsaquí <sup>[2]</sup>, David Zabala-Blanco <sup>[3]</sup>, Alberto Albuja <sup>[2]</sup>

<sup>[1]</sup> Departamento de Sistemas Inteligentes, I&H Tech, Latacunga (Cotopaxi), Ecuador

<sup>[2]</sup> Universidad de las Fuerzas Armadas-ESPE, Av. Gral. Rumiñahui, s/n, PBX 171-5-231B, Sangolquí (Pichincha), Ecuador

<sup>[A]</sup> Autor de correspondencia: [mjflores@espe.edu.ec](mailto:mjflores@espe.edu.ec)

<sup>[3]</sup> Departamento de Computación e Industrias, Facultad de Ciencias de la Ingeniería, Universidad Católica del Maule, Talca 3480112, Chile  
[dzabala@ucm.cl](mailto:dzabala@ucm.cl)

**Abstract** Cardiovascular diseases (CVD), and particularly cardiac arrhythmias, have become one of the main causes of death in the world, regardless of the level of development of the countries. The detection of cardiac arrhythmias on the electrocardiogram (ECG) is a laborious task for physicians, due to the large amount of information that must be analyzed, which could lead to inadvertent errors in diagnosis. For this reason, this work presents an automatic system for the classification/detection of cardiac arrhythmias. To extract the vector of characteristics of the heartbeats, a set of linear and non-linear techniques has been used to generate thirty-three characteristics, which are used from the input of an artificial neural network (ANN) for the classification of seven types of heartbeats. The experimental results, developed on the ECG signals from the MIT-BIH database, ordered according to the AAMI standard, demonstrate a Cohen's Kappa index value of 0,9953, with an error of 0,04 %, show an accuracy of 99,48 %, even under noisy conditions. Later, this system has been implemented in hardware using the MyRio-1900 card. which is composed of a Xilinx FPGA Z-7010.

**Resumen** Las enfermedades cardiovasculares (ECV) y en particular las arritmias cardíacas, se han convertido en una de las principales causas de muerte en el mundo, sin importar el nivel de desarrollo de los países. La detección de arritmias cardíacas sobre el electrocardiograma (ECG), es una tarea difícil para los médicos, debido a la gran cantidad de información que se debe analizar, lo que podría inducir a cometer errores involuntarios en el diagnóstico. Por este motivo, en este trabajo se presenta un sistema automático de clasificación/detección de arritmias cardíacas. Para extraer las características de los latidos se ha utilizado un conjunto de técnicas lineales y no lineales para generar treinta y tres características, que son usadas como entrada de una red neuronal artificial (ANN, en inglés) para la clasificación de siete tipos de latidos. Los resultados experimentales desarrollados sobre las señales ECG de la base de datos MIT-BIH y ordenadas de acuerdo al estándar AAMI, demuestran un valor del índice Kappa de Cohen de 0,9953, con un error del 0,04 %, y una exactitud del 99,48 %, aún en condiciones de ruido. Con el objetivo de construir un aparato portátil se ha implementado este sistema en hardware usando la tarjeta *MyRio-1900*, compuesta por un Xilinx FPGA Z-7010.

**Keywords:** Arrhythmia, ECG, PCA, fast-ICA, EMD, ANN, MyRio, FPGA.

**Palabras Clave:** Arritmia cardíaca, ECG, PCA, fast-ICA, EMD, ANN, MyRio, FPGA.

## 1. Introducción

Las enfermedades cardiovasculares (ECV) son una de las principales causas de muerte en el mundo, tanto en países en desarrollo como en vías de serlo. Según la Organización Mundial de la Salud [34], el 31 % de todas las muertes registradas en el mundo se deben a enfermedades cardiovasculares. Las arritmias cardíacas están presentes en un 6 % de las defunciones. Además se calcula que el 15 % de personas mayores de 50 años, padecen algún tipo de arritmia cardíaca a lo largo de su vida [11]. Al momento de redactar este documento, varias investigaciones presentan evidencias de que el Covid-19 puede estar asociado negativamente con varios tipos de arritmias cardíacas y por ende agravar la salud del paciente [22, 14].

En el caso específico de Ecuador, según el Instituto Nacional de Estadísticas y Censos (INEC), en el año 2016 se registraron 6513 muertes a causa de enfermedades isquémicas del corazón, las cuales son las principales causas de mortalidad general con un porcentaje de 9,65 %. Los fallecimientos por insuficiencia cardíaca fueron de 963 personas, en el mismo año [12]. En otro caso esta Chile, donde las enfermedades relacionadas con el sistema circulatorio (patologías del corazón) estuvieron entre las principales causas de muerte, con 139953 fallecidos, en el período 2016 a 2020 [9].

Por otra parte, gracias al desarrollo de la electrónica, se ha logrado construir aparatos que permiten medir y almacenar las señales de la actividad eléctrica del corazón, denominadas ECG [4, 11]. Además, debido a los avances de las técnicas de procesamiento digital de señales y aprendizaje máquina, existen diversos métodos automáticos para analizar las señales ECG y determinar algunas patologías cardíacas sin la supervisión directa de un médico especializado [26]. Sin embargo, el principal problema para diagnosticar enfermedades del corazón usando esta tecnología surge en la misma señal, porque ésta puede variar de persona a persona, y a menudo diferentes pacientes tienen distintas morfologías del ECG para la misma enfermedad, lo que puede inducir a errores de diagnóstico y pone de manifiesto la fragilidad que aún presentan estas tecnologías.

En el presente trabajo, el principal objetivo es construir un método eficiente para la clasificación de arritmias cardíacas definidas por el estándar AMMI [19], utilizando un conjunto de señales provenientes de la base de datos pública del MIT-BIH de Physionet [13]. El método presentado inicia con un preprocesamiento, que consta de un filtrado de las señales ECG usando análisis de componentes principales (PCA, en inglés). Luego se aplica un método de segmentación para obtener los latidos individuales. Inmediatamente, se obtienen treinta y tres características usando componentes independientes (fast-ICA, en inglés), análisis de modo empírico (EMD, en inglés), medidas estadísticas estándar (media, varianza, curtosis y asimetría) y los intervalos RR. El intervalo RR es el tiempo entre el pico R de un latido, con respecto al pico R del latido contiguo. Finalmente, para realizar la clasificación de los latidos se utiliza una red neuronal artificial. Los resultados de esta clasificación muestran valores promedios de exactitud de 99,48 %, sensibilidad de 94,71 %, especificidad de 99,67 % y precisión de 93,52 %; además de un índice Kappa de Cohen de 0,9953, con un error del 0,04 %.

Este documento está organizado de la siguiente manera. La primera sección corresponde a la motivación que ha dado origen a esta investigación. La siguiente sección presenta la descripción del ECG y los tipos de arritmias, las bases de datos, los trabajos previos y los métodos utilizados. A continuación, el apartado tres describe un nuevo algoritmo para clasificar los latidos usando características lineales y no lineales y una ANN. Seguidamente, la siguiente sección exhiben los resultados experimentales. En el apartado cuatro se explica la implementación en hardware usando la tarjeta *MyRio-1900*. Finalmente, la última parte esta dedicada a las conclusiones y los trabajos futuros.

## 2. Materiales y métodos

### 2.1. Electrocardiograma

El ECG es un registro de la actividad eléctrica generada por el corazón, a través, de señales que varían en el tiempo y que son desplegadas en una pantalla. El ECG ha demostrado ser una herramienta efectiva que no invade el cuerpo del paciente, por lo que es ampliamente utilizado en varias aplicaciones biomédicas [4], entre las más importantes que se pueden citar están: el diagnóstico de patologías cardíacas [8, 16], el reconocimiento de emociones [6] y la identificación biométrica [29].

El ECG está formado por varias secciones denominadas latidos. A la vez, un latido se encuentra compuesto por una onda P, un complejo QRS, una onda T y una onda U. Estos se producen en un orden concreto, durante períodos definidos de tiempo y con tamaños relativos propios, formando un patrón, en cada ciclo cardíaco [4]. La figura 1 muestra el gráfico de un latido con sus respectivos componentes.

Al momento de captar los registros ECG ingresan elementos no deseados que constituyen ruido, y que distorsiona la calidad de la señal. Entre los más comunes están el ruido producido por los movimientos musculares, el ruido de contacto de los electrodos, y el ruido producto de la interferencia eléctrica. Para reducir estas interferencias es necesario una etapa de preprocesamiento para limpiar la señal y dejarla preparada para las etapas

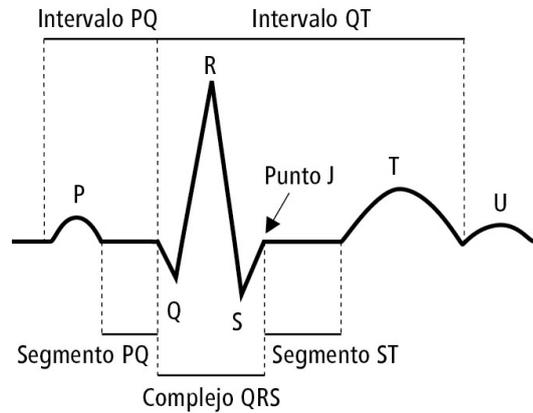


Figura 1: Latido típico compuesto por la onda P, el complejo QRS, la onda T y la onda U. El eje horizontal representa el tiempo y el eje vertical es la magnitud del latido.

posteriores [1, 4, 25].

## 2.2. Arritmias cardíacas y su tipología

Los ritmos cardíacos anormales se denominan arritmias, estos pueden ocurrir en las cámaras superiores e inferiores del corazón, y se producen debido a cambios en la secuencia normal de los impulsos eléctricos del corazón.

Dicho de otra manera, las arritmias cardíacas son un conjunto de trastornos del corazón que se producen debido a los cambios en la secuencia normal de los impulsos eléctricos del corazón; caracterizadas por latidos demasiado rápidos (taquicardia), demasiado lentos (bradicardia) o irregulares [34]; es decir, las arritmias cardíacas denotan discontinuidad en la propagación de los impulsos eléctricos.

Las principales arritmias cardíacas, definidos en el estándar AMMI [19], son las Normales (N), las prematuras auriculares (APC), las prematuras ventriculares (PVC), las de fusión (F) y las no clasificados. Además, estas se pueden subdividir en otras, como se verá más adelante.

## 2.3. Descripción de la base de datos de las señales ECG

En este trabajo se utiliza la base de datos de señales ECG denominada MIT-BIH [13, 23, 25], la cual está formada por 48 registros (23 normales y 25 con arritmias) de dos canales, con una duración de 30 minutos, obtenidos a 47 personas. Las señales han sido capturadas a una tasa de 360 muestras por segundo, con 11 bits de resolución, en un rango de amplitud de 10 mili-voltios.

Esta base de datos proporciona datos clínicos generados por especialistas en cardiología, y presenta información descriptiva de las arritmias, la posición del pico de la onda R y los intervalos RR de los latidos.

Los distintos tipos de arritmias cardíacas, que se encuentran en la base de datos MIT-BIH [13], se reagruparon en siete casos usando la categorización del estándar AAMI [19]. De manera que la tabla 1 muestra la notación que se utiliza en este trabajo.

En AAMI la clase Normal engloba a tres tipos de latidos de MIT-BIH, que son Normales, RBBB y LBBB.

La figura 2 muestra un ejemplo de cada uno de los casos de latidos de arritmias, de acuerdo a la organización y notación de la tabla 1.

## 2.4. Base de datos de los latidos

A partir de señales ECG de la base MIT-BIH se obtienen los latidos. Para este fin se ha utilizado el método desarrollado por Elgendi et al. [10], al amparo de este procedimiento se llega a obtener la información de la tabla 2, donde se presenta el número de latidos por cada tipo de arritmia, junto con su porcentaje de contribución al total, que son 49652 latidos, distribuidos de acuerdo a la organización exhibida en la tabla 1.

Tabla 1: Notación de los latidos por tipo de arritmia cardíaca, según AAMI [19] y MIT-BIH [13].

AAMI	MIT-BIH DB	Notación
Normal	Normales	N
Normal	RBBB (Latido bloque de rama derecha)	R
Normal	LBBB (Latido bloque de rama izquierda)	L
Ectópicos prematuros auriculares	APC	A
Ectópicos ventriculares	PVC	V
Latidos fusionados	Fusión	F
No clasificados	Marcapasos	P

Tabla 2: Número de latidos por cada tipo de arritmia cardíaca y su respectivo porcentaje. Los datos provienen de MIT-BIH [13].

Tipo	Notación	Latidos	Peso (%)
Normales	N	28273	56.9
RBBB	R	6740	13.6
LBBB	L	5048	10.2
APC	A	2075	4.2
PVC	V	3223	6.5
Fusión	F	765	1.5
Marcapasos	P	3528	7.1
<b>Total</b>	–	49652	100.0

## 2.5. Trabajos previos en la detección de arritmias cardíacas

En los últimos años diferentes algoritmos de aprendizaje automático han sido diseñados para identificar los diferentes tipos de arritmias. Durante este tiempo se ha formado dos tendencias; una que usa técnicas tradicionales, comprendidas como generación del vector de características y elección del algoritmo de clasificación, y otra basado en aprendizaje profundo, donde se hace uso de redes neuronales altamente complejas [4, 8, 16, 18, 26].

Entre los métodos tradicionales, la mayoría de los trabajos han utilizado máquinas de vectores de soporte (SVM) [25, 26], redes neuronales artificiales (ANN) [15], máquinas de aprendizaje extremo (ELM) [37], árboles de decisión [35], bosques aleatorios (RF) [3, 35] para el clasificador. Inmediatamente, para generar el vector de características se han usado varias técnicas de procesamiento digital de señales tales como STFT [18], transformada wavelet [15, 36, 35], fast-ICA [38] o una combinación de ellas [27, 35].

La metodología de aprendizaje profundo está siendo utilizada para identificar diferentes clases de arritmias, sin la necesidad de intervenir en la construcción del espacio de características a partir del ECG. Los principales modelos que han sido utilizados son redes neuronales densas (DNN), redes neuronales convolucionales (CNN) [18, 20, 26] con resultados altamente competitivos.

A la vez existe una tendencia que consiste en combinar las dos metodologías, por ejemplo, usar CNN junto con SVM [26] para perfeccionar la extracción de características y la clasificación, y en conjunto, mejorar los resultados.

Desafortunadamente, las técnicas de aprendizaje profundo aún no pueden ser implementadas masivamente debido al equipo computacional especializado que requieren para su óptimo funcionamiento, como es el caso de las GPU.

## 2.6. Redes neuronales artificiales

Una red neuronal artificial es un paradigma informático inspirado en la computación biológica del cerebro. Asimismo es parte de los algoritmos de aprendizaje supervisado dedicados a la clasificación y regresión [1]. Se compone de elementos de procesamiento (neuronas) que trabajan al unísono para resolver un problema específico. La disposición topológica más sencilla de neuronas es el Perceptrón Multicapa (MLP), donde las neuronas se organizan en una estructura formada por una capa de entrada, varias capas ocultas y una capa de salida. El

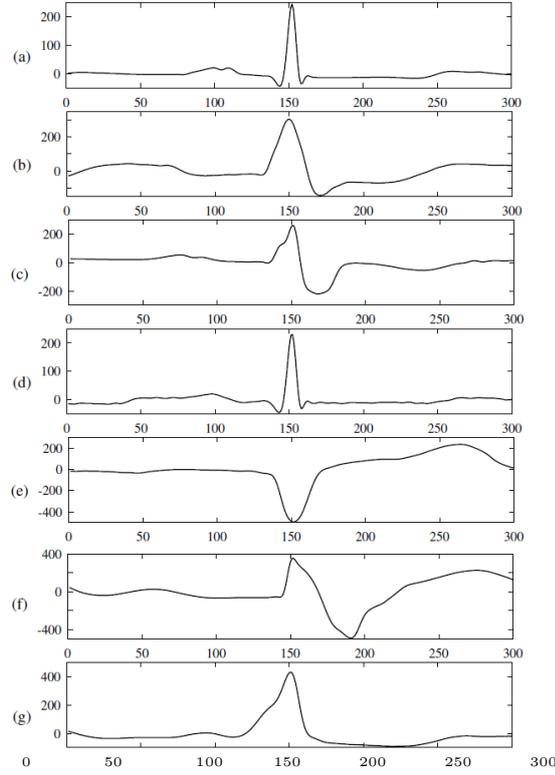


Figura 2: Morfología de los latidos bajo distintos tipos de arritmias cardíacas: (a) Latido normal, (b) LBBB, (c) RBB, (d) APC, (e) PVC, (f) Latido de marcapasos, (g) Fusión. En todos los casos, el eje horizontal representa el tiempo y el eje vertical es la magnitud, medida en voltios.

número de neuronas de la capa de entrada y la capa de salida es igual en tamaño al vector de características de entrada y vector objetivo, respectivamente. El número de capas y de neuronas, de la capa oculta, son parámetros a escoger en la red. Cada neurona en una capa  $L$  es conectada en la capa  $L + 1$  en una manera anticipada, dando algunos pesos para cada conexión como una matriz de pesos  $w_{ij}$ . La ecuación (1) es una representación matemática para la salida generada de una neurona  $y_j$  de cualquier capa.

$$\mathbf{y}_j = f \left( \sum_{i=1}^n w_{ij} \mathbf{x}_i + b_j \right) \quad (1)$$

donde  $\mathbf{x}_i$ ,  $w_{ij}$ , y  $b_j$  son las salidas de la capa previa de pesos de conexión entre las neuronas  $i$  y  $j$  y un sesgo aplicado a la neurona  $j$  respectivamente,  $f(\cdot)$  representa una función de activación no-lineal para introducir una no-linealidad en la representación de los datos, y  $n$  es el número de neuronas. Las funciones de activación más importantes son la sigmoide, tangente hiperbólica y ReLU [26].

## 2.7. Análisis de componentes principales

PCA [30, 27] se basa en el supuesto de que la señal  $\mathbf{x}$ , es un proceso aleatorio de media cero, siendo caracterizado por la matriz de correlación  $R_{\mathbf{x}\mathbf{x}} = E[\mathbf{x}\mathbf{x}^T]$ . Los componentes principales de  $\mathbf{x}$  resultan de la aplicación de una transformación lineal ortonormal  $\Psi = [\Psi_1 \Psi_2 \dots \Psi_q]$  a  $\mathbf{x}$  dada por  $\mathbf{w} = \Psi^T \mathbf{x}$ . Entonces, el vector de componentes principales  $\mathbf{w} = [w_1 w_2 \dots w_q]^T$  llega a ser mutuamente no correlacionado. El principal componente se obtiene como un producto escalar dado por  $w_1 = \Psi_1^T \mathbf{x}$ , donde el vector  $\Psi_1$  es escogido de manera que la varianza de  $w_1$  es dada por:

$$E[\mathbf{w}_1^2] = E[\Psi_1^T \mathbf{x} \cdot \mathbf{x}^T \Psi_1] = \Psi_1^T \mathbf{R}_{\mathbf{X}\mathbf{X}} \Psi_1 \quad (2)$$

Este valor es maximizado sujeto a la restricción  $\Psi_1^T \Psi_1 = \mathbf{I}$ . La máxima varianza es obtenida cuando  $\Psi_1$  es el vector propio normalizado correspondiente al valor propio más grande de  $\mathbf{R}_{\mathbf{X}}$  denotado por  $\lambda_1$ . Entonces, la varianza resultante es dada por  $E[w_1^2] = \lambda_1 \Psi_1^T \Psi_1 = \lambda_1$ .

En la mayoría de las aplicaciones, el objetivo de PCA es concentrar la información de  $\mathbf{x}$  dentro de un subconjunto de  $k$  componentes, esto es  $[w_1, \dots, w_q]$  donde  $k < q$ . Para eliminar el ruido, partimos de la matriz de vectores propios  $\mathbf{W}_{qq}$  y los valores propios  $\lambda_{q1}$ . Si  $\mathbf{B}_{qk}$  es un sub-conjunto de  $\mathbf{W}$ ,  $\mathbf{Y}_{pk}$  será la matriz de vectores de componentes principales dado por:

$$\mathbf{y}_{pk} = [\mathbf{x}_{pq} - 1_p \cdot \bar{\mathbf{x}}_{1q}] \mathbf{B}_{qk} \quad (3)$$

Por tanto, la señal reconstruida viene dada por:

$$\hat{\mathbf{x}}_{pq} = \mathbf{y}_{pk} \cdot \mathbf{B}_{qk}^T + 1_p \cdot \bar{\mathbf{x}}_{1q} \quad (4)$$

## 2.8. Análisis de componentes independientes

ICA es un método estadístico de orden superior que busca proyecciones lineales, no necesariamente ortogonales entre ellas, que sean estadísticamente independientes. La independencia estadística es una condición mucho más fuerte que la no-correlación. Mientras que la última involucra estadísticas de segundo orden, la primera depende completamente de estadística de orden superior.

Sea  $\{y_i : i = 1, \dots, q\}$  un conjunto de variables aleatorias con función de densidad de probabilidades conjunta  $p(y_1, \dots, y_q)$ . Suponiendo que  $E\{y_i\} = 0$ , se dice que las variables  $y_i$  son mutua y estadísticamente independientes si:

$$p(y_1, \dots, y_q) = \prod_{i=1}^q p_i(y_i) \quad (5)$$

donde  $p_i(y_i)$  es la densidad marginal de  $y_i$ . Por otro lado, se dice que dos variables aleatorias son no correlacionadas si:

$$E\{y_i y_j\} = E\{y_i\} E\{y_j\} = 0, \text{ para } i \neq j \quad (6)$$

El modelo ICA libre de ruido para el vector aleatorio  $\mathbf{x}$  (señal a analizar)  $p$ -dimensional busca estimar los componentes del vector  $q$ -dimensional  $\mathbf{y}$  con la matriz de mezcla con rango completo  $w_{p \times q}$  con:

$$\mathbf{y} = w_{p \times q} \cdot \mathbf{x} \quad (7)$$

donde  $\mathbf{y}$  es el vector de componentes independientes,  $w_{p \times q}$  es una matriz que permite que los componentes de  $\mathbf{y}$  sean estadísticamente independientes.

Por otra parte, fast-ICA [27, 30, 38], es un algoritmo iterativo de punto-fijo donde se minimiza la información mutua entre los componentes estimados. La separación de componentes independientes se logra cuando se obtiene el máximo de no-gaussianidad. Antes de usar fast-ICA, la señal observada  $\mathbf{x}$  es centrada y blanqueada, es decir, se elimina la media de la señal. Para el blanqueo se usa PCA de manera que los componentes no estén correlacionados entre sí.

El propósito de fast-ICA, basado en una estructura iterativa de punto-fijo, es hacer que  $y = w^T x$  tengan el máximo de no-gaussianidad. La función objetivo es fijada como:

$$J(y) \approx \{E[G(y)] - E[G(\vartheta)]\}^2 \quad (8)$$

donde  $E[\cdot]$  es el operador de la esperanza y  $\vartheta$  es la variable aleatoria gaussiana con media cero y varianza unitaria. Se asume que  $y$  tiene media cero y varianza unitaria.  $G(\cdot)$  es una función no cuadrática.

De acuerdo a la condición de Kuhn-Tucker, la optimización de  $E\{G(w^T x)\}$  podría ser obtenida por (8) bajo la restricción de  $E\{w^T x\}^2 = \|w\|^2 = 1$ :

$$E\{x g(w^T x)\} - \beta w = 0 \quad (9)$$

donde  $\beta$  es una constante que puede ser obtenida por la siguiente expresión  $\beta = E\{w_o^T x g(w_o^T x)\}$ , con  $w_o$  el valor inicial de  $w$  y  $g(\cdot)$  es una función no lineal, que es la derivada de  $G(\cdot)$ . En este caso, se escoge como función no lineal  $g(y) = y^3$ . Para resolver (8) se usa el método iterativo de Newton. La parte izquierda de (8) denotada como  $F(w)$  y la matriz Jacobiana  $JF(w)$  es:

$$JF(w) = E\{x x^T g'(w^T x)\} - \beta I \quad (10)$$

De manera de simplificar los cálculos computacionales de la inversa de la matriz (9) debido al blanqueamiento que se realiza se aproxima como:

$$E\{x x^T g'(w^T x)\} \approx E\{x x^T\} E\{g'(w^T x)\} = E\{g'(w^T x)\} I \quad (11)$$

La matriz Jacobiana es una matriz diagonal y su matriz inversa puede ser simplificada de manera similar, se reemplaza el valor de  $w_0$  con el valor presente de  $w$  por la constante  $\beta$ . Por tanto, se podría obtener la fórmula aproximada iterativa de Newton de la siguiente manera:

$$w_{k+1} = w_k - \frac{[E\{xg(w_k^T x)\} - \beta w_k]}{[E\{g'(w_k^T x)\} - \beta]} \quad (12)$$

donde  $\beta = E\{w^T xg(w^T x)\}$  y  $w_{k+1}$  representa el valor actualizado de  $w_k$ . Para mejorar la estabilidad del algoritmo,  $w$  fue normalizada por  $W_{k+1} = w_{k+1}/\|w_{k+1}\|$  después de la iteración. Para simplificar (12), se obtiene la fórmula iterativa simplificada del algoritmo fast-ICA que esta dada por:

$$w_{k+1} = E\{xg(w^T x)\} - E\{g'(w^T x)\}w_k \quad (13)$$

## 2.9. Descomposición del modo empírico

El punto de partida de EMD [23, 24] es el considerar a las señales desde el nivel de sus oscilaciones. Mirando la evolución de una señal  $\mathbf{x}(t)$  entre dos extremos locales consecutivos (por ejemplo, dos mínimos que ocurren en  $t_1, t_2$ ), podemos definir heurísticamente una parte de alta frecuencia (local)  $d(t)$ ,  $t_1 \leq t \leq t_2$ , también llamado detalle, corresponde a la oscilación que termina en los dos mínimos y pasando por el máximo que necesariamente existe entre ellos. Para que el proceso sea completo se identifica parte de la baja frecuencia correspondiente a  $m(t)$ , o tendencia local, para que tener  $\mathbf{x}(t) = m(t) + d(t)$  con  $t_1 \leq t \leq t_2$ .

Asumiendo que esto se hace de manera adecuada para todas las oscilaciones que componen la señal completa, se obtiene lo que se conoce como un función de modo intrínseco (IMF), así como un residual que consta de todas las tendencias locales. A continuación, el procedimiento se puede aplicar a este residuo, considerado como una nueva señal a descomponer, y los componentes constitutivos sucesivos de una señal pueden extraerse iterativamente, la única definición de tal componente extraído siendo que es localmente (es decir, en la escala de una sola oscilación) en la banda de frecuencia más alta.

Dada una señal  $\mathbf{x}(t)$ , el algoritmo EMD puede ser resumido como sigue:

- Identificar todos los extremos de  $\mathbf{x}(t) = m(t) + d(t)$ .
- Interpolarse entre mínimos (resp. máximos), terminando con una envolvente,  $e_{min}(t)$  (resp.  $e_{max}(t)$ ).
- Calcular en promedio  $m(t) = (e_{min}(t) + e_{max}(t))/2$ .
- Extraer el detalle  $d(t) = x(t) - m(t)$ .
- Iterar sobre el residuo.

## 2.10. Métricas de evaluación

Para validar el proceso de clasificación se utiliza un conjunto de métricas de la matriz de confusión, como son: exactitud (EXA), precisión (PRE), especificidad (ESP) y sensibilidad (SEN).

La matriz de confusión es una tabla bidimensional que relaciona las salidas del clasificador (predicciones) y los valores verdaderos. La información más importante es el número de casos clasificados correcta e incorrectamente.

A partir de esta tabla se derivan las métricas que se anotan a continuación:

- Índice Kappa de Cohen: Es un índice estadístico que se utiliza para medir la concordancia observada en un conjunto de datos, respecto a lo que podría ocurrir por mero azar. La proporción de concordancia que se esperaría por mero azar es:

$$\kappa = \frac{p_0 - p_e}{1 - p_e} \quad (14)$$

donde  $p_0$  es el acuerdo relativo observado entre los clasificadores y  $p_e$  es la probabilidad hipotética de acuerdo al azar. Un valor superior a 0,81 indica un excelente clasificador.

- Exactitud: La exactitud mide la proporción de todas las predicciones acertadas del clasificador en relación a las predicciones totales.

$$EXA = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

- Precisión: La precisión mide la proporción de todas las predicciones positivas que sí pertenecen a la clase positiva.

$$PRE = \frac{TP}{TP + FP} \quad (16)$$

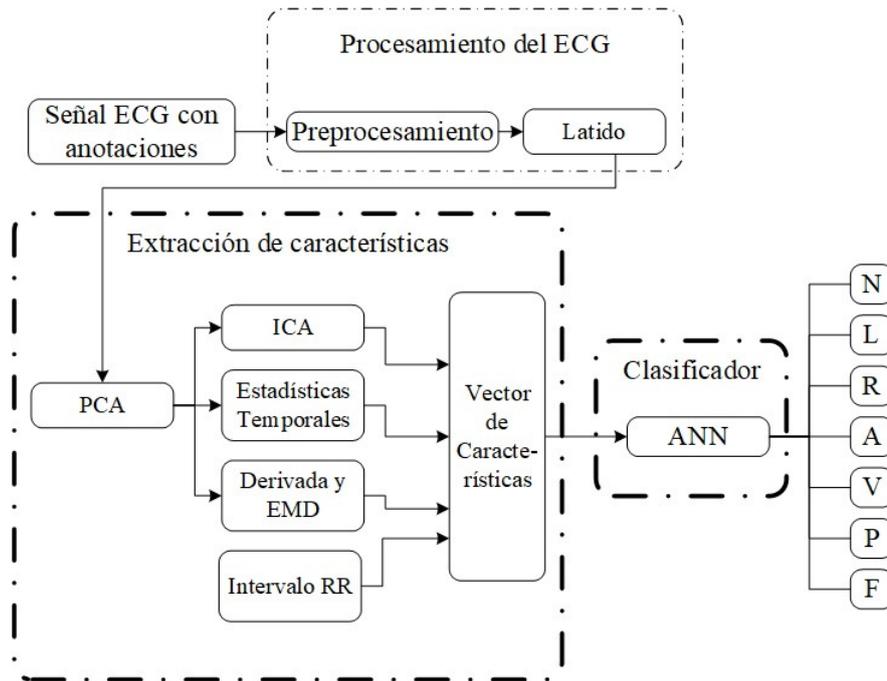


Figura 3: Diagrama general del sistema de clasificación de arritmias cardíacas sobre MIT-BIH.

- Sensitividad: La sensibilidad o recall mide la proporción entre el total de elementos que pertenecen a la clase positiva y la cantidad de predicciones positivas que sí pertenecen a la clase positiva.

$$SEN = \frac{TP}{TP + FN} \quad (17)$$

- Especificidad: La especificidad mide la proporción entre el total de elementos que pertenecen a la clase negativa y la cantidad de predicciones negativas que sí pertenecen a la clase negativa.

$$ESP = \frac{TN}{TN + FP} \quad (18)$$

En todos los casos, TP es verdadero positivo, TN es verdadero negativo, FP es falso positivo y FN es falso negativo.

### 3. Diseño del sistema de clasificación de arritmias cardíacas

En la figura 3 se muestra el diagrama general propuesto para la clasificación de los latidos, donde se observa que el algoritmo consta de tres bloques.

- El primero corresponde al preprocesamiento de las señales ECG, donde se aplican diferentes métodos de filtrado para eliminar los distintos tipos de ruidos. Luego viene el proceso de segmentación para obtener los latidos individuales.
- El segundo bloque corresponde a la extracción de características, donde se obtienen treinta y tres características, de las cuales veinte provienen de la aplicación ICA, las siguientes seis se obtienen aplicando EMD a la derivada de los latidos, posteriormente se obtienen cuatro características de medidas estadísticas; y por último tres características provenientes del intervalo entre latidos RR.
- En el último bloque se encuentra el clasificador ANN.

En las siguientes secciones se explicarán cada una de las etapas en detalle.

### 3.1. Preprocesamiento de la señal ECG

En esta etapa, con el fin de eliminar el ruido contenido en la señal ECG, se incluye un proceso de filtrado. Para eliminar la línea base y el ruido de la red eléctrica de 60Hz se utiliza el filtro de Butterworth tipo pasa banda, con frecuencias de corte entre 0.5Hz y 45Hz [5].

Una vez que la señal ha sido filtrada inicia el proceso de segmentación en donde se extraen los latidos individuales de la señal ECG, para lo cual se utiliza el algoritmo propuesto en [10], que permite obtener los puntos de referencia de inicio y fin, de las ondas P y T. Ulteriormente, a partir de estas etiquetas de referencia se segmentan los latidos de las grabaciones de señales ECG de MIT-BIH [13].

En general, los latidos tienen distinto tamaño, respecto al número de muestras que contienen; por lo tanto, usando un proceso de remuestreo se estandariza su tamaño a 300 muestras. El objetivo del remuestreo es mantener la información morfológica de la señal original. La función de remuestreo permite convertir una señal muestreada de manera no uniforme a una nueva señal muestreada uniformemente [33] y de igual tamaño. En la figura 4 se presenta un ejemplo de un latido que ha pasado por este proceso.

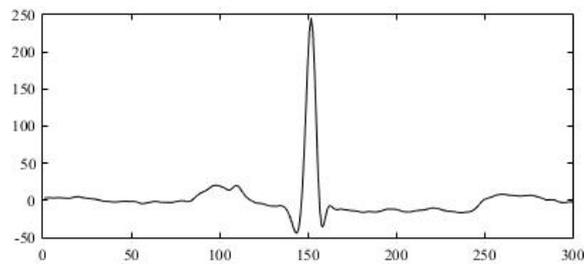


Figura 4: Latido generado después del proceso de muestreo.

Luego se usa PCA para eliminar el ruido remanente producto del remuestreo. Experimentalmente se ha verificado que las primeras 20 componentes principales retienen el 70% de la información útil de los latidos, descritas en la ecuación (3), a partir de la componente 21 se tiene ruido. Un ejemplo del ruido se muestra en la figura 5 (b).

Inmediatamente, aplicando la ecuación (4) se reconstruye cada latido usando las componentes principales elegidas, y se obtienen los latidos filtrados, un caso se muestra en la figura 5 (a), el latido proviene de la figura 4.

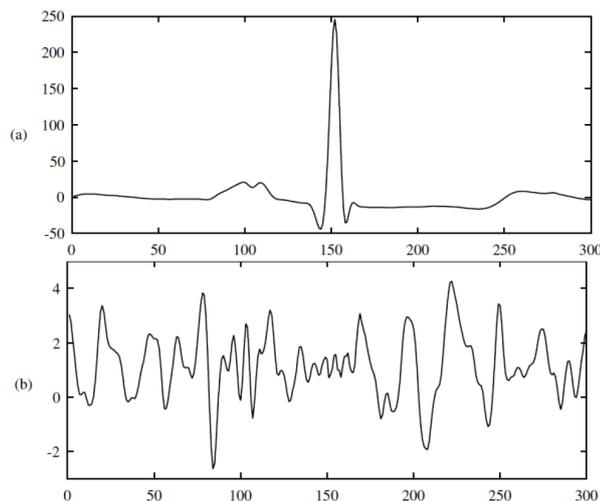


Figura 5: (a) Latido filtrado con PCA tomando las primeras 20 componentes principales, después del muestreo. (b) Componente principal 21 que representa el ruido del latido. En todos los casos, el eje horizontal corresponde al tiempo y el eje vertical está en voltios.

### 3.2. Extracción de características lineales y no lineales de los latidos

En esta etapa se extraen las características de los latidos, donde se genera un vector de dimensión treinta y tres, formado por características lineales y no-lineales, proporcionando información sobre la condición del latido. Las técnicas usadas son las siguientes:

- En esta etapa se aplica el algoritmo fastICA para hallar veinte componentes independientes del ECG. El algoritmo emplea el método de estimación de máxima verosimilitud y busca parámetros que maximizan la densidad de probabilidad de las observaciones. Los componentes independientes de los latidos se pueden ver en la figura 6. Cada componente independiente es una fuente de información y sumadas con ciertos pesos dan como resultado cualquier tipo de latido.

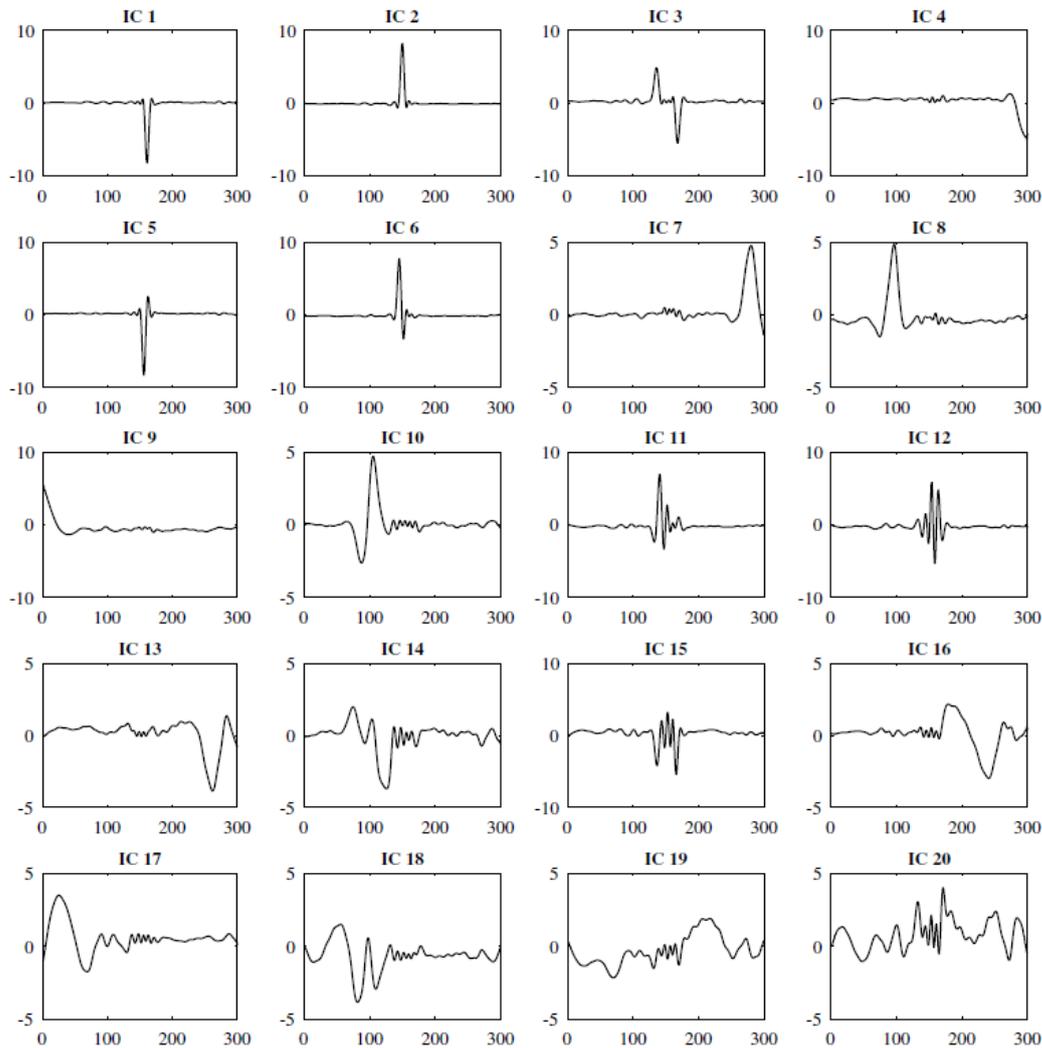


Figura 6: Componentes independientes de un conjunto de latidos normales calculados con Fast-ICA. En todos los casos, el eje horizontal representa el tiempo y el eje vertical está en voltios.

- En este caso, se implementa EMD sobre la derivada a un latido, lo que provee información de la pendiente y del complejo QRS, para obtener seis funciones de modo intrínseco IMFs, que son funciones base de la derivada del ECG. Un arquetipo de las IMFs de este proceso se muestran en la figura 7.
- Las principales medidas estadísticas de los latidos son la media, la desviación estándar, la curtosis y la asimetría. En la figura 8 se observa el diagrama de dispersión de la curtosis versus asimetría, donde se etiquetan por color los siete tipos de latidos.

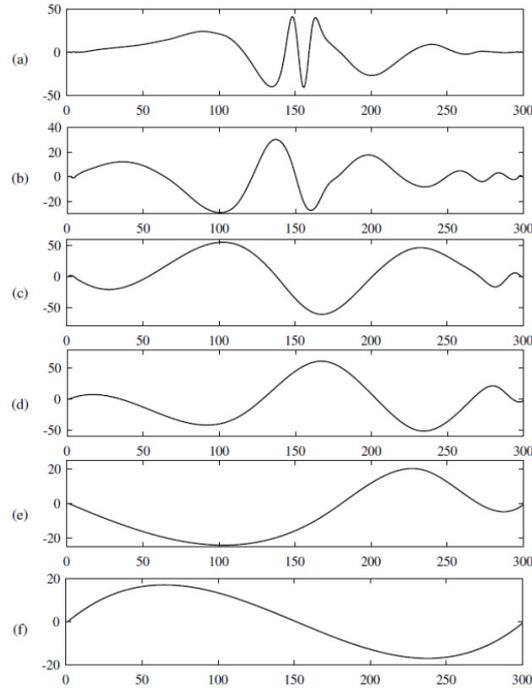


Figura 7: Funciones de modo intrínseco (IMF) de la derivada de un latido normal. En todos los casos, el eje horizontal representa el tiempo y el eje vertical está en voltios.

- La última característica corresponde a una del tipo temporal, donde el intervalo RR es el tiempo entre el pico R de un latido, con respecto al pico R del latido contiguo. En este caso, se obtuvieron dos medidas, una con respecto al anterior, y otra en relación a la posterior.

Para poder usar fast-ICA y EMD se ha construido un modelo de latido normal (MLN), generado como el promedio de todos los latidos normales de la base de datos. Luego se construyen los pesos de fast-ICA y EMD, mediante la suma del valor absoluto de la diferencia entre MLN y cada uno de los latidos de la base de datos.

Los intervalos RR anterior y posterior se preprocesan antes de convertirse en características. Los intervalos están expresados como una distancia entre los puntos de las ondas R de latidos consecutivos y deben ser normalizados de la siguiente manera:

$$r_n = \frac{R_n}{\hat{R}} \quad (19)$$

donde  $R_n$  y  $r_n$  son el intervalo RR original y normalizado, del latido  $n$ , respectivamente; y  $\hat{R}$  es el promedio de los intervalos RR. Este procedimiento se realiza para los latidos anteriores y para los posteriores.

De esta manera se obtienen treinta y tres características de las cuales veinte son pesos hallados con fast-ICA, seis son pesos hallados con EMD, cuatro son medidas estadísticas, dos son los intervalos RR y uno es la relación entre los intervalos RR.

### 3.3. Arquitectura ANN para la clasificación de los latidos

Para la clasificación de las arritmias cardíacas se utiliza una ANN [32], cuya arquitectura está constituida por cuatro capas de neuronas: una capa de entrada, dos capas ocultas y una capa de salida.

La capa de entrada está formada por treinta y tres neuronas, que equivale a la dimensión del vector de características, y la capa de salida tiene siete neuronas, que coincide con el número de clases de arritmias. Las dos capas ocultas se componen de ochenta neuronas cada una. Para obtener estos parámetros se realizó un exhaustivo trabajo experimental, tomando en consideración el tiempo de entrenamiento y la precisión en la clasificación.

La función de activación, de la segunda a la tercera capa, es la función tangente hiperbólica, dada en la ecuación (20).

$$f(x) = \frac{e^y - e^{-y}}{e^y + e^{-y}} \quad (20)$$

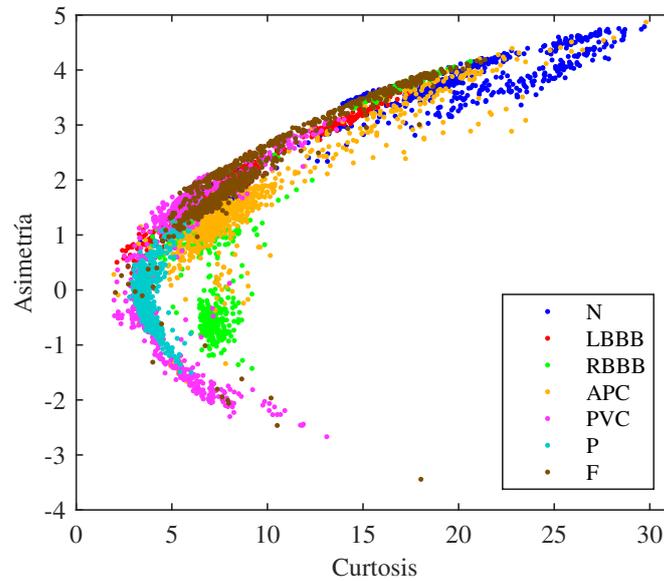


Figura 8: Gráfico de dispersión de la curtosis versus la asimetría donde se proyectan los diferentes tipos de latidos.

donde  $y$  es vector generado en la capa anterior.

Para la última capa se usa la función softmax, dada por la ecuación (21). La función softmax brinda facilidad para calcular las probabilidad de ocurrencia de cada clase.

$$\text{softmax}(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}} \quad (21)$$

en este caso,  $y$  es el vector generado en la penúltima capa.

Para el proceso de optimización se utilizó el algoritmo de retro-propagación (RPROP), que es una técnica que toma en cuenta únicamente el signo del gradiente para indicar la dirección de actualización de los pesos  $w_{i,j}$  de la ecuación (1), convirtiéndose así en el mejor algoritmo en términos de velocidad de convergencia [1].

### 3.4. Análisis de resultados y discusiones

#### 3.4.1. Entrenamiento de la ANN

Para entrenar la ANN usando la base de datos de latidos, se siguió el procedimiento descrito en [2] y las observaciones dadas en [1, 17, 32]. El proceso de entrenamiento involucra la minimización de una función de coste mediante un proceso iterativo, donde en cada época se van actualizando los pesos,  $w_{i,j}$ , de la ecuación (1), hasta alcanzar ciertos criterios de parada.

Al momento, la base de datos de latidos es altamente desequilibrada, ver la columna Peso de la tabla 2, donde la primera arritmia alcanza el 56,9%, las restantes representan el 43,1%, y de éstas la peor representada es la F con apenas el 1,5% del total. Sin un procesamiento apropiado de los datos, el clasificador resultante tenderá a favorecer a las clases mejor representadas.

Por lo tanto, para mitigar este inconveniente se han usado las estrategias de entrenamiento con datos no balanceados planteadas por Amr [2] y He y García [17], que reside en dos etapas. La primera consiste en dividir los datos en dos conjuntos, uno de entrenamiento y otro de prueba, al 70% y 30%, respectivamente. con muestreo estratificado. La segunda táctica ha sido utilizar el método de ponderación sobre el conjunto de entrenamiento, previo a realizar el ajuste de los pesos,  $w_{i,j}$ , de la ANN.

#### 3.4.2. Clasificación de latidos

En la tabla 3 se presentan los resultados de las métricas de evaluación, estimadas sobre las ecuaciones (15), (16), (17) y (18), para cada una de las clases, en la última fila se encuentran los promedios globales. La exactitud alcanza el 99,48% y la especificidad el 99,67%. En el caso de la sensibilidad y la precisión tenemos valores que rondan el 94,71% y el 93,52%, respectivamente; estos valores son bajos debido, posiblemente, a la presencia de

dos problemas por solucionar, i) pocos latidos en las clases F, V y A, ii) el algoritmo utilizado para localizar los puntos de inicio y fin de latido no funciona correctamente en todos los casos de arritmias. El primer problema se ha corregido parcialmente con las técnicas de aumento de datos, el segundo inconveniente necesita un método más robusto. Respecto al índice  $\kappa$ , éste llega al 0,9953, con un error del 0,04 %.

Tabla 3: Métricas de validación de la clasificación de arritmias cardíacas sobre varias señales de la base MIT-BIH [13].

Clase	EXA	SEN	ESP	PRE
<b>N</b>	99,27 %	99,17 %	99,43 %	99,64 %
<b>L</b>	99,56 %	98,58 %	99,71 %	98,14 %
<b>R</b>	99,69 %	98,13 %	99,85 %	98,42 %
<b>A</b>	99,64 %	98,57 %	99,68 %	91,54 %
<b>V</b>	99,20 %	92,50 %	99,65 %	94,77 %
<b>P</b>	99,85 %	99,52 %	99,87 %	97,40 %
<b>F</b>	99,17 %	76,53 %	99,56 %	74,74 %
<b>Prom.</b>	99,48 %	94,71 %	99,67 %	93,52 %

Por otra parte, resultados más exhaustivos, usando las métricas de evaluación (15), (16), (17) y (18), con los latidos originales, y modificados al añadir ruido gaussiano, se presentan en la tabla 4. En estas circunstancias de estrés, se observa que el clasificador es estable ante la presencia de perturbaciones. Por ejemplo, para el caso de la exactitud, apenas se modificó en el segundo decimal, cuando se añadió ruido a +5 dB.

Tabla 4: Resultados del entrenamiento de ANN sobre el conjunto de latidos de prueba, con latidos originales y con ruido añadido.

Latidos	EXA	SEN	ESP	PRE
<b>Original</b>	99.58 %	95.10 %	99.73 %	94.20 %
<b>+5 dB</b>	99.54 %	95.52 %	99.70 %	95.11 %
<b>+10 dB</b>	99.84 %	97.58 %	99.88 %	98.35 %

### 3.4.3. Tiempo de procesamiento por latido

El algoritmo de clasificación fue ejecutado en un computador portátil marca Asus modelo ROG GL552VW, con procesador Intel(R) Core(TM) i7-6700HQ @2.6Ghz de 64 bits y 16 GB de RAM, obteniendo un tiempo promedio de procesamiento de 8,89 mili segundos por cada latido. A esto hay que sumarle el tiempo promedio utilizado para generar el vector de características que es de 1,25 mili segundos.

### 3.4.4. Detección de arritmias cardíacas

Para validar el algoritmo de detección de arritmias cardíacas se tomaron 21 señales ECG de la base de datos MIT-BIH, que no fueron usadas en la etapa de entrenamiento. Los resultados de la clasificación se presentan en la tabla 5. En esta tabla se muestra la cantidad de latidos que contiene cada señal, por tipo de arritmias. Inclusive, la tabla indica la cantidad de latidos reales (Re) y predichos (Pr), es decir, las que se han generado por el algoritmo de clasificación ANN. Por ejemplo, sobre el registro ECG-100 se tiene 2269 latidos reales, donde se presentan dos latidos mal encasillados, uno en la clase N y uno en la clase V.

El tiempo de procesamiento depende del número de latidos que contiene la señal, en el caso del registro ECG-100, el algoritmo toma 23 segundos en clasificar todos los latidos. A esto hay que sumar el tiempo invertido en leer el registro, segmentar los latidos y en la presentación de los resultados en pantalla.

## 3.5. Discusión

Al someter al algoritmo de clasificación a distintas condiciones de ruido, sus resultados son altamente favorables con valores superiores al 99,5 % en la exactitud, respecto a la precisión se tiene el 93,52 % y la sensibilidad llega al 94,71 %, ver tabla 4. Además, los rendimientos expuestos en la tabla 5, sobre varias señales de MIT-BIT, ratifican la calidad de la propuesta con un alto desempeño.

Tabla 5: Resultados de la detección de las arritmias cardíacas sobre varias señales ECG de la base MIT-BIH.

	Clases de arritmias													
	N		L		R		A		V		P		F	
	Re.	Pr.	Re.	Pr.	Re.	Pr.	Re.	Pr.	Re.	Pr.	Re.	Pr.	Re.	Pr.
Ecg 100	2035	2034	0	0	0	1	33	33	1	1	0	0	0	0
Ecg 101	1857	1853	0	4	0	1	2	0	0	0	0	1	0	0
Ecg 103	2076	2075	0	0	0	1	2	2	0	0	0	0	0	0
Ecg 106	1500	1480	0	1	0	6	0	22	481	470	0	0	0	2
Ecg 107	0	0	0	4	0	1	0	4	58	28	2073	2076	0	18
Ecg 109	0	2	2017	2017	0	2	0	1	28	24	0	0	2	1
Ecg 111	0	0	2117	2107	0	2	0	4	1	3	0	0	0	2
Ecg 113	1789	1783	0	0	0	1	0	2	0	3	0	0	0	0
Ecg 115	1949	1940	0	1	0	0	0	8	0	0	0	0	0	0
Ecg 118	0	1	0	0	2161	2142	96	111	16	19	0	0	0	0
Ecg 119	1540	1540	0	0	0	0	0	0	443	441	0	2	0	0
Ecg 122	2472	2470	0	0	0	0	0	0	0	0	0	0	0	2
Ecg 123	1508	1491	0	0	0	0	0	17	3	3	0	0	0	0
Ecg 124	0	5	0	3	1545	1549	2	8	52	35	0	1	11	9
Ecg 205	2449	2451	0	1	0	0	2	6	61	49	0	1	10	14
Ecg 208	1567	1472	0	90	0	20	0	28	925	950	0	2	368	298
Ecg 213	2634	2653	0	1	0	1	1	1	195	123	0	1	364	413
Ecg 214	0	0	1918	1842	0	0	0	1	184	228	0	28	1	4
Ecg 220	1917	1919	0	0	0	1	71	66	0	2	0	0	0	0
Ecg 221	1997	1981	0	2	0	9	0	1	393	390	0	0	0	7
Ecg 232	0	13	0	6	296	253	1328	1340	0	4	0	6	0	2

Con estos antecedentes, en la tabla 6 se presenta un cuadro comparativo de ésta propuesta, respecto a las existentes en el estado del arte [3, 15, 18, 21, 25, 36, 37]. A partir de aquí se infiere que nuestra propuesta es competitiva con excelentes resultados. En concreto, la exactitud es superior en 4,5 %, 0,9 %, 0,7 %, 6,8 %, 1,4 % y 8,6 % respecto a Salah y Noureddine [36], Khalaf et al. [21], Li et al. [25], Gutiérrez et al. [15], Yang et al. [37] y Huang et al. [18], respectivamente, e igual de competitiva en referencia al trabajo de Prakash y Ari [3]. En el resto de métricas, esta propuesta sigue siendo competitiva.

Tabla 6: Comparación de los resultados de nuestra propuesta versus los trabajos del estado del arte.

Autor	EXA	SEN	ESP	PRE
Salah y Noureddine [36]	94,97 %	95,36 %	96,99 %	95,04 %
Khalaf et al. [21]	98,60 %	99,20 %	99,70 %	99,90 %
Li et al. [25]	98,80 %	–	–	–
Gutiérrez et al. [15]	92,74 %	–	–	–
Yang et al. [37]	98,10 %	93,90 %	–	–
Prakash y Ari [3]	99,52 %	–	–	–
Huang et al. [18]	90,93 %	–	–	–
<b>Nuestra</b>	<b>99,48 %</b>	<b>94,71 %</b>	<b>99,67 %</b>	<b>93,52 %</b>

## 4. Implementación del sistema de detección de arritmias cardíacas en hardware

Luego de la etapa de diseño, desarrollada en la plataforma Matlab [28], se ha procedido a implementar un dispositivo portátil que consta de dos partes, software y hardware. El diagrama global del sistema se muestra en la figura 9. En este esquema, los latidos se almacenan como un archivo en formato *.csv*, en una tarjeta micro SD. Seguidamente, el microcontrolador ATmega328P lee ésta tarjeta y envía los datos mediante una comunicación serial, a la tarjeta myRIO-1900; la misma que está compuesta por un procesador dual-core ARM Cortex-A9 y una Xilinx FPGA Z-7010.

La FPGA es el acrónimo de Field Programmable Gate Arrays y representa una serie de dispositivos basados en semiconductores a base de matrices de bloques lógicos configurables (CLB, en inglés), donde se conectan, a través,

de lo que en el sector se denomina como interconexiones programables. Su principal característica, y ventaja, es que pueden ser reprogramados para un trabajo específico o cambiar sus requisitos después de haberse fabricado. Lo interesante de este tipo de dispositivo son sus innumerables aplicaciones.

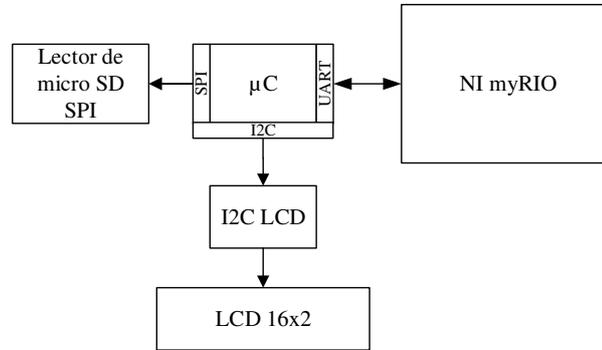


Figura 9: Diagrama de bloques del sistema de clasificación de arritmias cardíacas en la tarjeta *MyRio-1900*.

Los distintos módulos del algoritmo de clasificación se implementaron como bloques de programación que se ejecutan en un bucle infinito. La figura 10 muestra el diagrama de la propuesta, que fue implementado en la tarjeta myRio-1900 [7], usando el programa de desarrollo LabView [31].

Posteriormente, en la tarjeta myRIO-1900, específicamente en la FPGA, se realiza la clasificación de todos los latidos presentes en la señal ECG, acto seguido el resultado es enviado de regreso al microcontrolador para mostrar los resultados en una pantalla LCD.

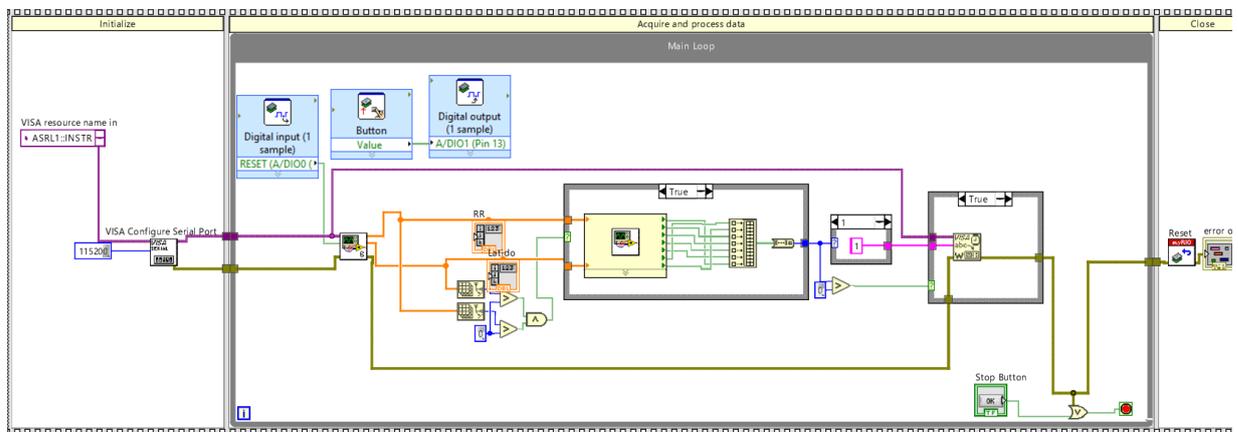


Figura 10: Diagrama de bloques para adquirir y procesar los datos del sistema de clasificación de arritmias cardíacas en LabView [31].

## 5. Conclusiones

En este trabajo se presentó el desarrollo de un sistema para detectar condiciones anormales del corazón, como son las arritmias cardíacas a partir del análisis de las señales ECG usando técnicas de procesamiento digital de señales y de aprendizaje automático. En esta propuesta se usó la base de datos de arritmias cardíacas del MIT-BIH, y con el estándar AAMI, como punto de referencia, se construyó el conjunto de datos para el desarrollo de los experimentos de entrenamiento y validación. Así se obtuvieron siete tipos de arritmias cardíacas.

Las técnicas de procesamiento digital de señales usadas para la generación de características fueron las siguientes: PCA, fast-ICA, EMD, estadísticas fundamentales y el ancho de los intervalos RR (anterior y posterior); generando un conjunto de treinta y tres características que representan adecuadamente los latidos. Acto seguido se entrenó una ANN, formada por dos capas ocultas, como clasificador.

El resultado de la clasificación tiene un valor del índice Kappa de Cohen de 0,9953, con un error del 0,04%, y una exactitud promedio del 99,48%. Claramente, esta propuesta es superior en 4,5%, 0,9%, 0,7%, 6,8%, 1,4% y 8,6% respecto a Salah y Noureddine [36], Khalaf et al. [21], Li et al. [25], Gutiérrez et al. [15], Yang et al. [37] y Huang et al. [18], respectivamente, e igual de competitiva que el trabajo de Prakash y Ari [3].

Posteriormente, se construyó un sistema móvil de detección de arritmias cardíacas basado en la tarjeta MyRIO-1900, donde se instaló el software aquí descrito.

A futuro se incorporará un módulo hardware para la captura de señales ECG en tiempo real, con la firme intención de dedicarlo a aplicaciones de eHealth o IoMT [16].

## Agradecimientos

En primer lugar, los autores deseamos expresar nuestro agradecimiento a los revisores anónimos, por el importante trabajo de revisión. También deseamos expresar nuestros agradecimientos a la empresa I&T Tech, por el financiamiento directo, y a la Universidad de las Fuerzas Armadas-ESPE por su apoyo, a través, de los proyectos sin financiamiento directo *2016-PIC-039* y *2020-PIC-001-CTE*.

## Conflicto de interés

Los autores declaran que leyeron y estuvieron de acuerdo con la versión publicada, y que no existe conflicto de intereses.

## Contribución de los autores

El diseño de la investigación, la supervisión y el análisis de los resultados corresponden a M. Flores-Calero. La implementación del software recae en B. Leppe. La redacción y la contrastación de la información recaen en M. Pilla, M. Gualsaquí y A. Albuja. La revisión del manuscrito es de D. Zabala-Blanco.

## Referencias

- [1] Oludare Isaac Abiodun, Aman Jantan, Abiodun Esther Omolara, Kemi Victoria Dada, Nachaat AbdElatif Mohamed, and Humaira Arshad. State-of-the-art in artificial neural network applications: A survey. *Heliyon*, (4), 2018.
- [2] Tarek Amr. *Hands-On Machine Learning with scikit-learn and Scientific Python Toolkits: A practical guide to implementing supervised and unsupervised machine learning algorithms in Python*. Packt, 2020.
- [3] Allam Jaya Prakash; Samit Ari. AAMI Standard Cardiac Arrhythmia Detection with Random Forest Using Mixed Features. *IEEE 16th India Council International Conference (INDICON)*, 2019.
- [4] Selcan Kaplan Berkaya, Alper Kursat Uysal, Efnan Sora Gunal, Semih Ergin, Serkan Gunal, and M. Bilginer Gulmezoglu. A survey on ecg analysis. *Biomedical Signal Processing and Control*, 43:216–235, 2018.
- [5] Nancy Betancourt, Marco Flores-Calero, and Carlos Almeida. ECG Denoising by using FIR and IIR Filtering Techniques: An Experimental Study. *11th International Conference on Bioinformatics and Biomedical Technology (ICBBT'19)*, pages 111–117, May 2019.
- [6] Aaron Frederick Bulagang, Ng Giap Weng, James Mountstephens, and Jason Teo. A review of recent approaches for emotion classification using electrocardiography and electrodermography signals. *Informatics in Medicine Unlocked*, 20, 2020.
- [7] NATIONAL INSTRUMENTS CORP. myRIO - Dispositivos Embebido para Estudiantes, 2021.
- [8] Eduardo Da-S.-Luz, William Schwartz, Guillermo Cámara-Chávez, and David Menotti. ECG-based heart-beat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine*, (127):144–164, 2016.
- [9] Departamento de Estadísticas e Información de Salud. Estadísticas de defunciones por causa básica de muerte, 2020. Defunciones por grupo de categorías, Causa básica de defunción: Todo, actualización de datos diciembre de 2020.
- [10] Mohamed Elgendi, Bjoern Eskofier, and Derek Abbott. Fast T wave detection calibrated by clinical knowledge with annotation of p and t waves. *Sensors MDPI*, (15):17693–17714, 2015.

- [11] Alejandra Vanessa Espinosa, María Daniela Carpio Toro, and Juan Felipe Vintimilla Garate. Arritmias cardíacas en corazón estructuralmente sano diagnosticadas por monitoreo holter electrocardiográfico y la correlación clínica en pacientes ambulatorios. *Revista Médica HJCA*, (9):270–274, 2017.
- [12] Jorge García, Roberto Castillo, Erika Buitrón, Magaly Paredes, Markus Nabernegg, Marco Boada, and Brenda Sempértégui. Compendio estadístico 2016., 2016.
- [13] Al Goldberger, Lan Amaral, L Glass, JM Hausdorff, PC Ivanov, RG Mark, JE Mietus, GB Moody, CK Peng, and Stanley HE. Physiobank, physiokit, and physionet: Components of a new research resource for complex physiologic signals. *Circulation*, (101):23, 2000. 101, e215-e220.
- [14] Rakesh Gopinathannair, Faisal Merchant, Dhanunjaya Lakkireddy, Susan Etheridge, Suzy Feigofsky, Janet Han, Rajesh Kabra, Andrea Natale, Stacy Poe, Sandeep Saha, and Andrea Russo. COVID-19 and cardiac arrhythmias: a global perspective on arrhythmia characteristics and management strategies. *J Interv Card Electrophysiol*, 2(59):329–336, Nov 2020.
- [15] J.A. Gutiérrez, R. Morfin, D. Lorias, A. Tellez, E. Reyes, A. Méndez, and R. Castañeda. DSP-based arrhythmia classification using wavelet transform and probabilistic neural network. *Biomedical Processing Signal and Control*, (32):44–56, 2017.
- [16] Mostafa Haghi, Saeed Danyali, Sina Ayasseh, Ju Wang, Rahmat Aazami, and Thomas M. Deserno. Wearable devices in health monitoring from the environmental towards multiple domains: A survey. *Sensors MDPI*, 6(21), March 2021.
- [17] H. He and E. A. García. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9):1263–1284, 2009.
- [18] Jingshan Huang, Binqiang Chen, Bin Yao, and Wangpeng He. ECG Arrhythmia Classification Using STFT-Based Spectrogram and Convolutional Neural Network. *IEEE Access*, 7:92871 – 92880, 2019.
- [19] Advancing Safety in Medical Technology AAMI. ANSI/AAMI EC57-2012–testing and reporting performance results of cardiac rhythm and st segment measurement algorithms, 2012. ISBN: 1-57020-478-0.
- [20] Pratik Kanani and Mamta Padole. ECG Heartbeat Arrhythmia Classification Using Time-Series Augmented Signals and Deep Learning Approach. *Procedia Computer Science*, 171:524–531, 2020.
- [21] Aya F. Khalaf, Mohamed I. Owis, and Inas A. Yassine. A novel technique for cardiac arrhythmia classification using spectral correlation and support vector machines. *Expert Systems with Applications*, (42):8361–8368, 2015.
- [22] Stephanie M. Kochav, Ellie Coromilas, Ani Nalbandian, Lauren S. Ranard, Aakriti Gupta, and Mina K. Chung. Cardiac arrhythmias in COVID-19 Infection. *Circulation: Arrhythmia and Electrophysiology*, 13(6), June 2020.
- [23] Shailesh Kumar, Damodar Panigrahy, and P.K. Sahu. Denoising of Electrocardiogram (ECG) signal by using empirical mode decomposition (EMD) with non-local mean (NLM) technique . *Biocybernetics and Biomedical Engineering*, 38(2):297–312, 2018.
- [24] M. Lambert, A. Engroff, M. Dyer, and B. Byer. Empirical mode decomposition, 1997.
- [25] Hongqiang Li, Danyang Yuan, Youxi Wang, Dianyin Cui, and Lu Cao. Arrhythmia classification based on multi-domain feature extraction for an ecg recognition system. *Sensors MDPI*, (16):13–20, 2016.
- [26] Manisha, Sanjeev Kr. Dhull, and Krishna Kant-Singh. ECG Beat Classifiers: A Journey from ANN To DNN. *Procedia Computer Science*, (167):747–759, 2020.
- [27] Roshan Joy Martis, Rajendra Acharya, and Lim Choo Min. ECG beat classification using PCA, LDA, ICA and Discrete Wavelet Transform. *Biomedical Signal Processing and Control*, 8(5):437–448, September 2013.
- [28] MathWorks. Matlab, 2020.
- [29] Mario Merone, Paolo Soda, Mario Sansone, and Carlos Sansone. ECG databases for biometric systems: A systematic review. *Expert Systems with Applications*, 67, 2016.
- [30] J. Muñoz, J. Rivera, and E. Duque. Análisis de componentes principales e independientes aplicados a reducción de ruido en señales electrocardiográficas. *Scientia et Technica*, 2(39), 2008.
- [31] National Instruments. Labview, 2020.
- [32] Michael Nielsen. Neural networks and deep learning. *Artificial Intelligence*, pages 389–411, 2018.
- [33] Alan Oppenheim, Ronald Schafer, and John Buck. Tratamiento de señales en tiempo discreto, 2000. Nonuniformly-sampled-signals.

- 
- [34] Organización Mundial de la Salud. Enfermedades cardiovasculares, 2017.
- [35] Jagdeep Rahul, Marpe Sora, Lakhan Dev-Sharma, and Vijay Kumar-Bohat. An improved cardiac arrhythmia classification using an RR interval-based approach. *Biocybernetics and Biomedical Engineering*, 41(2):656–666, April 2021.
- [36] Hadji Salah and Ellouze Nouredine. Cardiac arrhythmia classification by wavelet transform. *International Journal of Advanced Research in Artificial Intelligence (IJARAI)*, 4(5):18–20, 2015.
- [37] Ping Yang, Dan Wang, Wen-Bing Zhao, Li-Hua Fu, Jin-Lian Du, and Hang Su. Ensemble of kernel extreme learning machine based random forest classifiers for automatic heartbeat classification. *Biomedical Signal Processing and Control*, 63, 2021.
- [38] Li Yuan, Zhuhuang Zhou, Yanchao Yuan, and Shuicai Wu. An improved FastICA method for fetal ecg extraction. *Computational and Mathematical Methods in Medicine*, pages 1–7, 2018.