



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

**DEPARTAMENTO DE ELÉCTRICA,
ELECTRÓNICA Y TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

**TRABAJO DE TITULACIÓN, PREVIO A LA OBTENCIÓN DEL
TÍTULO DE INGENIERO EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

**TEMA: "CLASIFICACIÓN DE ARRITMIAS CARDÍACAS EN
BASE A CARACTERÍSTICAS LINEALES Y NO LINEALES
DEL ECG USANDO REDES NEURONALES"**

AUTOR: Leppe Bravo, Bruno Alonso

DIRECTOR: Flores Calero, Marco Javier

SANGOLQUÍ

2020



**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL**

CERTIFICACIÓN

Certifico que el trabajo de titulación, "**CLASIFICACIÓN DE ARRITMIAS CARDÍACAS EN BASE A CARACTERÍSTICAS LINEALES Y NO LINEALES DEL ECG USANDO REDES NEURONALES**" realizado por el señor **Bruno Alonso Leppe Bravo**, ha sido revisado en su totalidad y analizado por el software anti-plagio, el mismo cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Univesidad de las Fuerzas Armadas ESPE, por lo tanto me permito acreditarlo y autorizar a el señor **Bruno Alonso Leppe Bravo** para que lo sustente públicamente.

Sangolquí, 6 de diciembre de 2019


Flores Calero, Marco Javier
DIRECTOR



**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL**

AUTORIA DE RESPONSABILIDAD

Yo, **Bruno Alonso Leppe Bravo**, con cédula de identidad N° **1718828088** declaro que este trabajo de titulación "**CLASIFICACIÓN DE ARRITMIAS CARDÍACAS EN BASE A CARACTERÍSTICAS LINEALES Y NO LINEALES DEL ECG USANDO REDES NEURONALES**" ha sido desarrollado considerando los métodos de investigación existentes, así como también se ha respetado los derechos intelectuales de terceros considerándose en las citas bibliográficas.

Consecuentemente declaro que este trabajo es de mi autoría, en virtud de ello me declaro responsable del contenido, veracidad y alcance de la investigación mencionada.

Sangolqui, 6 de diciembre de 2019

Bruno Alonso Leppe Bravo

CI: 1718828088



**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL**

AUTORIZACIÓN

Yo, **Bruno Alonso Leppe Bravo**, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar en la biblioteca Virtual de la institución el presente trabajo de titulación **"CLASIFICACIÓN DE ARRITMIAS CARDÍACAS EN BASE A CARACTERÍSTICAS LINEALES Y NO LINEALES DEL ECG USANDO REDES NEURONALES"** cuyo contenido, ideas y criterios son de mi autoría y responsabilidad.

Sangolqui, 6 de diciembre de 2019

Bruno Alonso Leppe Bravo

CI: 1718828088

DEDICATORIA

A mi familia, amigos y mi banda. Gracias por estar ahí ayudándome a cumplir mis sueños.

Bruno Alonso Leppe Bravo

AGRADECIMIENTO

Quiero agradecer a mis padres y a mi hermano por su esfuerzo, dedicación y paciencia.

Agradezco al PhD Marco Flores, el director de esta tesis, por su guía y enseñanzas, por hacer posible la culminación de este trabajo de investigación.

Finalmente quiero agradecer a la Universidad de las Fuerzas Armadas ESPE y mis profesores, que me han dado la posibilidad de educarme profesionalmente.

Bruno Alonso Leppe Bravo

ÍNDICE DE CONTENIDOS

CARÁTULA	i
CERTIFICADO	ii
AUTORÍA DE RESPONSABILIDAD	iii
AUTORIZACIÓN	iv
DEDICATORIA	v
AGRADECIMIENTO	vi
ÍNDICE DE CONTENIDOS	x
ÍNDICE DE TABLAS	xi
ÍNDICE DE FIGURAS	xv
RESUMEN	xvi
ABSTRACT	xvii
CAPÍTULO I	1
Introducción	1
1.1 Antecedentes	1
1.2 Justificación e importancia	3
1.3 Alcance del proyecto	4
1.4 Objetivos	5
1.4.1 Objetivo General	5
1.4.2 Objetivos específicos	5
CAPÍTULO II	7
Estado del arte	7
2.1 Electrofisiología del corazón	7

2.1.1	Biopotenciales	7
2.1.2	Potencial de acción	7
2.1.3	Anatomía del corazón	8
2.1.4	Inervación del corazón	9
2.1.5	Electrocardiograma	9
2.1.6	Características del ECG	10
2.1.7	Tipos de arritmias	11
2.2	Segmentación del ECG	13
2.2.1	Algoritmos de segmentación	14
2.3	Técnicas de análisis de datos	15
2.3.1	Análisis de componentes independientes	15
2.3.2	Análisis de componentes principales	16
2.3.3	Descomposición de modo empírico	16
2.4	Medidas estadísticas	17
2.4.1	Media	17
2.4.2	Varianza	17
2.4.3	Asimetría estadística	17
2.4.4	Apuntamiento o Curtosis	17
2.5	Clasificación de arritmias cardíacas	17
2.5.1	Técnicas de clasificación	18
2.6	Redes neuronales artificiales	19
2.6.1	Perceptrón	20
2.6.2	Entrenamiento	21
	CAPÍTULO III	23
	Desarrollo del algoritmo de detección y clasificación de arritmias	23
3.1	Introducción	23
3.2	Bases de datos	23
3.3	Procesamiento de señales ECG	25
3.3.1	Latidos	30

3.4	Extracción de características	30
3.4.1	Análisis de Componentes Principales (PCA)	31
3.4.2	Análisis de Componentes Independientes (ICA)	31
3.4.3	Derivada	35
3.4.4	Características temporales	37
3.5	Clasificador	39
3.5.1	Arquitectura del clasificador	39
3.5.2	Entrenamiento del clasificador	41
3.6	Entrenamiento sobre latidos con ruido	41
3.7	Gráficas de características extraídas	42
3.8	Diseño e implementación de la interfaz gráfica de usuario	47
3.8.1	Descripción de la interfaz	47
3.8.2	Requerimientos de la interfaz	47
3.8.3	Diseño del flujograma general	48
3.8.4	Diseño del subproceso de preprocesamiento	48
3.8.5	Diseño del subproceso de segmentación	50
3.8.6	Diseño del subproceso de extracción de características	51
3.8.7	Diseño del subproceso de la red neuronal	54
3.8.8	Implementación de la pantalla de presentación	57
3.8.9	Implementación de la pantalla principal	57
3.9	Codigos en MATLAB de los subprocesos del sistema	63
3.9.1	Preprocesamiento	63
3.9.2	Segmentación	63
3.9.3	Extracción de características	67
3.9.4	Red Neuronal	68
	CAPÍTULO IV	71
	Pruebas y Análisis de Resultados	71
4.1	Pruebas sobre registros de la base de datos MIT-BIH	71
4.1.1	Escenario de pruebas	71

	x
4.1.2 Realización de pruebas	71
4.2 Métricas de desempeño del clasificador	74
4.2.1 Matriz de confusión	74
4.2.2 Exactitud	75
4.2.3 Precisión	75
4.2.4 Sensitividad	75
4.2.5 Especificidad	75
4.3 Resultados del Clasificador	76
CAPÍTULO V	79
Conclusiones	79
REFERENCIAS BIBLIOGRÁFICAS	82

ÍNDICE DE TABLAS

Tabla 1	Comparativa de resultados obtenidos de los métodos investigados	20
Tabla 2	Tipos de latidos definidos en el estándar AAMI	25
Tabla 3	Cantidad de latidos extraídos	30
Tabla 4	Vector de características extraídas del ECG	30
Tabla 5	Desviación estándar de intervalos RR	39
Tabla 6	Clases del clasificador y tipos de arritmias asociados.	40
Tabla 7	Matriz de confusión del clasificador	41
Tabla 8	Métricas de desempeño del clasificador	42
Tabla 9	Métricas de desempeño del clasificador	43
Tabla 10	Resultados de las pruebas realizadas	73
Tabla 11	Ejemplo de matriz de confusión	75
Tabla 12	Matriz de confusión del clasificador	76
Tabla 13	Métricas del clasificador	77
Tabla 14	Comparativa de resultados con trabajos anteriores	77

ÍNDICE DE FIGURAS

Figura 1	Ondas, segmentos e intervalos del pulso cardiaco de un corazón sano	10
Figura 2	Red neuronal artificial directa de tres capas de perceptrones. . .	21
Figura 3	Diagrama de bloques general del sistema de clasificación de arritmias.	23
Figura 4	Tipos de arritmias tratados en el proyecto. (a) Latido normal. (b) LBBB. (c) RBBB. (d) APC. (e) PVC. (f) Latido de marcapasos (P). (g) Fusión (F)	26
Figura 5	Latido normal filtrado con un filtro pasa banda Butterworth, frecuencia de corte inferior de 0.5Hz y frecuencia de corte superior de 45Hz.	27
Figura 6	Eigenvalores acumulados del conjunto de latidos normales, donde 1 equivale al 100 % de la información que contienen. . . .	28
Figura 7	(a) Latido filtrado mediante PCA usando el 70 % de la información, tomando solo 20 componentes principales. (b) Componente 21 del conjunto de latidos que solo representa ruido. Las componentes restantes también representan ruido.	29
Figura 8	Latido normal con ruido gaussiano añadido en una relación señal a ruido $SNR = 5dB$	31
Figura 9	Comparativa de un latido con ruido añadido y reconstruido con PCA. (a) Latido libre de ruido blanco. (b) Latido con ruido blanco gaussiano añadido con una relación señal a ruido de 5 dB. (c) Latido reconstruido con la matriz de transformación obtenida después de aplicar PCA.	32

Figura 10	Componentes independientes de un conjunto de latidos normales calculados con el algoritmo FastICA. Cada componente independiente es una fuente y sumadas con ciertos pesos dan como resultado cualquier tipo de latido.	34
Figura 11	a) Latido promedio de la base de datos. b) Derivada del latido promedio.	36
Figura 12	Funciones de modo intrínseco (IMF) de la derivada de un latido normal. Las imfs son fuentes que sumadas con ciertos pesos dan como resultado las derivadas de cualquier tipo de latido.	38
Figura 13	Arquitectura de la red neuronal usada como clasificador de arritmias cardiacas.	40
Figura 14	Comparativa de los grupos de arritmias prematuras y no prematuras. Dentro del grupo de arritmias prematuras se encuentran las clases APC y PVC. Los cúmulos formados por los puntos representan la agrupación de los tipos de arritmias. . .	43
Figura 15	Gráfica de los componentes independientes (IC) 1 y 2. Los componentes independientes consiguen definir las clases y agruparlas en cúmulos. La separación de clases no es perfecta debido a ciertas similitudes entre latidos.	44
Figura 16	IC_{12} vs curtosis. Se observa una dispersión de los puntos y formación cúmulos de latidos de una misma clase. Se observan varios cúmulos de una misma clase debido a las diferencias en de cada paciente.	45
Figura 17	IMF_1 vs curtosis. La clase PVC es la clase más diferenciada y se debe a la morfología de su complejo QRS.	45

Figura 18	Curtosis vs asimetría estadística. La curtosis es una medida que provee información del apuntamiento de un latido. Es decir, que tan concentrada está la información en el centro, la onda R. La asimetría es un indicador de la cantidad de información situada a la izquierda o derecha de un eje vertical de referencia que pasa por la itad del latido. Este indicador puede ser positivo o negativo. Cuando un latido contiene más información a su izquierda el indicador es positivo y viceversa.	46
Figura 19	Diagrama de flujo general de la interfaz.	49
Figura 20	Diagrama de flujo del filtrado de la señal ECG.	50
Figura 21	Diagrama de flujo del subproceso de segmentación de una señal ECG que pertenece a los registros.	52
Figura 22	Diagrama de flujo del subproceso de clasificación de latidos mediante la generación de un vector de 33 características.	55
Figura 23	Diagrama de flujo del proceso de la red neuronal.	56
Figura 24	Pantalla de presentación de la interfaz. Incluye el logo de la Universidad, el tema tratado, el autor y el presente año.	57
Figura 25	Vista de la pantalla principal. Por defecto, la pantalla empieza en la pestaña de selección de registro.	58
Figura 26	Vista de la pantalla principal. Por defecto, la pantalla empieza mostrando la pestaña de selección de registro.	58
Figura 27	Menú de selección de registro. El usuario deberá escoger uno de los registros desplegados para su visualización y procesamiento.	59
Figura 28	Controles de visualización de la gráfica.	59
Figura 29	Detalles marcados den la señal. La leyenda define el tipo de marca para las ondas del ECG.	59
Figura 30	Pestaña de segmentación y clasificación.	60
Figura 31	Botón de segmentación del ECG sobre el cuadro de texto donde se muestra la cantidad de latidos segmentados.	60

Figura 32	Controles de navegación para visualización de latidos segmentados.	61
Figura 33	Cuadros de texto donde se escribe la cantidad de arritmias clasificadas del registro.	61
Figura 34	Se marca la onda R de las arritmias encontradas por el clasificador.	62
Figura 35	Botones para guardar o imprimir los resultados de la clasificación del registro.	62
Figura 36	Grafica de un latido segmentado. Este latido corresponde a una arritmia de tipo PVC, clasificada correctamente.	62
Figura 37	Ejemplo de la base de datos generada después de aplicar el software a 7 registros.	63
Figura 38	Diagrama de bloques del procedimiento para la clasificación de latidos de los registros de la base de datos MIT-BIH.	71
Figura 39	Selección y visualización del registro ECG en la primera pestaña de la interfaz de usuario.	72
Figura 40	Segmentación y clasificación de latidos del registro ECG 100. La cantidad de latidos segmentados es de 2269.	72
Figura 41	Hoja de cálculo generada por el programa. Muestra las cantidades reales y predichas de las arritmias clasificadas. El archivo actual es una captura de los resultados del registro Ecg 100.	73

RESUMEN

Las enfermedades cardiovasculares se han vuelto una de las principales causas de muerte en el mundo, tanto en países en desarrollo como en países desarrollados. El diagnóstico de enfermedades cardíacas empieza por la detección de arritmias cardíacas y es una tarea laboriosa para los médicos especializados, debido a la gran cantidad de información que se debe analizar. En este trabajo se presenta un sistema de clasificación de 7 tipos de arritmias cardíacas que se encuentran contempladas dentro del estándar AAMI. Estas son: latidos normales, APC, PVC, fusión, LBBB, RBBB y latidos de marcapasos. En el presente trabajo se diseñó un sistema de extracción de características para determinar 33 características del ECG. Estas son: 20 características morfológicas extraídas con ICA, 6 características frecuenciales del complejo QRS extraídas mediante la aplicación de EMD sobre la derivada de un latido, 4 características lineales extraídas con el cálculo de 4 medidas estadísticas, 3 características que determinan la prematuridad de un latido mediante el procesamiento de los intervalos RR anterior y posterior. Se diseñó una técnica de filtrado de ruido basada en PCA aplicada previa a la extracción de características para eliminar cualquier tipo de ruido presente en los latidos. Finalmente las 33 características entran a una red neuronal directa compuesta de 4 capas con un total de 200 neuronas. Se realizaron pruebas sobre 21 registros de la base de datos MIT-BIH utilizando una interfaz gráfica diseñada en este trabajo. La exactitud promedio alcanzada al comparar los resultados obtenidos en este trabajo con los atributos de las señales proporcionados por *Physionet* fue de 99.91 %.

PALABRAS CLAVE

- **ARRITMIA**
- **ICA**
- **PCA**
- **EMD**
- **CLASIFICADOR**

ABSTRACT

Cardiac diseases have become one of the principal causes of death for all people in the world. Diagnosis of cardiac diseases begin with detection of cardiac arrhythmia. This is a very demanding task for medical specialists due to the amount of data that have to be analyzed, that is about two days of recordings. This work presents a classification system for 7 classes of cardiac arrhythmia defined by the AAMI standard, which are: normal beats, APC, PVC, fusion beats, LBBB, RBBB and paced beats. A feature extraction algorithm was designed to obtain 33 features from the ECG using data analysis algorithms: ICA and EMD, RR intervals and statistic measures. A new filter process based on PCA was designed. The 33 features are used by a direct artificial neural network composed of 4 layers and 200 neurons, with an achieved accuracy of 99.91 %.

KEY WORDS

- **ARRHYTHMIA**
- **ICA**
- **PCA**
- **EMD**
- **CLASSIFIER**

CAPÍTULO I

Introducción

1.1 Antecedentes

Las enfermedades cardiovasculares se han vuelto una de las principales causas de muerte en el mundo, tanto en países en desarrollo como en países desarrollados Hu et al. (2012). Datos tomados de la OMS indican que el 31 % de todas las muertes registradas en el mundo se deben a enfermedades cardiovasculares OMS (2017). En el Ecuador, según datos recogidos por el Instituto Nacional de Estadísticas y Censos del Ecuador INEC, en el año 2016 se registraron 6 513 muertes a causa de Enfermedades isquémicas del corazón, la cual es la principal causa de mortalidad general con un porcentaje de 9,65 %. Los fallecimientos por insuficiencia cardiaca fueron 963 García et al. (2016). Las arritmias están presentes en un 6 % de defunciones. Se calcula que el 15 % de personas mayores de 50 años padecen algún tipo de arritmia cardíaca Espinosa et al. (2017).

En el diagnóstico de arritmias, el médico especializado realizará pruebas de monitoreo cardiaco en las que se incluye el ECG Manka (2017). El ECG es una captura de biopotenciales y representa la actividad eléctrica del corazón. Es una prueba no invasiva en la que se conectan electrodos al paciente para capturar las señales eléctricas. Castillo et al. (2011). Las señales ECG son pre-procesadas para eliminar elementos no deseados; como el ruido producido por señales musculares, movimiento de los electrodos, entre otros Li et al. (2016). Existen diversos métodos automatizados que utilizan las señales ECG para analizar sus parámetros y determinar ciertos tipos de arritmias sin la supervisión de un médico especializado. Pequeñas variaciones en la señal que pueden pasar desapercibidas por un médico pueden ser obtenidas mediante estos métodos Luz et al. (2016). De esta manera se facilita la detección de arritmias cardiacas, con un alto porcentaje de fiabilidad Wang et al. (2013).

Las arritmias se definen como trastornos del ritmo cardiaco causados

por una actividad eléctrica anormal del corazón. Estas alteraciones del ritmo cardíaco se presentan en personas con enfermedades cardiovasculares, hipertensión y enfermedades de la arteria coronaria; enfermedades generalmente asociadas con estilos de vida no saludables como la falta de ejercicio, obesidad, dietas pobres y el uso del tabaco Espinosa et al. (2017); Elhaj et al. (2016). Existen varios tipos de arritmias, cada una asociada con un patrón morfológico o de frecuencia específico. Comúnmente, las arritmias se clasifican por su origen en el corazón y por la alteración del ritmo cardíaco. Las arritmias que se originan en las cámaras inferiores se denominan arritmias ventriculares, las que se originan en las cámaras superiores se denominan supra ventriculares. Los otros dos tipos son la bradicardia, disminución del ritmo cardíaco, y la taquicardia, aumento del ritmo cardíaco Arrhythmia Alliance (n.d.).

Existen métodos automatizados para la detección de latidos del corazón que reemplazan la detección gráfica usada por el personal médico. Estos métodos han probado ser más eficientes y eficaces, reduciendo la carga de trabajo de los doctores Li et al. (2016). Las señales ECG contienen varios parámetros que pueden ser utilizados para la detección y clasificación de arritmias. Estos parámetros o características son temporales, espectrales, no lineales y morfológicos. Los métodos actuales para la detección de arritmias utilizan transformaciones, reducción de la dimensionalidad de un conjunto de datos y algoritmos para la extracción de características de las señales ECG. La transformada de Fourier, transformada wavelet, análisis de componentes principales (PCA), análisis de componentes independientes (ICA), son algunas de las técnicas usadas para la extracción de características temporales y de frecuencia Luz et al. (2016). Una vez extraídas las características se clasifica cada tipo de arritmia utilizando también diversos métodos como las redes neuronales, las máquinas de soporte vectorial, lógica difusa, etc. Li et al. (2016); Übeyli (2009)

1.2 Justificación e importancia

Dentro de la Universidad de las Fuerzas Armadas ESPE se trabaja en el desarrollo de métodos y sistemas de alerta temprana de enfermedades cardíacas, de manera que contribuyan en el diagnóstico y tratamiento de patologías del corazón. Así el proyecto de investigación “EcuHeart-procesado digital de señal avanzado en monitorización cardiaca prolongada y densa” tiene entre unos de sus objetivos el desarrollar métodos para detectar y clasificar arritmias para el diagnóstico y tratamiento de enfermedades cardiovasculares.

La detección de arritmias puede llegar a ser una tarea difícil incluso para un médico especializado a causa de la gran cantidad de latidos presentes en las grabaciones de los pacientes, pues cada grabación puede durar hasta 48 horas. Los cardiólogos se encargan del diagnóstico y se basan en los antecedentes médicos del paciente, exámenes y resultados de ciertas pruebas. Las herramientas más usadas por los médicos para la grabación de latidos son el monitor de Holter y el monitor de eventos cardiacos National Heart, Lung & (NHLBI) (n.d.). Es por esto que en este proyecto se propone el desarrollo de un método para la detección y clasificación automática de arritmias tomadas de las grabaciones del ECG de la base de datos MIT-BIH.

Para este fin se propone el uso del análisis de componentes independientes con kernel (KICA) como método principal, medidas estadísticas y el análisis de la derivada del latido para la extracción de nuevas características no lineales de los latidos del corazón y su posterior clasificación automática. El fin de este proyecto es construir un sistema inteligente altamente eficiente para la clasificación automática de arritmias cardíacas.

1.3 Alcance del proyecto

El presente proyecto tiene como finalidad la clasificación de 7 tipos de latidos cardiacos definidos en el estándar de la Asociación para el Avance de la Instrumentación Médica (AAMI), los cuales son: latidos normales, auriculares ectópicos, ventriculares ectópicos, latidos fusionados y latidos desconocidos. El estándar engloba las arritmias existentes en la base de datos MIT-BIH Rahhal et al. (2015). Las señales ECG son tomadas de la base de datos MIT-BIH. Las grabaciones de la base de datos contienen dos señales, generalmente la primera señal es tomada de la segunda derivación modificada del ECG y la segunda señal suele ser tomada de la derivación V5. Se debe efectuar un pre-procesamiento de las señales ECG que se encuentran en la base de datos MIT-BIH basado en trabajos anteriores dentro del proyecto “EcuHeart”, en los cuales se utilizan filtros digitales y la transformada de wavelet para eliminar el ruido debido a la red eléctrica de 60Hz, movimientos musculares del paciente y otros. Se aplica un método de filtrado con PCA para eliminar ruido remanente. Después del filtrado se segmentará cada señal ECG para obtener latidos individuales usando un algoritmo de detección de latidos.

Durante el proceso de extracción de características se aplicará el análisis de componentes independientes con kernel (KICA), como método principal de extracción, a una matriz formada por los latidos obtenidos del pre-procesamiento. Las características obtenidas con KICA se consideran no lineales. KICA es un método para encontrar componentes estadísticamente independientes, con el cual se puede descomponer el ECG en un conjunto de señales independientes Cruces & Nuñez (2005).

Se diseñó un método basado en PCA para remover ruido blanco gaussiano de todas las señales que entren al sistema previo a la aplicación de KICA. También se extraen características temporales de medidas estadísticas que son: media, desviación estándar, curtosis y apuntamiento. Por último se desarrolló un método

nuevo en el cual se extraen características de la derivada del ECG aplicando la Descomposición de Modo Empírico (EMD) obteniendo seis nuevas características. El total de características obtenidas es de 32, 20 características obtenidas con KICA, 4 características temporales y 6 características de la derivada.

La clasificación de arritmias se realizará mediante redes neuronales artificiales (ANN). La red neuronal estará compuesta de tres capas de neuronas, las cuales son: capa de entrada, capa de salida y capa oculta. El número de neuronas en cada capa es de 32, 20 y 7 respectivamente. Para la capa de entrada se necesitan tantas neuronas como la dimensión del espacio de características del ECG. La capa de salida estará compuesta por 7 neuronas para la clasificación de los cinco tipos de latidos definidos por el estándar AAMI. Se entrena la red neuronal con el algoritmo de propagación hacia atrás para el espacio de características obtenido.

Para probar la red neuronal se utilizan los latidos que no fueron usados para la extracción de características. Se calculan cuatro métricas para validar el desempeño del clasificador: precisión, sensibilidad, especificidad y exactitud.

1.4 Objetivos

1.4.1 Objetivo General

Desarrollar un sistema para la detección, extracción de características lineales y no lineales, y clasificación de arritmias cardíacas en base a redes neuronales artificiales.

1.4.2 Objetivos específicos

- Realizar un estudio de tecnologías de vanguardia de métodos de detección y clasificación de arritmias usando ECG.
- Realizar el pre-procesamiento de las señales ECG de la base de datos MIT-BIH.

- Implementar un algoritmo basado en métodos tradicionales y experimentales para la extracción de características lineales del ECG.
- Implementar un algoritmo basado en ICA para la extracción de características no lineales del ECG.
- Diseñar y entrenar una red neuronal para la clasificación de arritmias usando el espacio de características obtenido.
- Validar el clasificador usando los registros de la base de datos MIT-BIH realizar un análisis de la precisión, sensibilidad, especificidad y exactitud. .

La tesis se compone de 5 capítulos. En el Capítulo I se tratan los temas que anteceden la investigación. El Capítulo II contiene el marco teórico. En el Capítulo III se describe la metodología y algoritmos utilizados. En el Capítulo IV se muestran los resultados del sistema. En el Capítulo V se exponen las conclusiones del proyecto.

CAPÍTULO II

Estado del arte

2.1 Electrofisiología del corazón

2.1.1 Biopotenciales

Un biopotencial es un potencial eléctrico existente entre el interior y el exterior de la membrana celular. Las células musculares y nerviosas presentan una membrana semipermeable que permite el paso de iones. Las células están rodeadas del líquido intersticial que contiene iones (electrolito), principalmente iones de potasio (K⁺), sodio (Na⁺) y cloruro (Cl⁻) Noda et al. (1996).

Cuando la célula se encuentra en reposo la membrana permite el paso de los iones de potasio pero impide el paso de los iones de sodio. Existe una concentración mayor de iones de cloruro y sodio fuera de la membrana celular, mientras que en el interior existe mayor concentración de iones de potasio. La diferencia de potencial en la membrana celular causada es negativa en el interior de la membrana con respecto al exterior. Esta diferencia de potencial, denominada potencial de reposo tiene un valor entre -9 y -100 milivoltios(mV) Noda et al. (1996).

2.1.2 Potencial de acción

El potencial de acción es una onda eléctrica que viaja por la membrana celular y modifica la carga eléctrica de esta. Los potenciales de acción permiten la transmisión de información entre células y son producidos generalmente por células nerviosas para la comunicación con otras células nerviosas o con tejidos musculares, glándulas, etc Berg et al. (2008).

Una célula que se encuentra en reposo se dice que está polarizada, con un potencial de -70 milivoltios (mV). Cuando la célula se excita debido a un potencial de acción la membrana sufre cambios en la distribución de sus iones. Estos

cambios se dividen en tres etapas: reposo, despolarización y repolarización. Durante la despolarización se produce un intercambio de iones entre el interior y exterior de la célula. Los iones de sodio entran en la célula y el potencial de la membrana cambia, se vuelve positivo respecto al exterior con un potencial de aproximadamente 30 mV. Durante la etapa de repolarización la célula vuelve a su estado inicial Garza et al. (2015).

2.1.3 Anatomía del corazón

El corazón está situado en el tórax, encima del diafragma y alineado a la izquierda. Tiene un tamaño similar al de un puño cerrado y pesa alrededor de 250 a 300 gramos en personas adultas Torosa (n.d.). Está envuelto en una capa externa denominada pericardio que lo protege y mantiene en su posición. La pared del corazón está formado por tres capas: la capa externa denominada epicardio que corresponde al pericardio, la capa media o miocardio que está formada por tejido muscular y la capa interna llamada endocardio que cubre las cuatro cavidades.

El corazón está formado por cuatro cavidades, dos superiores llamadas aurículas y dos inferiores llamadas ventrículos. La contracción de estas cavidades genera el flujo de sangre a través de venas y arterias. Dos válvulas auriculo-ventriculares permiten el paso de la sangre entre aurículas y ventrículos y son la válvula mitral, que se encuentra entre la aurícula y ventrículo izquierdo, y la válvula tricúspide, entre la aurícula y ventrículo derecho. Otras dos válvulas permiten el flujo de sangre a la aorta y pulmonar y son la válvula aortica, que se encuentra en la salida del ventrículo izquierdo y la arteria aorta, y la válvula pulmonar que se encuentra entre la salida del ventrículo derecho y la vena pulmonar. La sangre oxigenada que proviene de los pulmones fluye por las venas pulmonares hasta llegar a la aurícula izquierda. La sangre de la aurícula izquierda fluye hacia el ventrículo izquierdo y sale por la arteria aorta hacia el resto del cuerpo. La sangre carboxigenada proviene de los tejidos del cuerpo y fluye por la vena cava superior e inferior hasta la aurícula derecha, la sangre

llega al ventrículo derecho y sale por la vena pulmonar De los Nietos (2007).

2.1.4 Inervación del corazón

El corazón está conectado al sistema nervioso simpático, que es parte del sistema nervioso autónomo, el cual controla las funciones de los sistemas internos del cuerpo humano. Su función es la de mantener la homeostasis o el equilibrio interno del cuerpo. El sistema nervioso central inerva el miocardio, el músculo liso, presente en los órganos internos, y glándulas Navarro (2002).

El sistema de conducción del corazón está compuesto por conjuntos de células nerviosas especializadas que inician y transmiten los impulsos nerviosos por todo el miocardio Fajuri (2018). El nodo sinusal o sinoauricular inicia el impulso eléctrico en un corazón sano y propaga el potencial de acción hacia las aurículas. Los impulsos nerviosos convergen en el nodo auriculoventricular y este los propaga a través del haz de His hacia los ventrículos. El haz de His se bifurca, generando las ramas derecha e izquierda que recorren los ventrículos y se distribuyen en todo el miocardio. Los impulsos nerviosos viajan hasta las fibras de Purkinje que conducen el potencial de acción a través de todo el miocardio ventricular Torosa (n.d.).

2.1.5 Electrocardiograma

El ECG (electrocardiograma) es una prueba no invasiva para el registro de la actividad eléctrica del corazón. La prueba se realiza colocando electrodos en el tórax del paciente. Estos electrodos se conectan a un electrocardiógrafo que muestra gráficamente la actividad del corazón en función del tiempo. El electrocardiógrafo se utiliza para el diagnóstico de enfermedades cardiovasculares y el ritmo cardiaco Prieto (n.d.).

Cuando se realiza la prueba del ECG, los electrodos se conectan en posiciones específicas y se mide el voltaje entre uno o dos electrodos. Estas mediciones se

denominan derivaciones y existen varias maneras de conectar los electrodos. La derivación usada en este proyecto se denomina segunda derivación de las extremidades modificada o MLII. En la versión original de esta derivación los electrodos se conectan en el brazo derecho (RL) y la pierna izquierda (LL). En la versión modificada los electrodos se conectan en la parte derecha del pecho. Así se evitan ruidos producidos por el movimiento de las extremidades Jayaraman et al. (2017).

2.1.6 Características del ECG

El electrocardiograma representa la actividad del corazón y en él se distinguen ondas, intervalos y segmentos. Una onda es una deflexión positiva o negativa con respecto a la línea isoeletrica o la línea horizontal. El ECG presenta seis ondas P, Q, R, S, T y U. Un segmento representa una pausa en la actividad eléctrica como el segmento PR y ST. Un intervalo es la combinación de un segmento con una o más ondas, estos son el intervalo PR y QT. Un complejo es la unión de varias ondas, como el complejo QRS. *Figura 1* Empendium (n.d.).

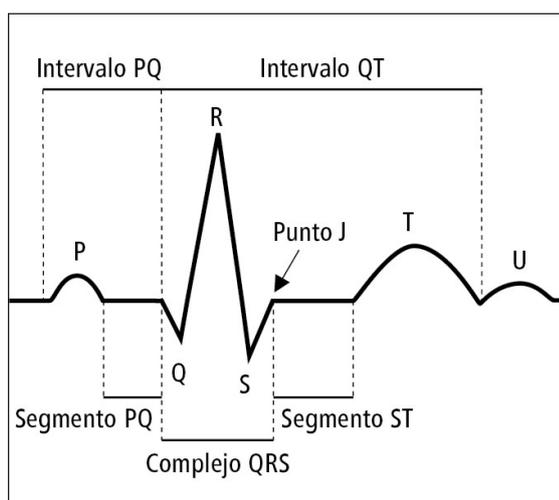


Figura 1. Ondas, segmentos e intervalos del pulso cardíaco de un corazón sano

La onda P representa la actividad auricular. El intervalo PQ, que va desde el inicio de la onda P hasta el comienzo del complejo QRS, representa el tiempo de conducción aurículo-ventricular. El segmento PQ se encuentra entre el final de la onda P y hasta antes del inicio del complejo QRS y representa una pausa fisiológica que se genera cuando un impulso eléctrico circula por el nodo aurículo-ventricular y las ramas del haz de His. El complejo QRS representa la despolarización de los ventrículos. La onda T representa la repolarización ventricular. Intervalo QT: va desde el inicio del complejo QRS hasta el final de la onda T y mide la despolarización y la repolarización ventricular. Segmento ST se da desde el final del complejo QRS hasta antes del inicio de la onda T. La onda U suele aparecer después de la onda T. El punto J es el final del complejo QRS. El intervalo RR representa la duración del ritmo cardiaco y se mide entre dos ondas R. M. A. Martínez & Morales (n.d.).

2.1.7 Tipos de arritmias

El proyecto esta enfocado a la clasificación de 7 tipos de arritmias cardíacas definidos en el estandar AAMI, el estudio de otro tipos de arritmias no está implementado. Las características morfológicas de las siguientes arritmias se toman de la segunda derivación de las extremidades modificada MLII.

Ritmo normal

Un latido normal, *Figura 4a*, visto es aquel que presenta todos sus segmentos, los cuales tener una duración promedio, y ondas que deben tener amplitudes y direcciones normales. Las características principales de un latido normal son:

- Ritmo cardiaco entre 60 y 100 pulsos por minuto (bpm)
- El complejo QRS debe estar precedido por una onda P normal positiva, es decir que apunta hacia arriba

- La duración del complejo QRS es de 60 a 100 milisegundos (ms)
- El intervalo PR es constante y no debe superar los 20 ms
- El segmento ST tiene una duración de 5 a 150 ms
- Al complejo QRS le sigue una onda T positiva

Contracción prematura auricular

La contracción prematura auricular (APC), *Figura 4d*, se caracteriza por un latido prematuro en la aurícula como su nombre lo indica y se origina en el nodo sinoauricular como un latido normal. Esto quiere decir que el latido empieza antes, causando una irregularidad en el ritmo cardiaco y el intervalo RR que presenta una menor duración. El latido posterior a una APC empieza después para compensar el adelanto, por lo que el intervalo RR aumenta. En ciertas ocasiones la onda T de un latido se combina con la onda P de una APC.

Contracción ventricular prematura

Una contracción ventricular prematura (PVC), *Figura 4e*, o extrasístole se caracteriza por un latido prematuro que se origina en las fibras de Purkinje, es decir en la zona ventricular del corazón, a diferencia de una APC. Las PVCs se originan en el ventrículo izquierdo o el ventrículo derecho cambiando su morfología. Las PVCs originadas en la izquierda presentan una onda R positiva mucho más grande que una normal. Cuando se originan en la derecha la onda R es negativa. Una PVC tiene una duración mucho mayor a un latido normal pues las fibras de Purkinje se despolarizan a una velocidad menor que el nodo sinoauricular.

Bloqueo de la rama

Este tipo de arritmia es causada por un bloqueo en el haz de His, sea en la rama derecha, *Figura 4c*, o en la rama izquierda, *Figura 4b*. Un bloqueo impide el paso del impulso eléctrico por el sistema de conducción. Cuando una rama se bloquea, la contracción de los ventrículos se ve afectada; uno de los ventrículos se contraerá normalmente mientras que el otro se demorará más tiempo en contraerse. Un bloqueo de la rama derecha (RBBB) presenta una onda S ensanchada y grande. Un bloque de la rama izquierda (LBBB) presenta una onda R ensanchada y una onda T negativa.

Latidos fusionados

Los latidos fusionados, *Figura 4g*, se producen cuando dos nodos, uno auricular y otro ventricular, del corazón se disparan al mismo tiempo, produciendo impulsos eléctricos desde las aurículas y desde los ventrículos. La combinación de impulsos origina latidos complejos que presentan características de varios tipos de latidos.

2.2 Segmentación del ECG

La segmentación del ECG en latidos individuales es el proceso previo necesario para la extracción de características y clasificación. Los algoritmos de segmentación se basan en la detección de puntos de referencia, e.g. picos de ondas R, P, T. Existen varios métodos para segmentar el ECG que tienen un bajo índice de detección en ciertos tipos de arritmias cardiacas, ya que su morfología aberrada dificulta la detección de sus puntos de referencia.

2.2.1 Algoritmos de segmentación

En 1985 Jiau Pan y Willies J. Tompkins idearon un algoritmo que hace uso de un filtro derivativo, un integrador de ventana móvil, una transformación no lineal y un algoritmo de toma de decisiones para detectar la posición de las ondas R Tompkins & Pan (1985).

Laguna et al. Laguna et al. (1994), desarrollaron un algoritmo basado en un filtro derivativo, que resalta el complejo QRS y provee información de la pendiente de la onda R. Los puntos de referencia se identifican usando umbrales adaptativos. Los picos de las ondas de la señal original se toman de los cruces por cero de la señal derivada.

Un algoritmo desarrollado por Martinez et al. J. Martínez et al. (2004) usa la transformada de Wavelet diádica que resalta el complejo QRS, la onda P y la onda T, filtrando ruido y otros artefactos. Se aplican umbrales adaptativos para obtener los puntos de referencia.

El uso de filtros pasa bajos recursivos y la primera derivada de la señal para resaltarla fue implementado en el algoritmo de Singh et al. Singh & Gupta (2008). El algoritmo detecta picos en las ondas y dibuja líneas que van desde cada pico hasta la base. Las ondas se detectan encontrando el desplazamiento vertical máximo que existe entre las ondas y las líneas definidas.

Sun et al. Sun et al. (2005) desarrollaron un algoritmo que utiliza la derivada morfológica multiescala. Los puntos máximos y mínimos de la señal resultante se toman como potenciales puntos de referencia que representan los picos de cada onda y sus límites. Umbrales adaptativos se utilizan para detectar máximos locales, estos representan los picos de cada onda.

Un método para la segmentación del ECG usando fasores fue desarrollado por Martínez et al. A. Martínez et al. (2010). El algoritmo transforma cada muestra tomada del ECG en un fador, maximizando los puntos máximos de cada onda. Se deriva la señal fasorial para encontrar los límites de las ondas P y T. Los puntos máximos de la señal derivada se toman como los picos de las ondas P y T, mientras que los cruces por cero se toman como los límites.

Hughes et al. Hughes et al. (2002) desarrollaron un algoritmo que emplea la transformada de Wavelet discreta para resaltar las ondas del ECG. Después se aplica un modelo oculto de Markov entrenado para identificar puntos de referencia.

Elgendi et al. Elgendi et al. (2015) desarrollaron un algoritmo para la detección de ondas T usando dos medias móviles y umbrales adaptativos después de remover el complejo QRS. Al remover el complejo QRS la onda predominante del ECG es la onda T.

2.3 Técnicas de análisis de datos

2.3.1 Análisis de componentes independientes

El análisis de componentes independientes (ICA) es un método estadístico para obtener componentes ocultos dentro de un grupo de variables o señales. ICA se puede relacionar con el algoritmo de BSS (separación de fuentes ciega), en el cual se descompone una señal como una combinación lineal de fuentes originales. En el caso de ICA las fuentes originales son denominadas componentes independientes Hyvärinen & Oja (2000). ICA puede ser explicado usando como ejemplo del problema del coctel. En una sala se encuentran dos hablantes. Se tienen dos micrófonos situados en distintos sitios dentro de la sala. Al grabar la conversación usando los dos micrófonos se obtienen dos grabaciones de la conversación. Como cada micrófono está situado en una posición diferente del otro, cada señal grabada es diferente. Esto quiere decir que cada micrófono capta la voz de cada hablante de diferentes maneras, pues el

sonido se demora más o menos en llegar a cada micrófono. Se puede representar cada señal matemáticamente de la siguiente manera.

$$x_1 = a_1s_1 + a_2s_2$$

$$x_2 = b_1s_1 + b_2s_2$$

Siendo s_1 y s_2 las voces de cada hablante respectivamente, x_1 y x_2 las señales grabadas de cada micrófono y a_1, a_2, b_1 y b_2 como los coeficientes que representan la distancia a la que se encuentra cada micrófono de los hablantes Bee & Micheyl (2008). El objetivo de ICA es el de encontrar las fuentes s_1 y s_2 teniendo como datos únicamente las grabaciones x_1 y x_2 .

2.3.2 Análisis de componentes principales

El análisis de componentes principales (PCA) es un método estadístico cuyo objetivo es la compresión o reducción dimensional de un gran conjunto de datos. PCA genera un nuevo conjunto de datos, los cuales no tienen correlación, de menor dimensión que el conjunto original Jolliffe (2002). Los componentes principales son el resultado de una combinación lineal del conjunto de datos.

2.3.3 Descomposición de modo empírico

La descomposición de modo empírico (EMD) es un algoritmo que descompone señales no estacionarias en funciones de modo intrínseco (IMF). Las IMFs representan las oscilaciones de la señal y están definidas por los cruces por cero de la misma. Cada IMF comprende solo una frecuencia de oscilación Huang et al. (1998). El resultado de aplicar EMD es el siguiente:

$$x(t) = \sum_n x_n(t) + r(t)$$

donde $x(t)$ es la señal, $x_n(t)$ es la n -ésima IMF y $r(t)$ es el residuo.

2.4 Medidas estadísticas

2.4.1 Media

La media aritmética es el promedio de un conjunto de datos. Se puede definir como una medida de posición central Universo Formulas (2016).

2.4.2 Varianza

La varianza es una medida de dispersión de los datos de un conjunto con respecto a su media López (n.d.).

2.4.3 Asimetría estadística

Es una medida que indica la simetría que existe en una distribución estadística de los valores de la variable con respecto a la media. Se puede decir que la asimetría indica si existe la misma cantidad de elementos a la derecha e izquierda de la media *Asimetría y curtosis* (2014).

2.4.4 Apuntamiento o Curtosis

Esta medida indica la cantidad de valores que se acumulan cerca de la media del conjunto de datos. La distribución de referencia es la distribución normal o la campana de Gauss que tiene un valor de curtosis nulo. Una distribución es más escarpada mientras tenga una curtosis mayor que cero Salinas (2011).

2.5 Clasificación de arritmias cardíacas

La clasificación es el proceso de predecir el tipo de arritmia a partir de las características extraídas. Para este proceso se utilizan clasificadores basados en redes neuronales artificiales (ANN), máquinas de soporte vectorial (SVM), árboles de decisión, el método de los k vecinos más próximos (k-NN), etc.

2.5.1 Técnicas de clasificación

Salah Salah (2015) diseñó un sistema de clasificación para los tipos de arritmias normales (N), prematuras ventriculares (PVC), prematuras auriculares (APC), fusión (F) y bloqueo de rama derecha (RBBB); extrayendo características con la transformada de Wavelet y usando un mapa autoorganizado de Kohonen para la clasificación. Alcanzó una exactitud promedio de 94.97 %.

Wang et al. Wang et al. (2013) diseñó un esquema de clasificación de arritmias utilizando PCA y análisis discriminante lineal para la extracción de características y redes neuronales probabilísticas para la clasificación. Los tipos de arritmias cubiertos son: N, PVC, APC, RBBB, LBBB y latidos de marcapasos, con una exactitud promedio del 99.71 %.

Ghorbani et al. Ghorbani et al. (2016) propusieron un método de clasificación de arritmias cardíacas basado en la extracción de características morfológicas y temporales. Para la clasificación se utilizó el modelamiento de mezcla gaussiano con una exactitud promedio del 99.70 % para 7 tipos de arritmias: N, LBBB, RBBB, APC, PVC, F y latidos no clasificados.

Castillo et al. Castillo et al. (2011) diseñaron un sistema para la clasificación de 5 tipos de arritmias: N, LBBB, RBBB, PVC y F. Utilizaron 3 métodos de clasificación: KNN con lógica difusa, red neuronal entrenada con retropropagación y otra red neuronal entrenada con retropropagación de gradiente conjugado. Finalmente un sistema de inferencia difuso de tipo Mamdani fue usado para combinar las salidas de los 3 métodos de clasificación. Alcanzó una exactitud promedio del 98 %.

Los hermanos Saini Saini & Saini (2012) diseñaron un método basado en redes neuronales artificiales para la clasificación de 5 tipos de arritmias: N, LBBB, RBBB,

APC y latidos de marcapasos alcanzando una exactitud promedio del 98 %.

Elhaj et al. Elhaj et al. (2016) propusieron un método basado en la extracción de características lineales y no lineales y usaron redes neuronales artificiales y SVMs para la clasificación de 5 tipos de arritmias: N, APC, PVC, F y latidos no clasificados. El sistema alcanzó una exactitud promedio del 98.91 %.

Li et al. Li et al. (2016) propusieron un sistema para la clasificación de arritmias usando ICA y la transformada de Wavelet para la extracción de características y SVM para la clasificación de 5 tipos de latidos: N, LBBB, RBBB, APC y PVC, alcanzando una exactitud promedio del 98.8 %.

Khalaf et al. Khalaf et al. (2015) diseñaron un sistema para clasificar 5 tipos de latidos: N, LBBB, RBBB, APC, PVC. La correlación espectral se usó para extraer características y SVM para la clasificación. El sistema alcanzó una exactitud promedio del 98.60 %.

Übeyli Übeyli (2009) propuso un método de clasificación de arritmias basado en el método de Pisarenko para la extracción de características y redes neuronales recurrentes para la clasificación. Alcanzó una exactitud del 98.06 %.

A continuación se presenta en la **Tabla 1**, una comparativa de los resultados de los métodos y sistemas mencionados.

2.6 Redes neuronales artificiales

Una red neuronal es un conjunto de neuronas artificiales interconectadas entre sí. Al igual que en un cerebro biológico, las neuronas artificiales, o perceptrones, cambian su estado de salida dependiendo de sus entradas.

Tabla 1
Comparativa de resultados obtenidos de los métodos investigados

Autor	Exactitud	Sensitividad	Especificidad	Precisión
Salah	94.97 %	95.36 %	96.99 %	95.04 %
Wang et al.	99.61 %	89.94%	98.27 %	99.43 %
Ghorbani et al.	99.17 %	93.3 %	88.96 %	97.58 %
Castillo et al.	97.33 %	98.7 %	96.66 %	99.31 %
Saini	98 %	98 %	99.5 %	97.79 %
Elhaj et al.	98.91 %	98.91 %	97.85 %	98.90 %
Li et al.	98.80 %	98.50 %	99.69 %	98.91 %
Khalaf et al.	98.6 %	99.2 %	99.7 %	99.9 %
Übeyli	98.06 %	98.06 %	99.34 %	98.6 %

Las redes neuronales son usadas en problemas de inteligencia artificial, como el *Deep Learning* o *Machine Learning*. Existen muchas clases de redes neuronales dependiendo del tipo de interconexión entre sus perceptrones. La configuración utilizada para este clasificador se denomina Red Neuronal directa. Este tipo de red neuronal consiste en capas de perceptrones conectadas una después de la otra como se muestra en la **Figura 2**. Las capas más comunes en este tipo de redes neuronales son tres: la capa de entrada, la capa oculta y la capa de salida.

2.6.1 Perceptrón

La unidad fundamental de una red neuronal es el perceptrón. El perceptrón funciona como una neurona artificial; combina sus entradas para producir una única salida. Cada entrada x_i tiene asignada un peso w_i , las entradas se suman y se evalúan con una función de activación que mantiene la salida en un rango, e.g. (0,1). Para mantener la salida en un rango (0,1) o (-1,1) se utilizan funciones sigmoideas Nielsen (2018).

$$y = sig(\sum x_i w_i + b)$$

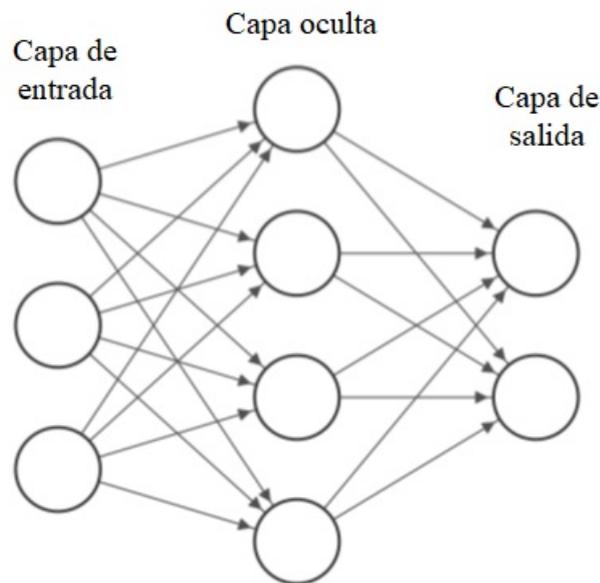


Figura 2. Red neuronal artificial directa de tres capas de perceptrones.

donde y es la salida, b es un sesgo y $sig()$ es una función de activación sigmoide. La función de activación del clasificador es la tangente hiperbólica, que mantiene la salida entre -1 y 1.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{2}{1 + e^{-2x}} - 1$$

2.6.2 Entrenamiento

Las redes neuronales se entrenan usando entradas de prueba y estableciendo las salidas para cada entrada, llamadas objetivos. Ajustando los pesos y sesgos de los perceptrones se consigue que la salida tenga un valor deseado. Los algoritmos de entrenamiento modifican y ajustan los pesos y sesgos de una red neuronal. El ajuste se repite hasta que la salida se encuentre lo más próxima posible al objetivo.

El algoritmo de entrenamiento usado en el clasificador es el método Rprop (retropropagación resistente). Los algoritmos de retropropagación se centran en la disminución de una función de error, a esto se le llama el problema de aprendizaje. Esta función de error se calcula restando el objetivo de la salida, la cual es producto

de la ecuación del perceptrón. Los pesos que minimizan la función de error son la solución del problema de aprendizaje. Para minimizar la función de error se emplea el método del descenso del gradiente, con el cual se deriva la función de error para encontrar la dirección que la minimiza basándose en su pendiente. Las funciones de activación deben ser derivables para poder hallar su gradiente, por esto se usan funciones sigmoides Rojas (1996).

El algoritmo Rprop se reduce a una toma de decisiones basado en el signo del gradiente pues este indica la dirección de la minimización para definir un valor de actualización de los pesos. Después de saber la dirección, se evalúa si hubo un cambio de signo reciente en el gradiente. Cuando el gradiente cambia de signo se reduce el valor de actualización por un factor η^- ; si no, se incrementa por un factor η^+ . El valor de $\eta^- = 0,5$ y $\eta^+ = 1,2$ Riedmiller (1994).

CAPÍTULO III

Desarrollo del algoritmo de detección y clasificación de arritmias

3.1 Introducción

El diagrama de bloques del algoritmo para la clasificación de arritmias se muestra en la *Figura 3*. El sistema se basa en la extracción de características del ECG para su posterior clasificación con una red neuronal artificial (ANN). El sistema consta de tres bloques principales: procesamiento de las señales ECG, extracción de características y clasificación.

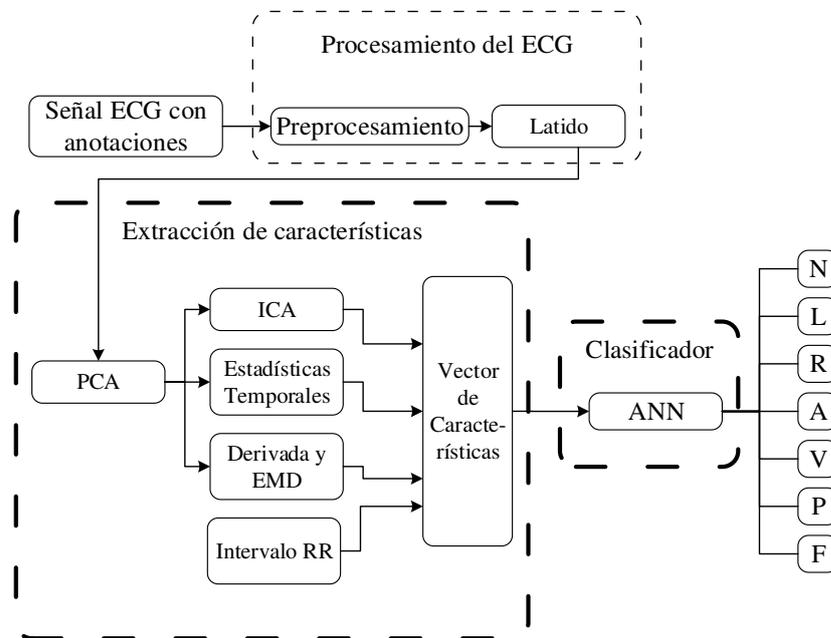


Figura 3. Diagrama de bloques general del sistema de clasificación de arritmias.

3.2 Bases de datos

La base de datos de a arritmias de Physionet, MIT-BIH, cuenta con 47 registros de 24 horas de duración del ECG y pueden ser descargadas del siguiente enlace: <https://physionet.org/content/mitdb/1.0.0/>. Los registros de la base de datos MIT-BIH contienen dos señales tomadas de dos derivaciones. En la mayoría de registros predomina la derivación V2 modificada en una de las dos señales por lo que

todo el sistema está basado en esta derivación. Los registros que estén tomadas de otras derivaciones no se utilizan debido a la diferencia morfológica de los latidos.

Cada grabación contiene tres señales importantes, la primera contiene la grabación del ECG muestreada a 360 Hz, digitalizada con una resolución de 11 bits en un rango de 10mV. La segunda contiene anotaciones de medicos especializados y marcan la posición de cada tipo de arritmia en la grabación, esta posición corresponde al pico de la onda R. La última señal contiene los intervalos RR de todos los latidos empezando desde el primero. Es decir, el primer intervalo RR de la señal es el intervalo entre el segundo y primer latido. Tomando como ejemplo la grabación ECG 100, esta contiene 2273 latidos en total; de los cuales 2239 son de tipo N, 33 son de tipo A y uno es de tipo V. Las anotaciones se utilizan en el sistema para etiquetar todos los latidos segmentados para el entrenamiento de la red. También se utiliza la base de datos desarrollada por Elgendi et al. que contiene anotaciones para los picos de las ondas P y las ondas T, necesarias para la segmentación de los latidos.

En este trabajo se desarrollaron nuevas bases de datos a partir de las bases de datos mencionadas. Usando la base de datos de Elgendi et al. se pudo segmentar el ECG de los registros de la base de datos MIT-BIH. Finalmente utilizando los archivos atr, que contienen las anotaciones de los tipos de arritmias en cada grabación, se etiquetaron todos los latidos segmentados y tambien se extrajeron los intervalos RR anterior y posterior. Como resultado de este proceso el primer y ultimo latido de los registros fueron desechados. Se debe tomar en cuenta que en la base de datos de Elgendi et al. existen latidos que presentan solo un punto, que puede ser la onda P o la onda T. Estos latidos también se desecharon para evitar errores. Se creó una nueva base de datos para cada grabación que contiene los latidos, sus etiquetas, intervalos RR y amplitudes de las ondas R, P y T. Finalmente se crearon 7 nuevas bases de datos para cada tipo de latido usando la base de datos anterior.

Se desarrolló un algoritmo para la segmentación de latidos tomando como referencia las anotaciones de la base de datos MIT-BIH y la base de datos de Elgendi. De todos los tipos de arritmia de la base de datos MIT-BIH, solo fueron seleccionados los englobados por el estándar AAMI y se muestran en la **Tabla 2**. Finalmente se crearon 7 bases de datos, una para cada tipo de arritmia, las cuales contienen latidos y los intervalos RR. Los tipos de arritmias se muestran en la **Figura 4**.

Tabla 2
Tipos de latidos definidos en el estándar AAMI

AAMI	Normales	Ectópicos supra- ventriculares	Ectópicos ventriculares	Latidos Fusionados	No clasificados
Base de datos MIT BIH	Normales (N) RBBB (R) LBBB (L)	APC (A)	PVC (V)	Fusión (F)	Marcapasos (P)

Tipos de latidos que engloba el estándar AAMI en comparación a los tipos de latidos de la base de datos MIT-BIH utilizados.

3.3 Procesamiento de señales ECG

Las señales que ingresan al sistema son filtradas con un filtro Butterworth pasa banda con frecuencias de corte de $0,5Hz$ y $45Hz$, para eliminar la línea base y el ruido de la red de $60Hz$. Usando la transformada de wavelet se elimina el ruido de la señal filtrada.

Debido a la dificultad para segmentar el ECG que presenta arritmias se usó una base de datos libre desarrollada a partir de la propia base de datos MIT-BIH que contiene anotaciones de las ondas P y T de todos los registros Elgendi et al. (2015). Tomando los puntos de referencia P y T se desarrolló un algoritmo para la segmentación de los latidos, tomando en consideración que existen algunos latidos que presentan solo un punto de referencia sea de la onda T o la onda P. Los latidos extraídos

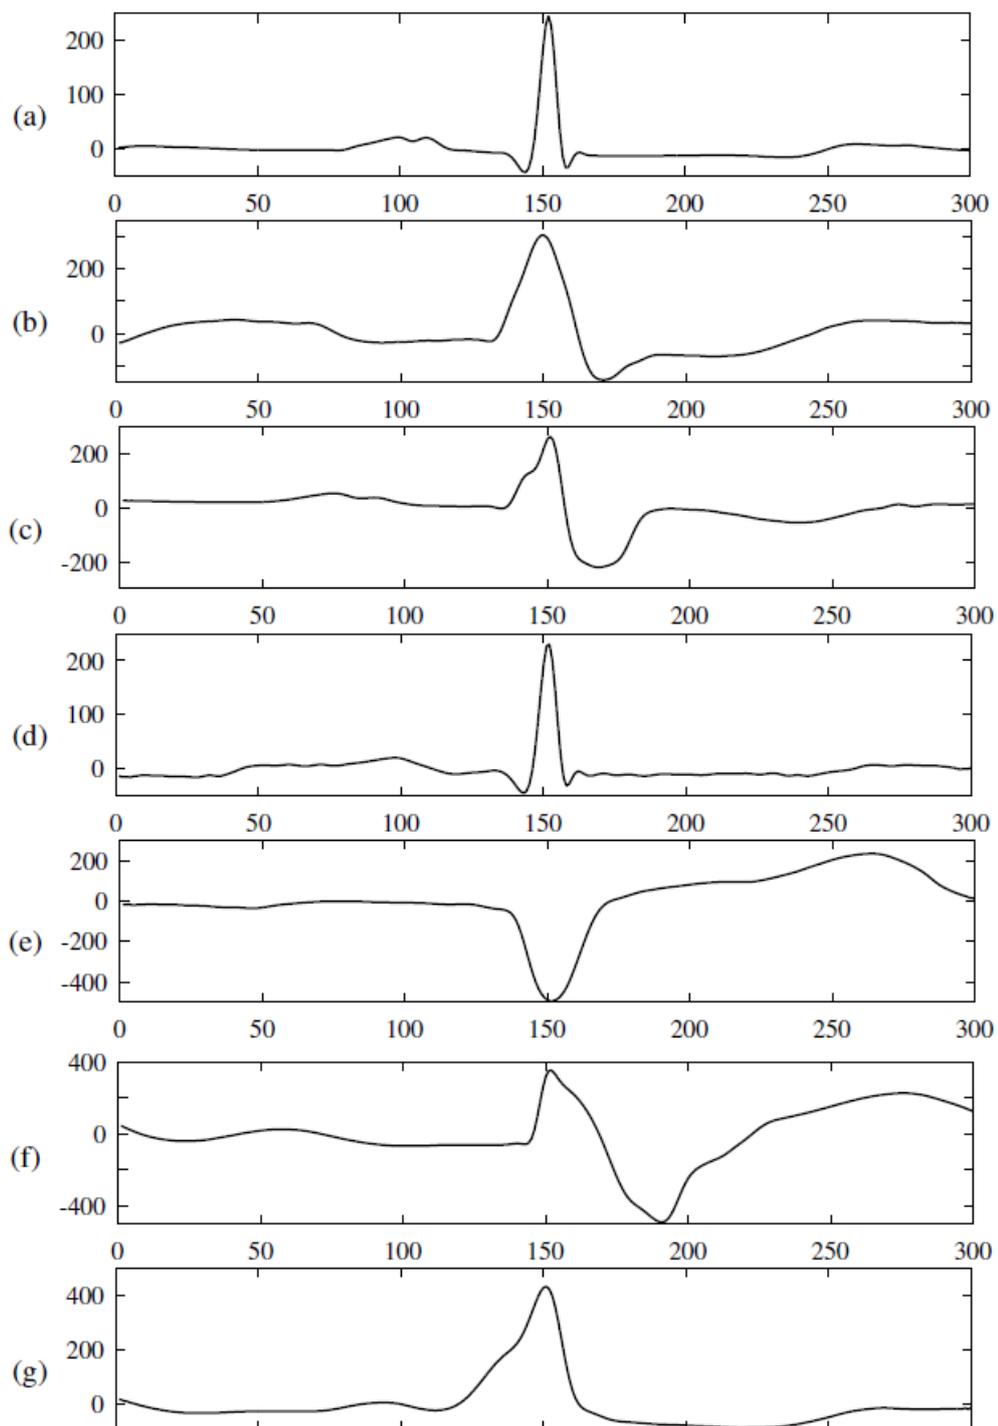


Figura 4. Tipos de arritmias tratados en el proyecto. (a) Latido normal. (b) LBBB. (c) RBBB. (d) APC. (e) PVC. (f) Latido de marcapasos (P). (g) Fusión (F)

son comparados con la base de datos MIT-BIH en relación a la posición de sus ondas R para determinar el tipo de arritmia anotada. Finalmente se extraen los intervalos RR anterior y posterior de cada latido de la base de datos. Los latidos son ahora un vector de tamaño variable y se llenan de ceros para alcanzar un tamaño específico, de esta manera pueden ser almacenados en una matriz. Se genera una matriz por cada grabación existente de la base de datos, en un total de 46.

Los ceros introducidos en el proceso de segmentación son eliminados de los vectores y se remuestrean. El remuestreo es una técnica que hace uso de la interpolación y la decimación para convertir la frecuencia de muestreo original a otra, dada la relación $R = L/M$, donde L es la frecuencia original y M es la frecuencia deseada; y se aplica un filtro pasa bajos como filtro anti-aliasing para eliminar componentes frecuenciales no deseados producto del remuestreo Porteous (1983). De esta manera el vector cambia de tamaño manteniendo su información morfológica original. El tamaño buscado se establece en 300 puntos. Se tiene una relación para el remuestreo donde $L = 300$ y M será igual al tamaño inicial del vector.

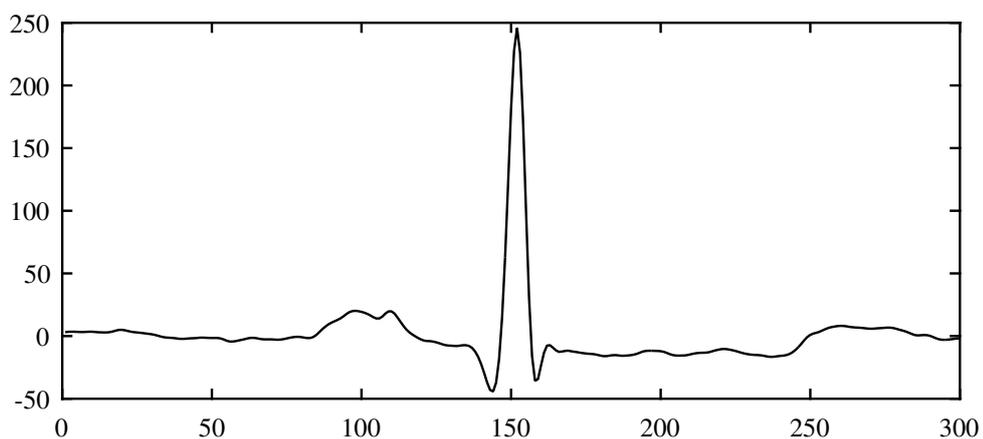


Figura 5. Latido normal filtrado con un filtro pasa banda Butterworth, frecuencia de corte inferior de 0.5Hz y frecuencia de corte superior de 45Hz.

Los latidos segmentados y remuestreados presentan un remanente de ruido como se muestra en la **Figura 5**, que se elimina con un método basado en PCA.

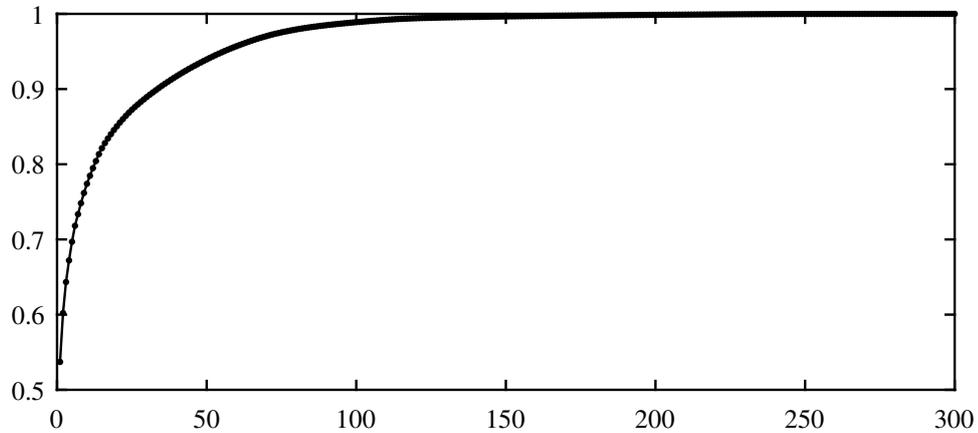


Figura 6. Eigenvalores acumulados del conjunto de latidos normales, donde 1 equivale al 100 % de la información que contienen.

Se aplica la descomposición en valores singulares (SVD), $M = U \times \Sigma \times V^T$ Baker (2005) a una matriz M que representa un set de latidos de cada clase de arritmias. La matriz Σ contiene los eigenvalores que representan los pesos de cada componente principal como se muestra en la **Figura 6**. La matriz U contiene los eigenvectores o los componentes principales del conjunto. Se puede evaluar la cantidad n de eigenvectores necesarios para contener al menos el 99 % de información de cada conjunto, a pesar de que en esta aplicación se utiliza solamente el 70 % para suavizar los latidos. Los componentes restantes se consideran ruido. La matriz U se reduce en sus n primeras columnas, se conoce a esta como la Matriz de Transformación W . Finalmente se reconstruye un nuevo conjunto usando los componentes principales escogidos $M_r = W \times W^T \times M$. El resultado del algoritmo se puede ver en la **Figura 7**.

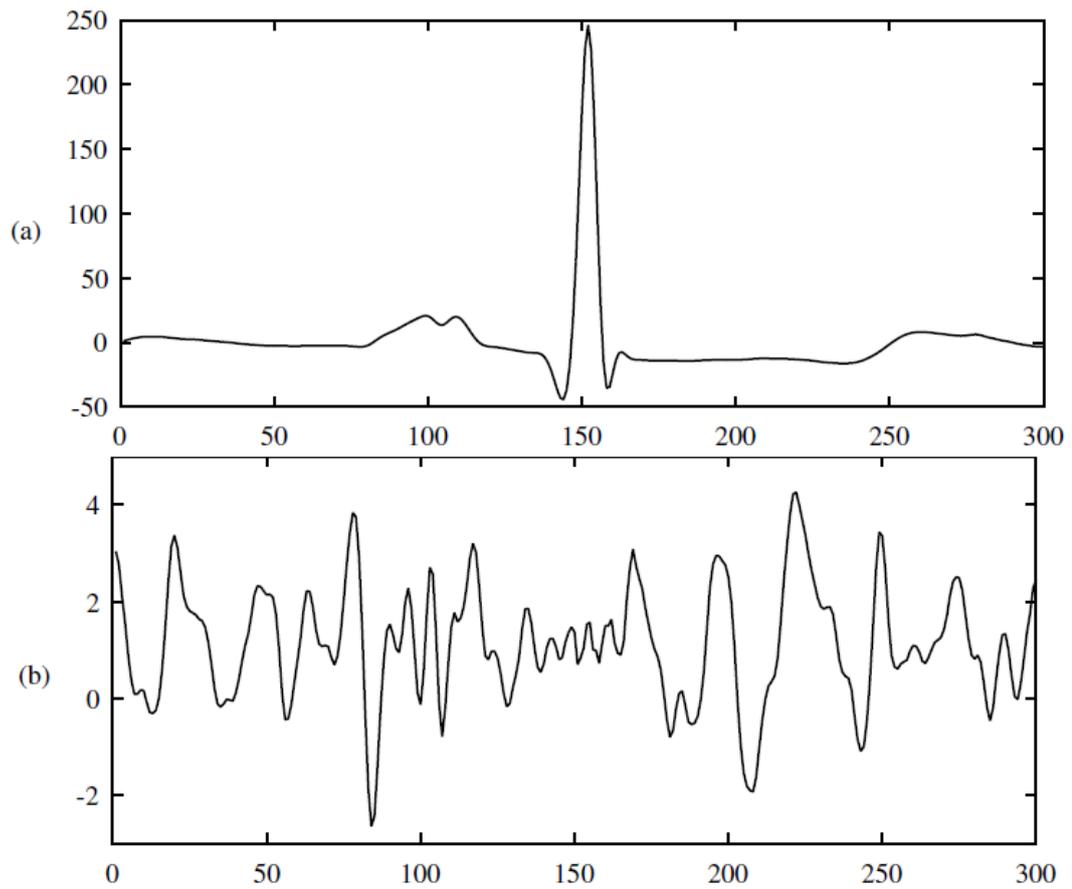


Figura 7. (a) Latido filtrado mediante PCA usando el 70 % de la información, tomando solo 20 componentes principales. (b) Componente 21 del conjunto de latidos que solo representa ruido. Las componentes restantes también representan ruido.

3.3.1 Latidos

Cada grabación de la base de datos MIT-BIH es preprocesada, se segmentan los latidos y se extraen el intervalo RR posterior y anterior. Para saber el tipo de latido que se segmenta se usan las anotaciones de la propia base de datos. Estas anotaciones están colocadas en la misma posición de los picos de las ondas R anotadas de la base de datos. Se construye una nueva base de datos de cada grabación. Posteriormente se construye una nueva base de datos para cada tipo de latido. Al final se construyen siete bases que contienen los latidos y sus intervalos RR. La cantidad de latidos se muestra en la **Tabla 3**.

Tabla 3
Cantidad de latidos extraídos

Latido	N	LBBB	RBBB	APC	PVC	P	F
Cantidad	28273	5048	6740	2075	3223	3528	765

3.4 Extracción de características

El fin de la extracción de características es la reducción de la dimensionalidad de un conjunto de datos. Es decir, se pretende representar un espacio vectorial con una selección o combinación de características que lo describen. Meyer-Baese & Schmid (2014). Los latidos pasan por un proceso de extracción del cual se generan nuevos vectores formados de 33 características como se muestra en la **Tabla 4**.

Tabla 4
Vector de características extraídas del ECG

Característica	Intervalo RR	ICA	Estadísticas	EMD
Cantidad	3	20	4	6

3.4.1 Análisis de Componentes Principales (PCA)

El sistema está diseñado para eliminar ruido presente en las señales sin filtrar que pudieran ingresar. El filtrado del proceso de la extracción de características está basado en PCA. La finalidad de este proceso es generar una matriz de transformación generalizada para los siete tipos de arritmias, con la cual se obtiene un nuevo latido libre de ruido.

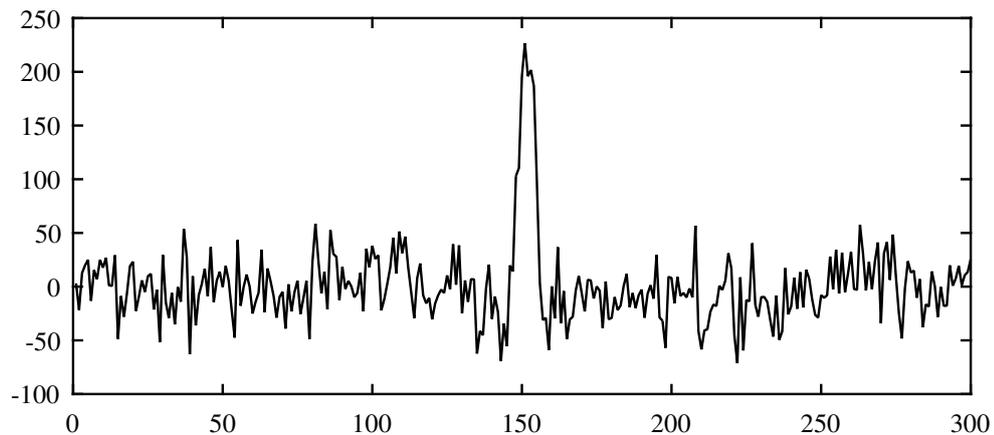


Figura 8. Latido normal con ruido gaussiano añadido en una relación señal a ruido $SNR = 5dB$.

A los latidos se les añade ruido blanco gaussiano con una relación señal a ruido $SNR = 2$. Un latido normal con ruido añadido se muestra en la **Figura 8**. Se reduce la dimensión de las bases de datos originales de cada tipo de latidos aplicando PCA. Se integran las bases reducidas en una sola y se vuelve a aplicar PCA esta vez para reducir a 14 componentes, estos componentes no contienen el ruido blanco añadido. La matriz de transformación creada de la segunda aplicación de PCA se utiliza para reconstruir nuevamente los latidos como se muestra en la **Figura 9**.

3.4.2 Análisis de Componentes Independientes (ICA)

ICA es un método estadístico para revelar características ocultas en sets de datos Hyvarinen et al. (2001). ICA esta relacionado con el método de separación de

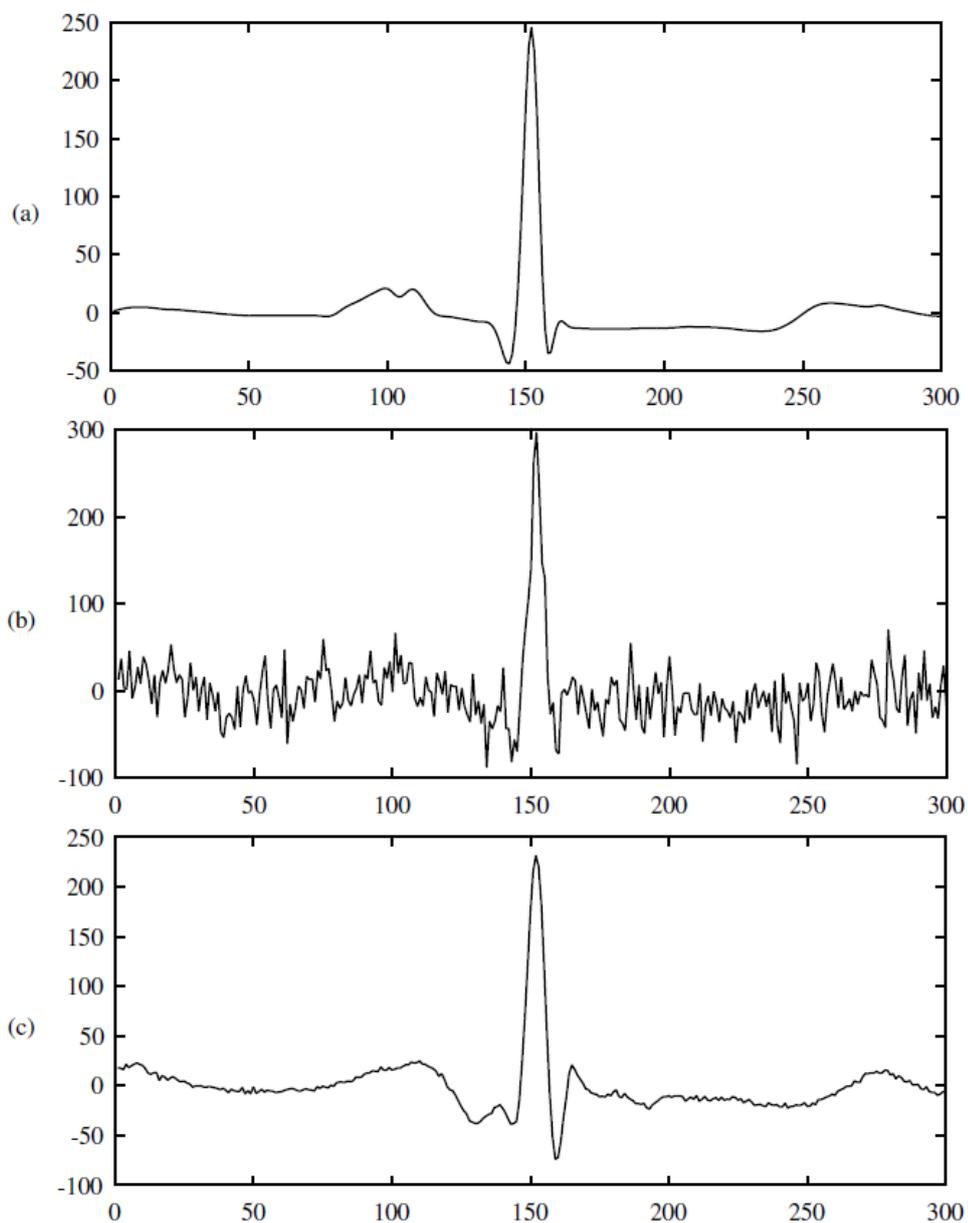


Figura 9. Comparativa de un latido con ruido añadido y reconstruido con PCA. (a) Latido libre de ruido blanco. (b) Latido con ruido blanco gaussiano añadido con una relación señal a ruido de 5 dB. (c) Latido reconstruido con la matriz de transformación obtenida después de aplicar PCA.

fuentes BSS y es usado en este sistema para hallar las señales o fuentes que forman el ECG de un latido normal. El problema del cocktail se toma como ejemplo para explicar la función de ICA Haykin & Chen (2005). El problema generalizado es el siguiente: se tienen dos observaciones de las combinaciones lineales de dos señales independientes. Sean las observaciones x_1 y x_2 ; y las señales independientes s_1 y s_2 tal que

$$x_1 = a_1 s_1 + a_2 s_2$$

$$x_2 = b_1 s_1 + b_2 s_2$$

donde a_1, a_2, b_1 y b_2 son escalares. El problema se reduce al cálculo de las fuentes s_1 y s_2 .

FastICA Gävert et al. (2005), es el toolbox utilizado para hallar los componentes independientes del ECG. El algoritmo emplea el método de estimación de máxima verosimilitud. El algoritmo busca parámetros que maximizan la densidad de probabilidad de las observaciones x Hyvarinen et al. (2001).

El proceso para aplicar ICA a un conjunto de observaciones de las señales ECG empieza por el centrado de las señales agupadas en una matriz, que es la remoción de la media:

$$x_c = x - \bar{x}$$

La matriz centrada pasa por otro proceso conocido como blanqueo. El blanqueo de una matriz produce otra matriz con varianza 1, sus elementos no están correlacionados.

$$x_w = W x_c$$

La matriz W se denomina matriz de blanqueo está dada por:

$$W = \sqrt{D} E^T$$

donde D es la matriz diagonal de los eigenvalores de x y E es la matriz que contiene los eigenvectores de x . FastICA se aplica sobre la matriz blanqueada.

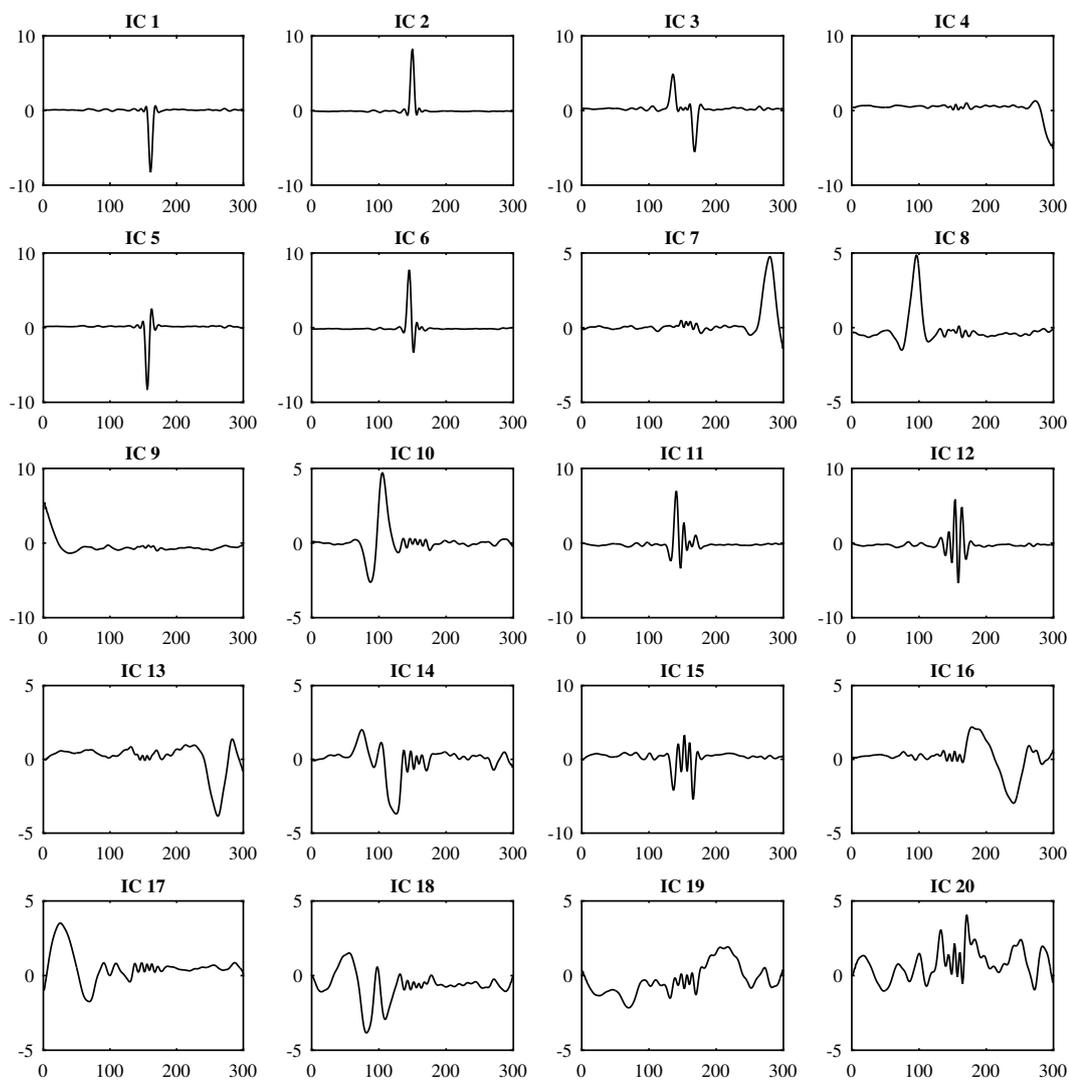


Figura 10. Componentes independientes de un conjunto de latidos normales calculados con el algoritmo FastICA. Cada componente independiente es una fuente y sumadas con ciertos pesos dan como resultado cualquier tipo de latido.

Se toma como matriz x el conjunto de latidos normales que contiene 28273 latidos. Es necesario reducir el tamaño del conjunto aplicando PCA. Se reduce la dimension del conjunto para pasar de 28273 hasta 20; se debe mencionar que solo se puede reducir el conjunto de datos en 20 o menos componentes, debido a que en el proceso de filtrado con PCA los conjuntos fueron reducidos en 20 componentes antes de ser reconstruidos. Los componentes principales no tienen correlación por lo que el proceso de blanqueo se omite. La nueva matriz se centra sustrayendo su media y se le aplica el algoritmo FastICA. Los componentes independientes de los latidos se pueden ver en la *Figura 10*.

Los latidos, x , se consideran como las observaciones de los componentes independientes s , por lo tanto x es una combinación lineal de s

$$x = As$$

$$x_1 = a_{1,1}s_1 + a_{1,2}s_2 + \dots + a_{1,20}s_{20}$$

donde A es la matriz de transformación lineal. Los elementos de A se denominan pesos. Estos pesos conforman el vector de características.

3.4.3 Derivada

La derivada de un latido provee información de la pendiente y es utilizada para realzar la información del complejo QRS Tompkins & Pan (1985). La derivada de una función continua $f(x)$ es:

$$f'(x) = \frac{f(x + \Delta x) - f(x)}{\Delta x}$$

Al ser $f(x)$ una función discreta, que representa a un latido muestreado, se toma $\Delta x =$

1. Se puede expresar la derivada discreta como

$$g(0)f(x + 1) + g(1)f(x)$$

donde $g(0) = 1$ y $g(1) = -1$ Tomasi (2003). Se expresa la derivada como la convolución de $g(x)$ con $f(x)$ como

$$f'(x) = (g * f)(x) = \sum_{k=-\infty}^{\infty} g(x) f(x - k)$$

$g(x)$ se conoce como filtro derivativo.

La derivada se aplica a un latido normal promediado de todos los latidos normales de la base de datos, se puede ver en la **Figura 11**.

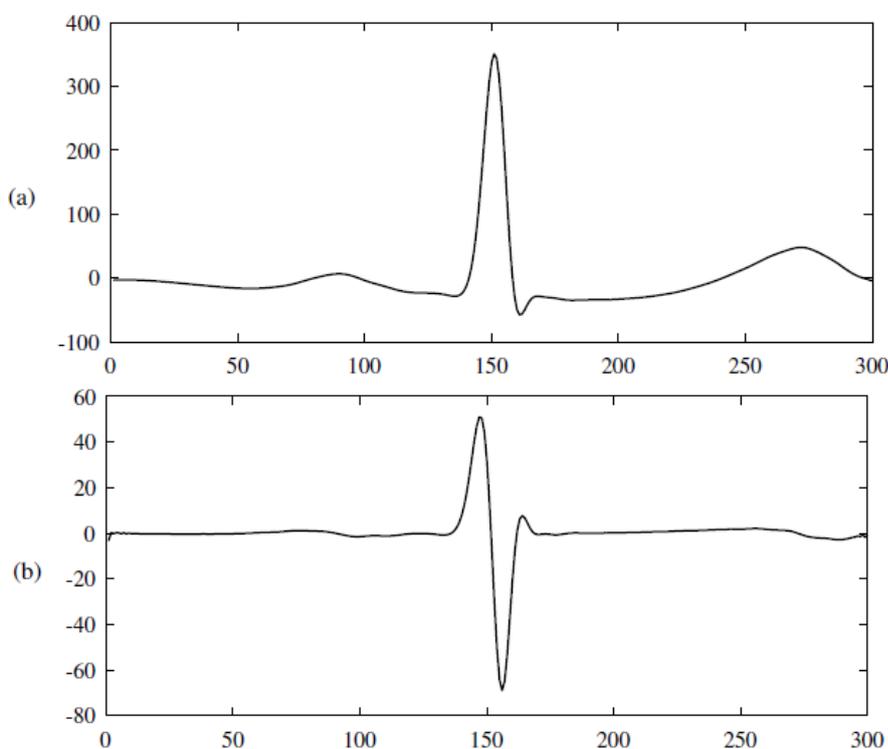


Figura 11. a) Latido promedio de la base de datos. b) Derivada del latido promedio.

Después de obtener la derivada del latido se aplica EMD (Descomposición de Modo Empírico) sobre la derivada. Las IMFs $x_n(t)$ obtenidas después de aplicar EMD se toman como funciones base de la derivada del ECG. Se establece una relación entre

las IMFs y la derivada, que es una combinación lineal de IMFs:

$$x(t) = Ax_n(t)$$

donde A es un vector de escalares o pesos. Estos pesos se toman como nuevas características y representan las oscilaciones intrínsecas de la derivada del ECG, la cual a su vez contiene información del complejo QRS. Las IMFs se muestran en la *Figura 12*.

3.4.4 Características temporales

Las últimas características del ECG se obtienen del cálculo de la media, la desviación estándar, la curtosis, el apuntamiento y los intervalos RR. 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:

$$r_n = \frac{R_n}{\bar{R}}$$

Donde r_n es el intervalo RR normalizado, R_n es un intervalo RR expresado como la distancia entre los puntos de las ondas R y \bar{R} es la media de los intervalos RR para un paciente en específico. Los intervalos RR normalizados se reducen, i.e. se dividen para su desviación estándar. Se puede dividir la base de datos general en dos grandes grupos de latidos prematuros y no prematuros. Dentro de los latidos prematuros se encuentran las clases A, V y ciertos latidos de la clase F. Las clases N, L, R, P son latidos no prematuros. Se halla la media de las desviaciones estándar para los tipos de latidos prematuros y no prematuros y se presentan en la **Tabla 5**. Se halla la relación r entre ambos intervalos RR:

$$r = \frac{R_2}{R_1}$$

Los latidos prematuros tienen una relación mayor a 1.2 porque su intervalo RR posterior (R_2) siempre es mayor que el intervalo RR anterior (R_1). Dada la relación r se elige un valor de la desviación estándar calculada para generar las nuevas características.

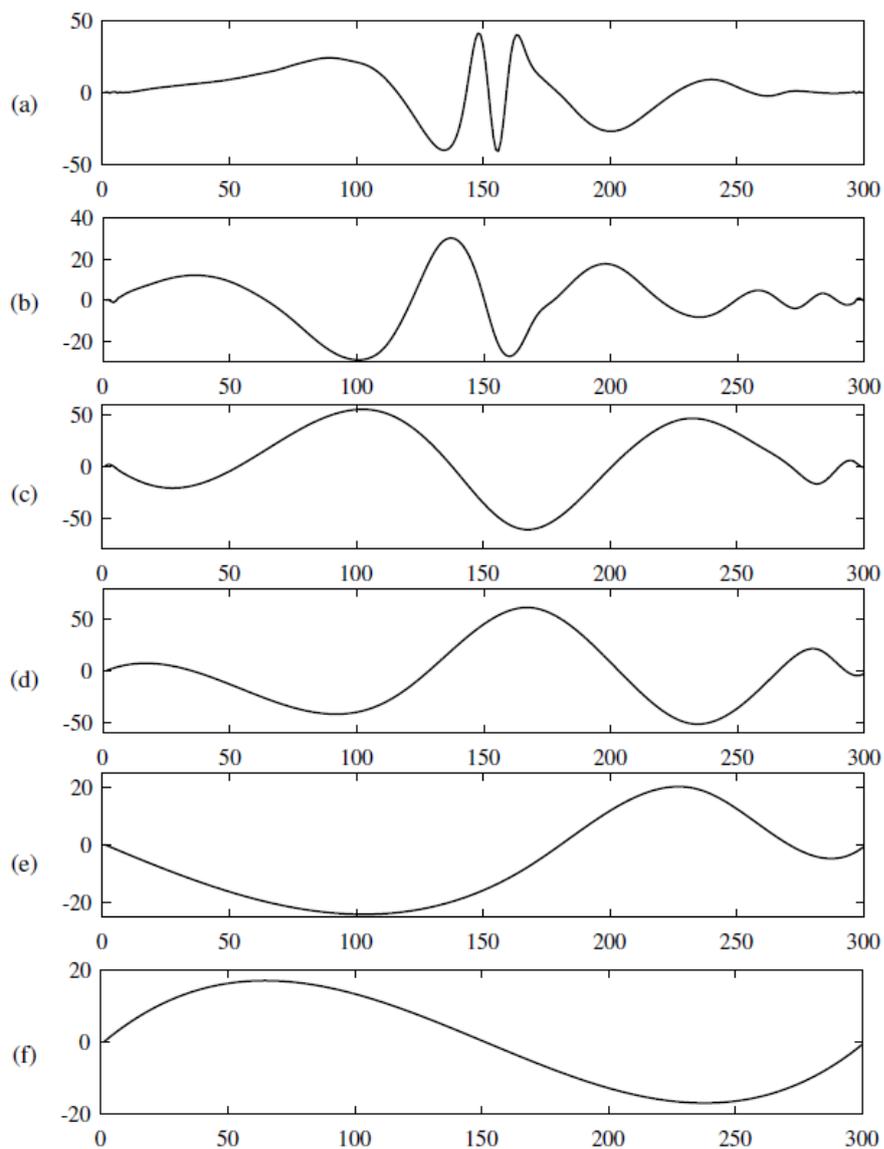


Figura 12. Funciones de modo intrínseco (IMF) de la derivada de un latido normal. Las imfs son fuentes que sumadas con ciertos pesos dan como resultado las derivadas de cualquier tipo de latido.

Tabla 5
Desviación estándar de intervalos RR

Desviación estándar (σ)	R_1	R_2
Prematuro	0.083	0.465
No prematuro	0.166	0.161

Valores de la desviación estándar para latidos prematuros y no prematuros. R_1 es el intervalo RR con el latido anterior y R_2 es el intervalo RR con el latido posterior.

3.5 Clasificador

La clasificación de los latidos se logra gracias a una red neuronal artificial. Las 33 características ingresan a la red neuronal y mediante sus 7 salidas se indica que tipo de arritmia coincide con las características ingresadas. Las redes neuronales están formadas por perceptrones y se deben entrenar con algoritmos de aprendizaje para que funcionen adecuadamente. Las salidas del clasificador son binarias, i.e. 1 y 0, donde 1 es verdadero y 0 es falso. Esto quiere decir que cuando una salida se encuentra en 1, las demás salidas deben ser 0. De esta manera se logra la clasificación de las siete clases de arritmias.

3.5.1 Arquitectura del clasificador

La red neuronal está formada por cuatro capas de neuronas: capa de entrada, dos capas ocultas y capa de salida. La capa de entrada contiene 33 neuronas, las dos capas ocultas contienen 80 neuronas y la capa de salida contiene 7. En la **Figura 13** se muestra la arquitectura de la red neuronal. Esta es una arquitectura directa, en la que cada capa anterior se conecta con la capa siguiente.

Esta arquitectura de redes neuronales es la más sencilla de implementar y se consiguen buenos resultados cuando los datos están libres de ruido. La desventaja de la arquitectura directa es la cantidad de neuronas que se generan cuando un problema

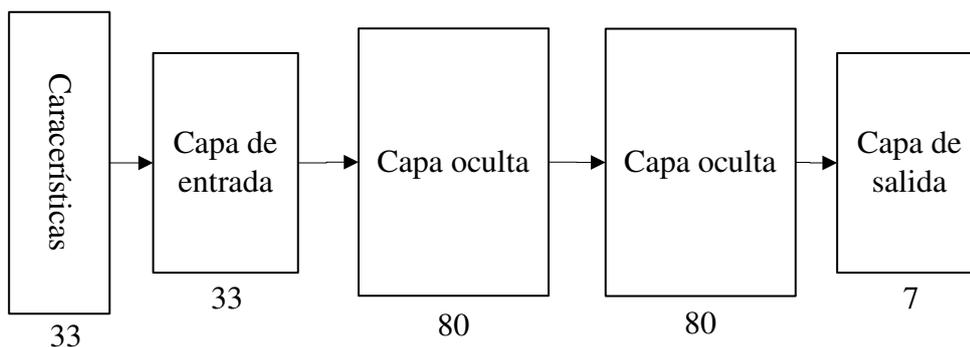


Figura 13. Arquitectura de la red neuronal usada como clasificador de arritmias cardíacas.

de clasificación es demasiado complejo Svozil et al. (1997). Es por esto que solo se extraen 33 características del ECG para evitar la necesidad de generar una gran cantidad de neuronas. Así se consiguen tiempos de entrenamiento más cortos y junto con el algoritmo de entrenamiento Rprop el tiempo de entrenamiento del clasificador fue de aproximadamente 40 segundos. La función de activación de la capa de entrada y las capas ocultas es la función tangente hiperbólica \tanh . La capa de salida necesita la función de activación softmax porque la clasificación es multi-clase. Esta función calcula la probabilidad de cada clase en las salidas de la red neuronal de la siguiente manera:

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}}$$

donde x_i es el valor numérico de la clase i y x_j son los valores numéricos de todas las clases.

Las salidas de la red neuronal están ordenadas como se muestra en la **Tabla 6**

Tabla 6
Clases del clasificador y tipos de arritmias asociados.

Clase	1	2	3	4	5	6	7
Tipo	N	L	R	A	V	P	F

3.5.2 Entrenamiento del clasificador

El clasificador fue entrenado con la base de datos desarrollada en este trabajo. El 70 % de todos los latidos fue utilizado para el entrenamiento y el 30 % restante fue utilizado para la validación de la red neuronal. En la **Tabla 7** se presenta la matriz de confusión obtenida de los latidos de las bases de datos desarrolladas.

Tabla 7
Matriz de confusión del clasificador

Clase	N	L	R	A	V	P	F
N	28242	2	3	13	1	0	48
L	0	5042	1	1	2	0	6
R	1	1	6733	1	1	0	1
A	9	0	2	2054	8	0	1
V	1	3	1	5	3202	0	7
P	0	0	0	0	0	3528	0
F	20	0	0	1	8	0	702

Matriz de confusión del clasificador sobre la señal original filtrada y procesada.

3.6 Entrenamiento sobre latidos con ruido

El sistema está diseñado para trabajar con latidos con una relación señal a ruido máxima de 5 decibelios.

$$SNR = 5 = 10 \log_{10} \left(\frac{P_{latido}}{P_{ruido}} \right)$$

Se debe tomar en cuenta que en pruebas anteriores se determinó que la relación señal a ruido (SNR) de los latidos usados para el entrenamiento de la red es mayor a 60. Mientras la SNR es más alta, existe menos ruido contaminando la señal, por lo tanto la señal es de mayor calidad.

Gracias al método de filtrado basado en PCA que se aplica antes de la extracción de características, es posible remover la mayor cantidad de ruido de los latidos a costa de un cambio en su morfología. En la **Tabla 8** y **Tabla 9** se presentan las métricas del clasificador para distintos niveles de ruido. Se aprecia en la disminución de las métricas del clasificador, para una $SNR = 10dB$ y para una $SNR = 5dB$. La disminución de la exactitud promedio es de 0.07 % y 0.37 %. En la **Tabla 9** se ve que la sensibilidad y precisión de la clase F disminuyen considerablemente. A pesar del alto nivel de ruido el sistema se mantiene estable.

Tabla 8
Métricas de desempeño del clasificador

Clase	Exactitud	Sensitividad	Especificidad	Precisión
N	99.69 %	99.77 %	99.59 %	99.69 %
L	99.91 %	99.54 %	99.96 %	99.60 %
R	99.90 %	99.45 %	99.97 %	99.78 %
A	99.86 %	98.99 %	99.89 %	97.62 %
V	99.82 %	98.70 %	99.90 %	98.61 %
P	100 %	99.94 %	100 %	100 %
F	99.70 %	86.67 %	99.90 %	93.12 %
Promedio	99.84 %	97.58 %	99.88 %	98.35 %

Métricas de desempeño para una relación señal a ruido de 10 dB.

3.7 Gráficas de características extraídas

Los latidos se pueden separar en dos grandes grupos, prematuros y no prematuros. La característica principal de los latidos prematuros es la relación entre el intervalo RR posterior y anterior, relación RR. Los latidos no prematuros tienen una relación RR de 1, mientras que los latidos prematuros tienen una relación RR mayor a 1,2. Como se puede ver en la **Figura 14**, los intervalos RR no son suficientes para lograr la separabilidad de todas las clases.

La separación de clases se consigue gracias a la combinación de las demás

Tabla 9
Métricas de desempeño del clasificador

Clase	Exactitud	Sensitividad	Especificidad	Precisión
N	99.7 %	99.15 %	99.18 %	99.38 %
L	99.72 %	98.21 %	99.89 %	99.08 %
R	99.41 %	96.70 %	99.84 %	98.98 %
A	99.48 %	97.92 %	99.55 %	90.59 %
V	99.63 %	97.45 %	99.78 %	96.91 %
P	99.97 %	99.74 %	99.99 %	99.88 %
F	99.39 %	79.47 %	99.70 %	80.95 %
Promedio	99.54 %	95.52 %	99.7 %	95.11 %

Métricas de desempeño para una relación señal a ruido de 5 dB.

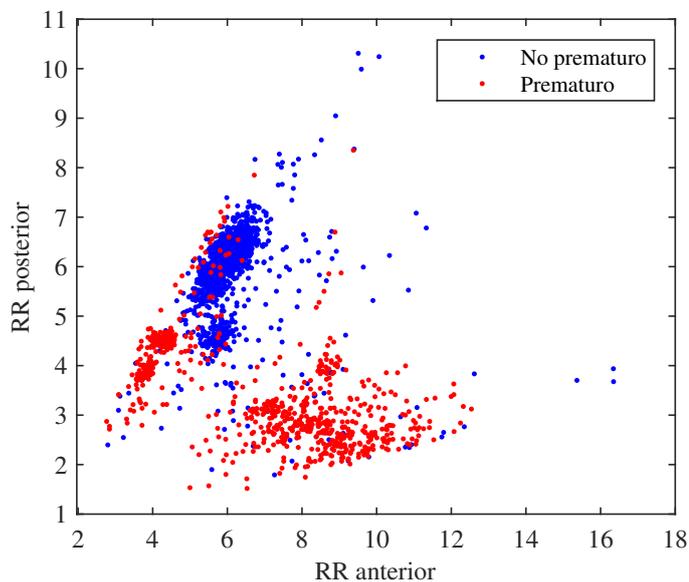


Figura 14. Comparativa de los grupos de arritmias prematuras y no prematuras. Dentro del grupo de arritmias prematuras se encuentran las clases APC y PVC. Los cúmulos formados por los puntos representan la agrupación de los tipos de arritmias.

características. Los componentes independientes son las características principales para definir cada clase como se ve en la *Figura 15*.

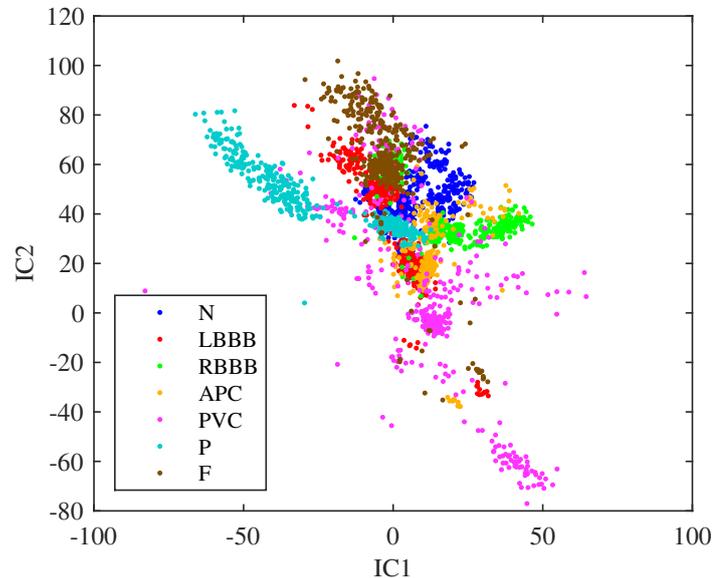


Figura 15. Gráfica de los componentes independientes (IC) 1 y 2. Los componentes independientes consiguen definir las clases y agruparlas en cúmulos. La separación de clases no es perfecta debido a ciertas similitudes entre latidos.

Las características de las medidas estadísticas y la derivada sirven de apoyo para mejorar la separabilidad de clases. Ciertas agrupaciones de características delimitan mejor las clases. La red neuronal está entrenada para poder diferenciar cada clase y tener la máxima utilidad de las características extraídas. En la *Figura 16* y *Figura 17* se observan comparativas entre componentes independientes, medidas estadísticas y funciones de modo intrínseco. En la figura *Figura 18* se muestra la relación de la curtosis y la asimetría estadística de los latidos.

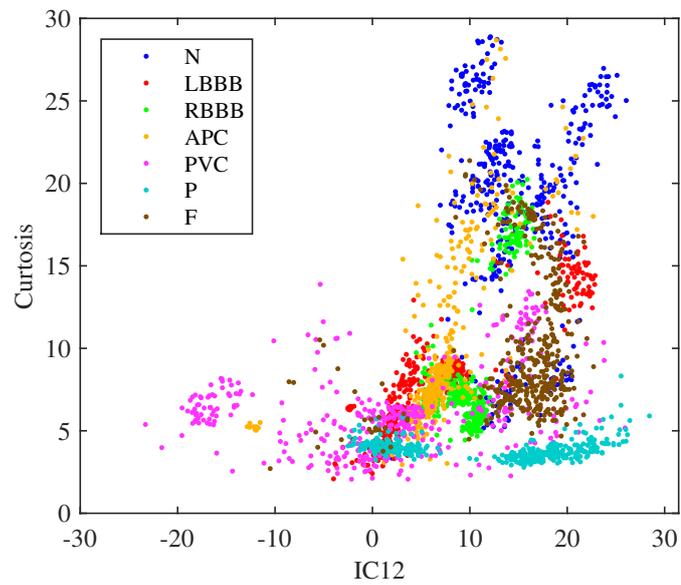


Figura 16. IC_{12} vs curtosis. Se observa una dispersión de los puntos y formación cúmulos de latidos de una misma clase. Se observan varios cúmulos de una misma clase debido a las diferencias en de cada paciente.

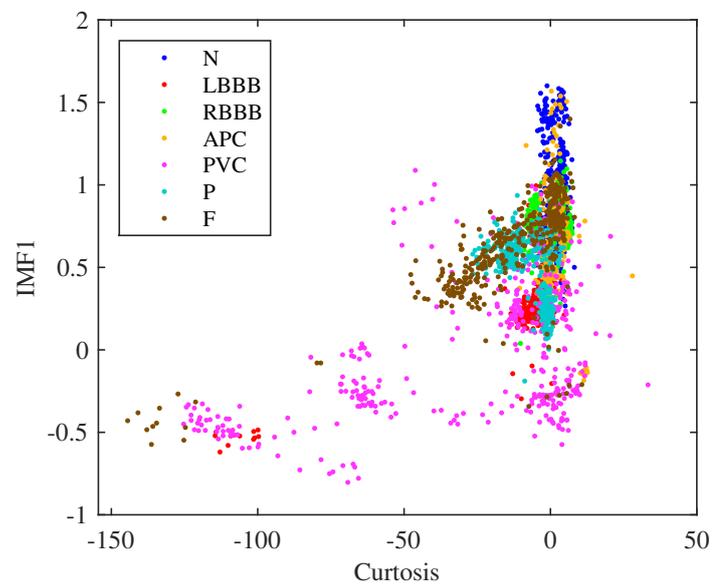


Figura 17. IMF_1 vs curtosis. La clase PVC es la clase más diferenciada y se debe a la morfología de su complejo QRS.

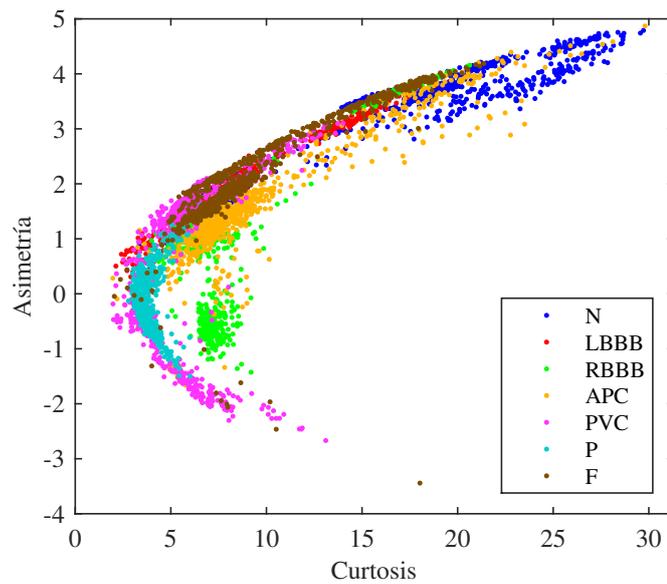


Figura 18. Curtosis vs asimetría estadística. La curtosis es una medida que provee información del apuntamiento de un latido. Es decir, que tan concentrada está la información en el centro, la onda R. La asimetría es un indicador de la cantidad de información situada a la izquierda o derecha de un eje vertical de referencia que pasa por la itad del latido. Este indicador puede ser positivo o negativo. Cuando un latido contiene más información a su izquierda el indicador es positivo y viceversa.

3.8 Diseño e implementación de la interfaz gráfica de usuario

3.8.1 Descripción de la interfaz

La interfaz gráfica de usuario se utiliza para la selección, procesamiento y clasificación de las arritmias cardíacas presentes en los registros de la base de datos MIT-BIH. La interfaz permite al usuario seleccionar el registro deseado, visualizarlo y marcar los picos de las ondas P, R y T. Después de seleccionar el registro la interfaz segmenta el ECG, presenta la cantidad de latidos segmentados y permite al usuario la visualización de los latidos. Finalmente la interfaz realiza la extracción de características y la clasificación de los latidos, presenta la cantidad de arritmias de cada clase y permite al usuario guardar la información en una base de datos e imprimirla como una hoja de cálculo. La interfaz consta de una ventana de presentación y una ventana principal, en la cual se realizarán las funciones antes mencionadas.

3.8.2 Requerimientos de la interfaz

A continuación se presenta una lista de requerimientos para la interfaz.

- Lectura de registros de la base de datos MIT-BIH.
- Lectura de atributos proporcionados por *Physionet*.
- Graficación y visualización de ondas.
- Etiquetado de la señal.
- Segmentación del ECG.
- Visualización de la cantidad de latidos segmentados.
- Clasificación de latidos.

- Visualización de la cantidad de arritmias de cada clase.
- Graficación y visualización de arritmias segmentadas.
- Almacenamiento de resultados.
- Impresión de resultados.

3.8.3 Diseño del flujograma general

Para cubrir los requerimientos del software a diseñarse se ha planteado un diagrama de flujo que involucra una serie de todos los procesos necesarios para el correcto funcionamiento del sistema. El diagrama se muestra en la *Figura 19*.

El flujo consta de los subprocesos de preprocesamiento, segmentación, extracción de características. Los diagramas de flujo de estos subprocesos serán presentados más adelante.

3.8.4 Diseño del subproceso de preprocesamiento

Descripción del subproceso

Durante este subproceso la señal ECG será filtrada con un filtro pasa bandas. Las frecuencias de corte son de $0,5Hz$ y $45Hz$, de esta manera se elimina la línea base y el ruido de la red eléctrica.

Requerimientos del subproceso

A continuación se listan los requerimientos del subproceso de filtrado

- Eliminar la línea base
- Eliminar ruido proveniente de la red eléctrica.

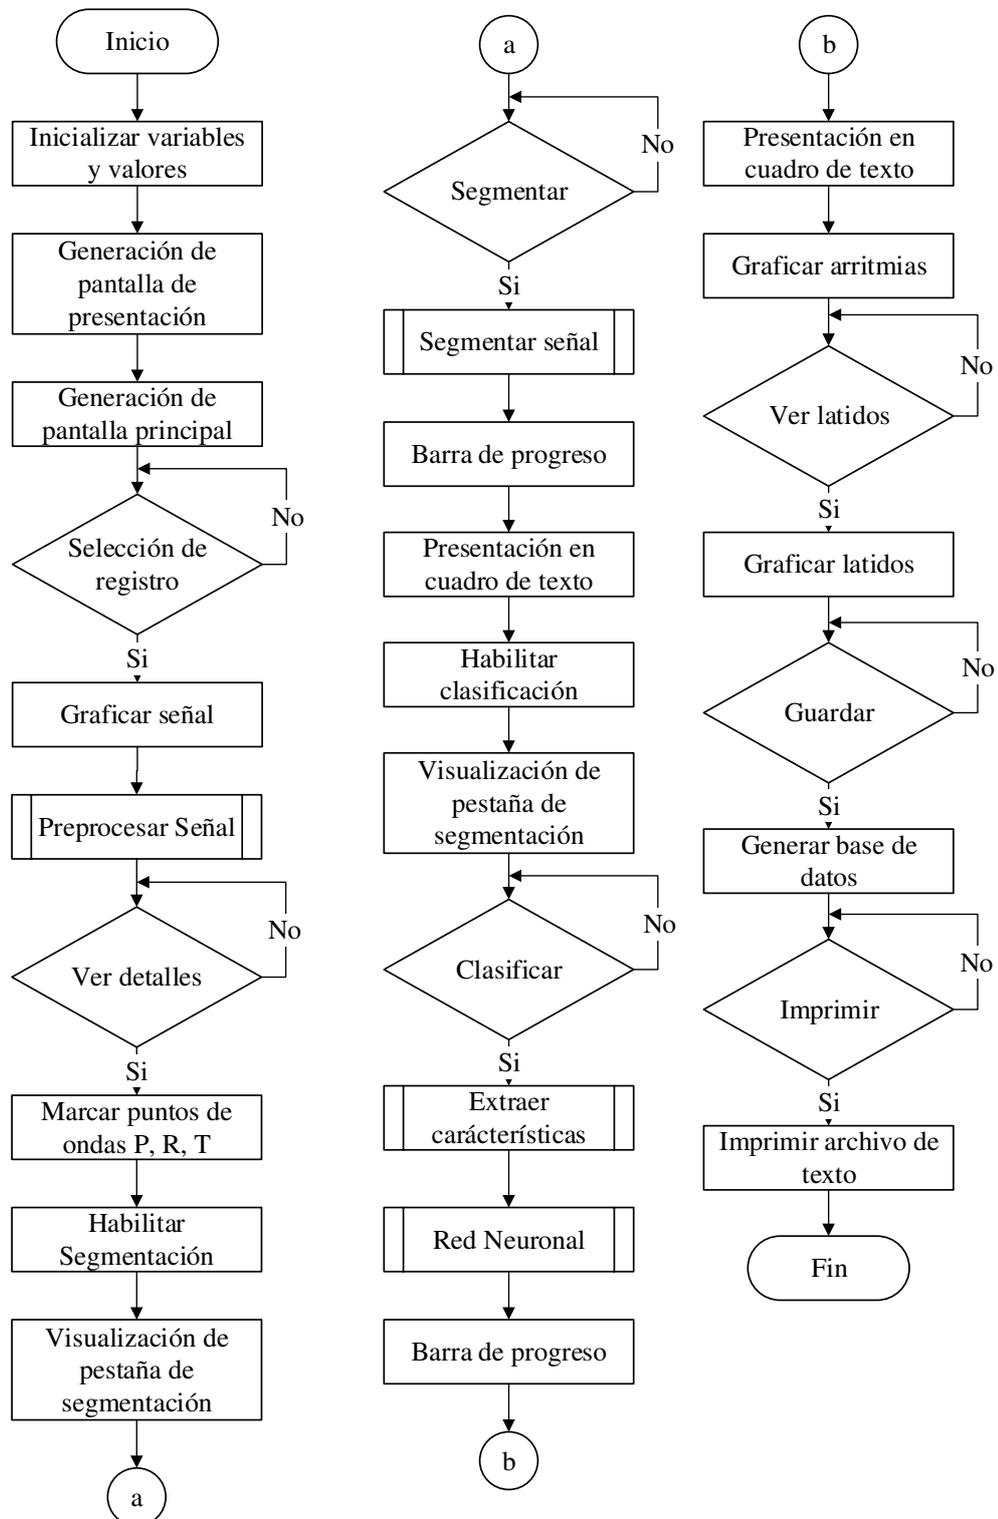


Figura 19. Diagrama de flujo general de la interfaz.

Diagrama de flujo del subproceso

El diagrama de flujo se muestra en la *Figura 20*.

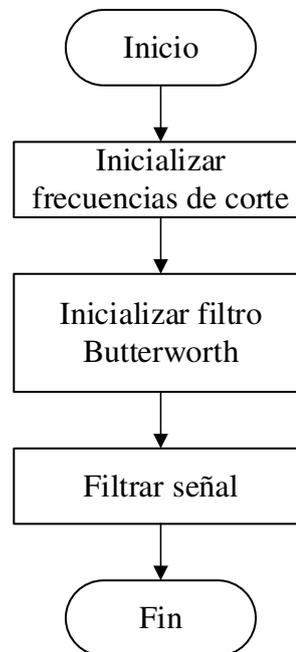


Figura 20. Diagrama de flujo del filtrado de la señal ECG.

Implementación del proceso en MATLAB

El código en MATLAB[®] para el filtrado de la señal se presenta en la siguiente sección

3.8.5 Diseño del subproceso de segmentación

Descripción del subproceso

Durante este subproceso la señal ECG filtrada se segmenta en latidos individuales tomando como referencia los puntos de los picos de las ondas P y T, ya que estas representan el inicio y fin, respectivamente, de un latido. Los puntos de las ondas P y T se encuentran definidos en la base de datos de Elgendi Elgendi et al. (2015). Se debe mencionar que las ondas P y T de la base de datos no siempre están

completas; o pueden contener una mayor cantidad de puntos que la cantidad real de latidos.

Requerimientos del subproceso

A continuación se listan los requerimientos del subproceso de segmentación

- Igualar la cantidad de puntos de las ondas P y T.
- Verificar que a cada par de puntos T y P le corresponde un punto R.
- Comparar los puntos con la información contenida en los archivos atr.
- Extraer los intervalos RR anterior y posterior.
- Segmentar el ECG.
- Almacenar los latidos segmentados.

Diagrama de flujo del subproceso

El diagrama de flujo se muestra en la *Figura 21*.

Implementación del proceso en MATLAB

El código en MATLAB[®] para la segmentación de la señal se presenta en la siguiente sección.

3.8.6 Diseño del subproceso de extracción de características

Descripción del subproceso

Durante este subproceso los latidos segmentados y almacenados pasan por el proceso de remuestreo, filtro PCA y el algoritmo de extracción de características. El remuestreo se debe realizar para todos los latidos. Cada latido tiene una longitud única que debe ser transformada a 300 puntos. El filtrado PCA se realiza gracias a

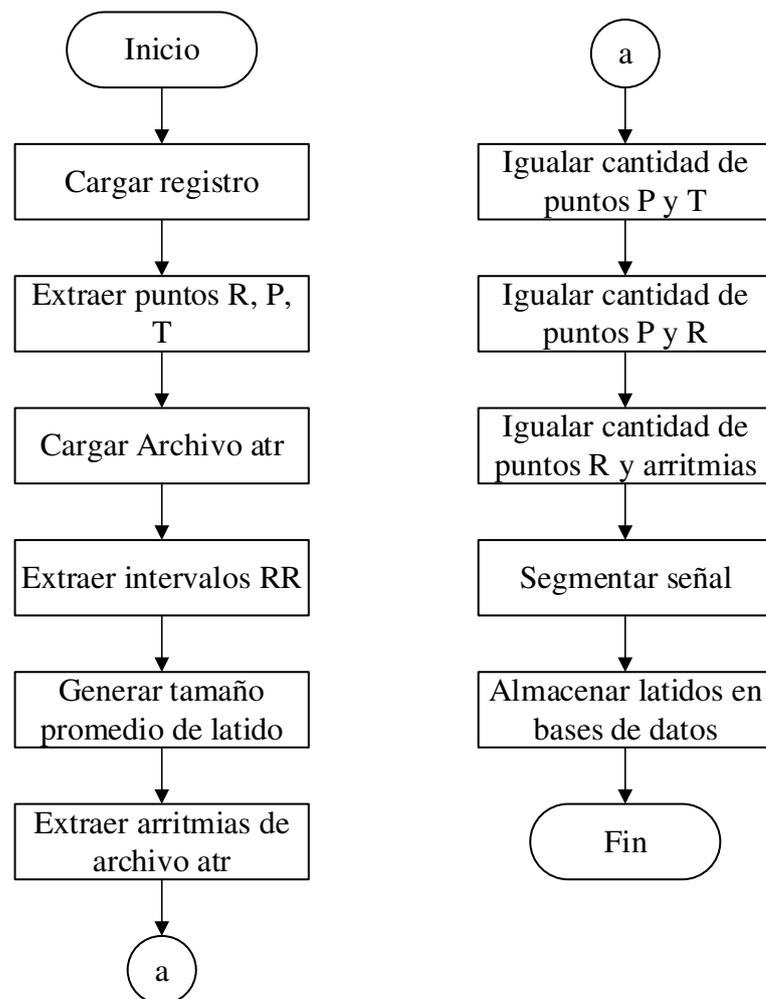


Figura 21. Diagrama de flujo del subproceso de segmentación de una señal ECG que pertenece a los registros.

la reconstrucción de un latido mediante la matriz de transformación obtenida con el análisis de componentes principales PCA.

El algoritmo de extracción calcula los pesos de las componentes independientes, pesos de las funciones de modo intrínseco, intervalos RR anterior y posterior, relación de los intervalos RR, media, desviación estándar, curtosis y apuntamiento para cada latido. En total se extraen 33 características, de las cuales 20 son los pesos de las componentes independientes (IC), 6 son los pesos de las funciones de modo intrínseco (IMF), 3 de los intervalos RR y 4 de las medidas estadísticas.

Para obtener los pesos, se debe calcular la matriz pseudo inversa de las ICs y las IMFs. Estas matrices deben ser multiplicadas con cada latido para obtener los pesos. Para procesar los intervalos RR, primero se determina si un latido es prematuro o no prematuro. Cuando un latido es prematuro, sus intervalos RR anterior y posterior se multiplican por la pseudo inversa del vector $(0,08; 0,465)$. Si el latido no es prematuro, sus intervalos RR anterior y posterior se multiplican por la pseudo inversa del vector $(0,166; 0,161)$.

Requerimientos del subproceso

A continuación se listan los requerimientos del subproceso de extracción de características.

- Remuestreo de latidos a 300 puntos.
- Calcular los pesos de las ICs.
- Calcular la derivada del latido.
- Calcular los pesos de las IMFs.
- Calcular las 4 medidas estadísticas.

- Determinar si el latido es prematuro o no prematuro en base a la relación de sus intervalos RR.
- Procesar intervalos RR anterior y posterior.
- Calcular la relación de intervalos RR.
- Generar un vector de 33 características.

Diagrama de flujo del subproceso de la red neuronal

El diagrama de flujo se muestra en la *Figura 22*.

Implementación del proceso en MATLAB

El código en MATLAB® para la extracción de características de un latido se presenta en los anexos.

3.8.7 Diseño del subproceso de la red neuronal

Descripción del subproceso

La red neuronal clasifica el tipo de arritmia según el vector de características que ingrese. Cada capa de la red calcula una salida que será la entrada para la capa siguiente. Las características ingresan a la primera capa de la red neuronal y la salida de la última capa define el tipo de arritmia.

Requerimientos del subproceso

A continuación se listan los requerimientos del subproceso de la red neuronal.

- Adecuar la entrada de la red
- Calcular la salida de la capa de entrada.
- Calcular la salida de la primera capa oculta.

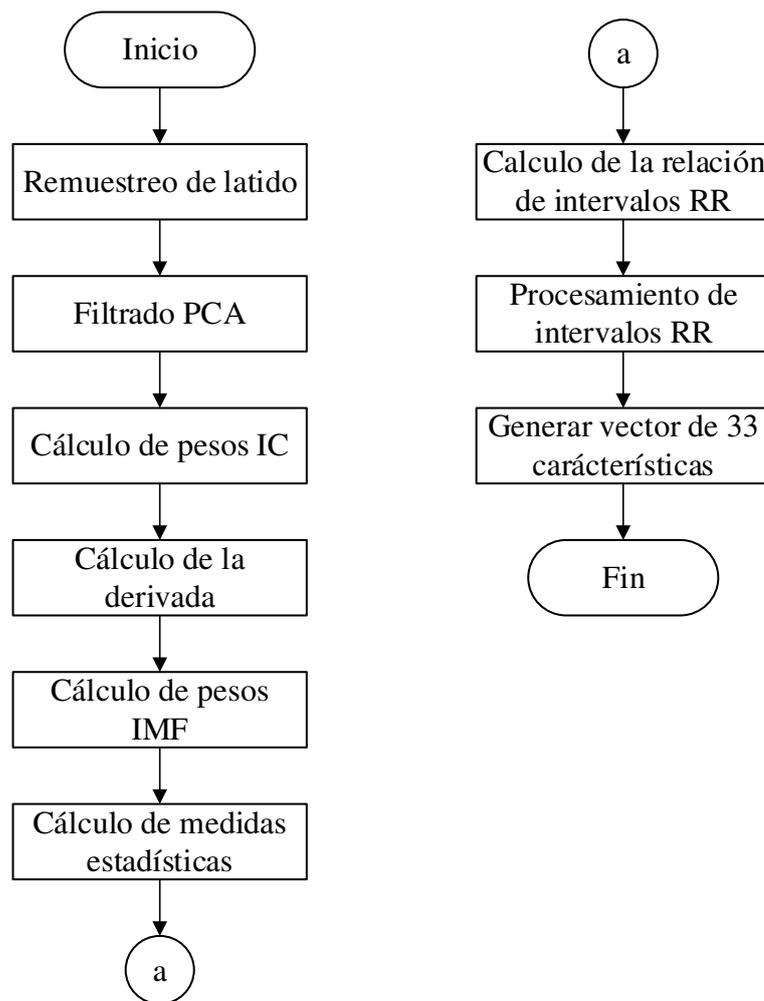


Figura 22. Diagrama de flujo del subproceso de clasificación de latidos mediante la generación de un vector de 33 características.

- Calcular la salida de la segunda capa oculta.
- Calcular la salida de la última capa.

Diagrama de flujo del subproceso

El diagrama de flujo se muestra en la *Figura 23*.

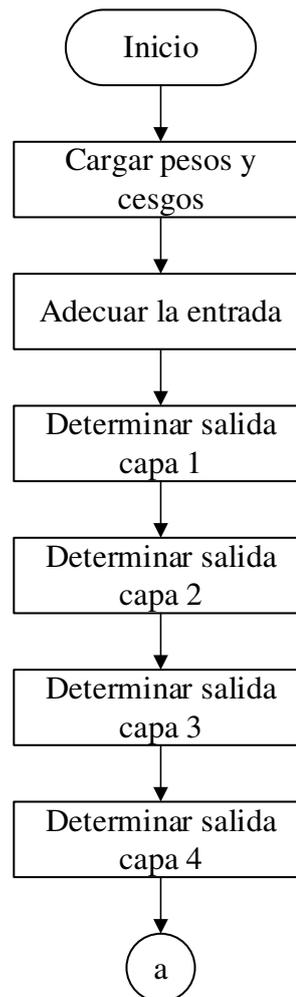


Figura 23. Diagrama de flujo del proceso de la red neuronal.

Implementación del proceso en MATLAB

El código en MATLAB® de la implementación de la red neuronal se presenta en la siguiente sección.

3.8.8 Implementación de la pantalla de presentación

La primera pantalla presenta el tema tratado en este trabajo, el autor y el presente año. Dura 10 segundos activa antes de desactivarse y pasar a la segunda pantalla. Se muestra su implementación en la **Figura 24**



Figura 24. Pantalla de presentación de la interfaz. Incluye el logo de la Universidad, el tema tratado, el autor y el presente año.

3.8.9 Implementación de la pantalla principal

La segunda pantalla incluye las funciones necesarias para la selección de los registros por parte del usuario y los procesos de filtrado, segmentación y clasificación. La pantalla contiene 2 pestañas. Cada una de estas pestañas permite la interacción del usuario con los procesos mencionados. La vista general de esta pantalla se muestra en la **Figura 25**.

Para seleccionar el registro con el que se desea trabajar se debe ingresar al menú de la aplicación como se muestra en la **Figura 26**. La señal del registro seleccionado se filtra y luego se grafica en la gráfica de la pestaña como se muestra en la **Figura 27**. Si se pulsa sobre el botón de Ver Detalles, las ondas P, R y T serán marcadas en la señal. Utilizando los controles de visualización, como se muestra en la **Figura 28**, se podrá acercar y alejar para observar los detalles de la señal como se muestra en la **Figura 29**.

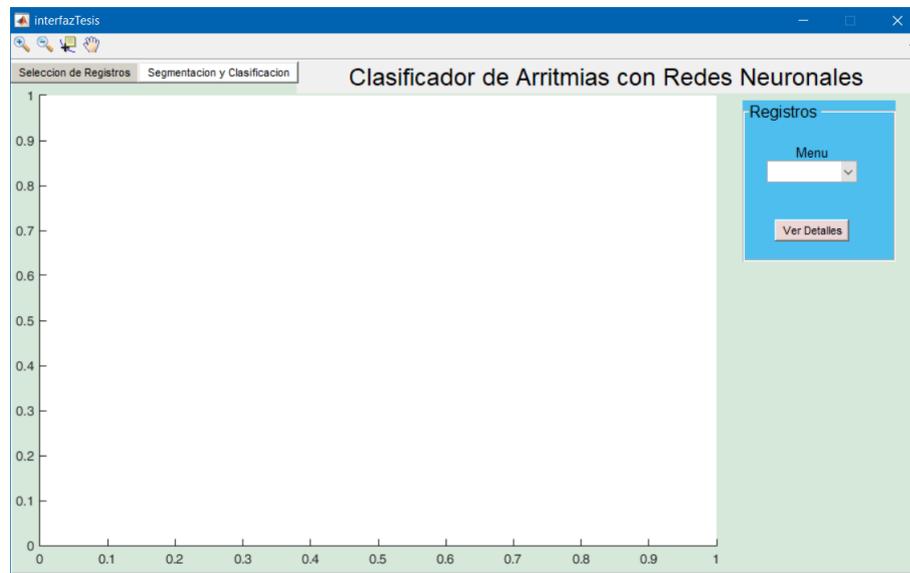


Figura 25. Vista de la pantalla principal. Por defecto, la pantalla empieza en la pestaña de selección de registro.

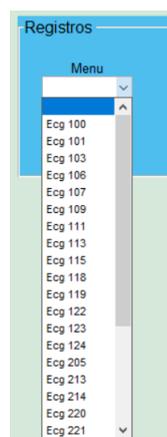


Figura 26. Vista de la pantalla principal. Por defecto, la pantalla empieza mostrando la pestaña de selección de registro.

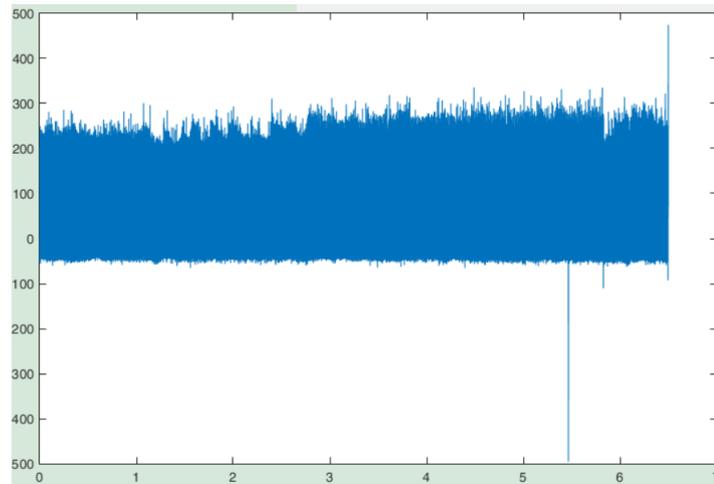


Figura 27. Menú de selección de registro. El usuario deberá escoger uno de los registros desplegados para su visualización y procesamiento.



Figura 28. Controles de visualización de la gráfica.

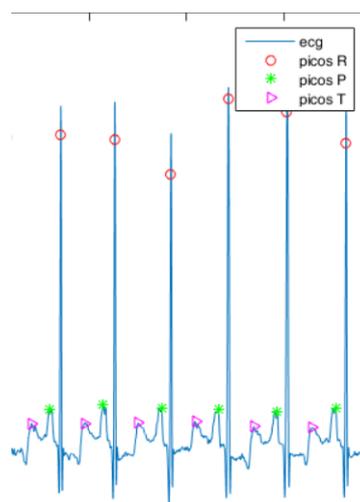


Figura 29. Detalles marcados den la señal. La leyenda define el tipo de marca para las ondas del ECG.

Con el registro seleccionado y la señal filtrada se procede a la pestaña de segmentación y clasificación, **Figura 30**. Dentro de la pestaña el usuario deberá pulsar el botón de segmentar. El resultado de la segmentación son latidos individuales y su cantidad se escribe en el cuadro de texto, **Figura 31**.

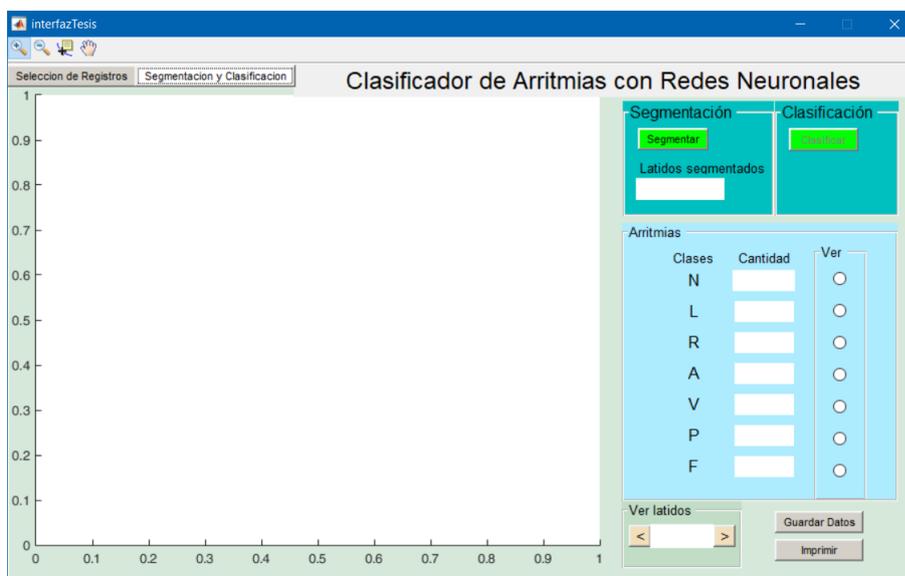


Figura 30. Pestaña de segmentación y clasificación.

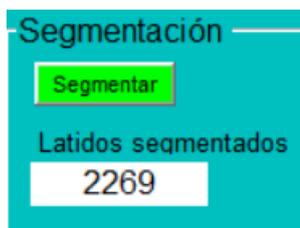


Figura 31. Botón de segmentación del ECG sobre el cuadro de texto donde se muestra la cantidad de latidos segmentados.

Una vez que se obtienen los latidos segmentados, estos se pueden visualizar en la gráfica mediante los controles que se muestran en la **Figura 32**. Para continuar con el proceso el usuario debe pulsar el botón de Clasificar. De esta manera empezará la extracción de características y la clasificación de cada latido. El resultado se mostrará

en los cuadros de texto, **Figura 33**. Si se pulsán los botones de Ver en cualquier clase de arritmia, estas se marcarán en la gráfica de la señal en la pestaña de selección de registros como se muestra en la **Figura 34**. También se grafica la arritmia en la gráfica de la pestaña de segmentación y clasificación como se muestra en la **Figura 36**.

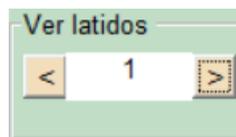


Figura 32. Controles de navegación para visualización de latidos segmentados.

Clases	Cantidad	Ver
N	2233	<input type="radio"/>
L	0	<input type="radio"/>
R	1	<input type="radio"/>
A	33	<input type="radio"/>
V	1	<input type="radio"/>
P	0	<input type="radio"/>
F	0	<input type="radio"/>

Figura 33. Cuadros de texto donde se escribe la cantidad de arritmias clasificadas del registro.

Finalmente el usuario tiene la opción de guardar los resultados en una base de datos generada en Excel. Los campos de la base de datos son: fecha y hora de la prueba, nombre del registro, cantidades predichas de arritmias y cantidades reales de arritmias. El usuario puede ingresar a la aplicación de Excel e imprimir el reporte de todos los análisis realizados a las señales en una sola hoja consolidada. Además desde la aplicación Clasificador de arritmias desarrollada en este trabajo se puede imprimir mediante el botón imprimir el reporte del análisis realizado al registro en ese instante, La **Figura 35** muestra los controles del almacenamiento de datos. La **Figura 37** muestra los campos de la base de datos detallados anteriormente.

El usuario debe abrir la base de datos almacenada en la hoja de excel cada vez

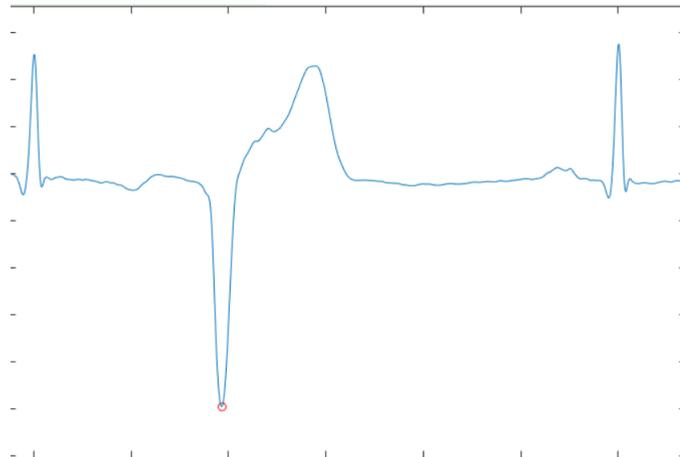


Figura 34. Se marca la onda R de las arritmias encontradas por el clasificador.



Figura 35. Botones para guardar o imprimir los resultados de la clasificación del registro.

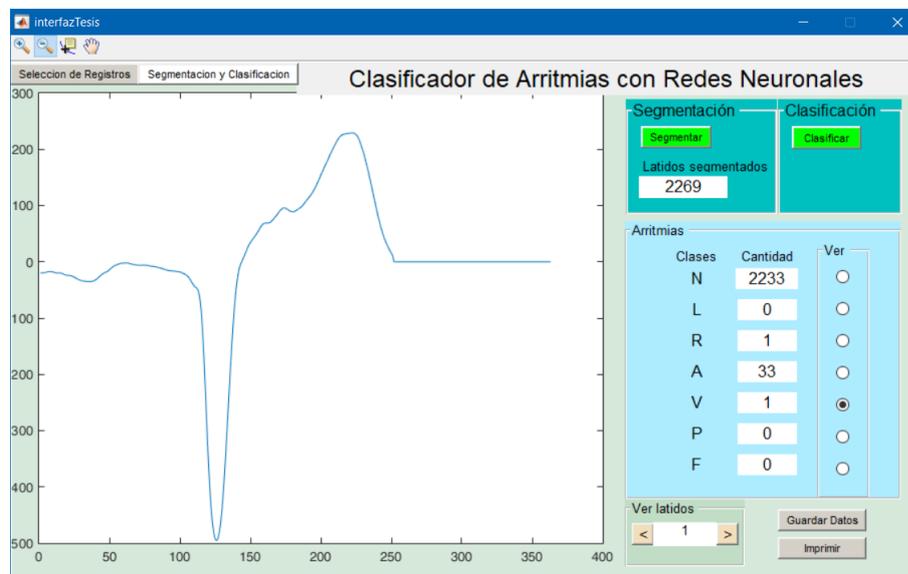


Figura 36. Grafica de un latido segmentado. Este latido corresponde a una arritmia de tipo PVC, clasificada correctamente.

Fecha	Hora	Registro	N real	N predicho	L real	L predicho	R real	R predicho	A real	A predicho	V real	V predicho	P real	P predicho	F real	F predicho
13/01/20	13:53	ECG 100	1	2234	1	0	1	1	1	33	1	1	1	0	1	0
13/01/20	13:57	ECG 100	2235	2234	0	0	0	1	33	33	1	1	0	0	0	0
13/01/20	13:58	ECG 101	1857	1853	0	4	0	1	2	0	0	0	0	1	0	0
13/01/20	13:58	ECG 103	2076	2075	0	0	0	1	2	2	0	0	0	0	0	0
13/01/20	13:59	ECG 106	1500	1480	0	1	0	6	0	22	481	470	0	0	0	2
13/01/20	14:57	ECG 122	2472	2470	0	0	0	0	0	0	0	0	0	0	0	2

Figura 37. Ejemplo de la base de datos generada después de aplicar el software a 7 registros.

que necesite revisar las pruebas realizadas, pudiendose revisar el historial de pruebas y los resultados obtenidos.

3.9 Codigos en MATLAB de los subprocessos del sistema

3.9.1 Preprocesamiento

```

function ecg=filtro ( signal )
f1=0.5;           frecuencia de corte inferior
f2=45;           frecuencia de corte superior
fs=360;          frecuencia de muestro de la senal
Wn=[f1 f2 ]*2/ fs ;   frecuencia de corte normalizada
N = 3;           orden del filtro
[a,b] = butter(N,Wn); calculo de coeficientes del filtro
ecg = filtfilt(a,b,signal); filtraje de senal
end

```

3.9.2 Segmentación

```

function ds = segmentacion(ecg,name)
% cargar bases de datos
str='C:\Users\bruno\Dropbox\Tesis\Pwaves_Twaves_Annotation\';
base=[str, 'Ant_mitdb_', name];
x=load ( base );
% extraer puntos

```

```

ppeaks=x.P_Peaks_Annot;
rpeaks=x.R_Peaks;
tpeaks=x.T_Peaks_Annot;
[a,~]=size(ppeaks);
if a==1
    ppeaks=ppeaks';
end
p=ppeaks;
t=tpeaks;
r=rpeaks;
p1=p;t1=t;r1=r;
%dear archivos de atributos
na=['mitdb/',name];
[RR,tms]=ann2rr(na,'atr',[],[],false);
[an,ty,~,~,~,~]=rdann(na,'atr');
ann=find(ty=='N'|ty=='R'|ty=='L'|ty=='A'|ty=='a'|ty=='J'...
|ty=='S'|ty=='V'|ty=='F'|ty=='e'|ty=='/'|ty=='j'|ty=='E'...
|ty=='f'|ty=='Q'|ty=='p'|ty=='!');
ty=ty(ann);
an=an(ann);
l=length(tms);
r=tms(2:l);
l=length(r);
rr=r(2:l)-r(1:l-1);
r=r(2:l-1);
l=length(rr);
RR=[rr(1:l-1),rr(2:l)];
l=length(an);
an([1,l-1,l])=[];

```

```

ty ([1, 1-2, 1]) = [];
d=sum(an-r)/(1-3);
mu=mean(rr);
sig=std(rr);
lim=mu+sig;
l=length(p); %igualar longitudes de P y T
try
for k=1:l
d=t(k)-p(k);
while(d<0 || d>lim)
    if d<0 %eliminar t(k)
        t(k) = [];
    elseif d>lim %
        p(k) = [];
    end
    d=t(k)-p(k);
end
end
catch
end
while(length(p)>length(t))
    p(length(p)) = [];
end
while(length(t)>length(p))
    t(length(t)) = [];
end
indices = [];
l=length(an);
%igualar longitudes de P y atributos

```

```

try
  for i=1:l
    d=an(i)-p(i);
    while d<0 || d>lim
      if d<0
        an(i)=[];
        RR(i,:)=[];
        ty(i)=[];
        indices=[indices,i];
      end
      if d>lim
        p(i)=[];
        t(i)=[];
      end
      d=an(i)-p(i);
    end
  end
catch
end

while (length(p)>length(an))
  p(length(p))=[];
  t(length(t))=[];
end

while (length(an)>length(p))
  an(length(an))=[];
  RR(length(RR))=[];
  ty(length(ty))=[];
end

```

```

RR=RR./mu;
dif=max(t-p+50);
l=length(t);
beat=zeros(1,dif);
%segmentar latidos
for i=1:l
    s=t(i)+25-an(i);
    b=ecg(an(i)-s:an(i)+s);
    beat(i,1:length(b))=b;
end
%almacenar latidos
tabla=table(beat,ty,RR,an,'variableNames'...
,{ 'latido', 'tipo', 'RR', 'an' });
ds=table2dataset(tabla);
end

```

3.9.3 Extracción de características

```

function news=clasificacion(l,rr,ic,imf,wt,sig,net)
l=resample(l,300,length(l)); %remuestreo del latido
l=(l*wt)*wt'; %filtro PCA
ics=l/ic; %calculo de pesos ICs
der=conv2(l,[1 -1]); %calculo de la derivada del latido
imfs=der/imf; %calculo de pesos IMFs
%medidas estadisticas
mu=mean(l')';s=std(l')';kurt=kurtosis(l')';skew=skewness(l')';
r=rr(:,2)./rr(:,1);%relacion de intervalos RR
%procesamiento de intervalos RR
rr(r>1.2,:)=bsxfun(@rdivide,rr(r>1.2,:),sig(2,:));
rr(r<1.2,:)=bsxfun(@rdivide,rr(r<1.2,:),sig(1,:));

```

```

% if r>1.2
%     rr=bsxfun(@rdivide,rr,sig(2,:));
% else
%     rr=bsxfun(@rdivide,rr,sig(1,:));
% end

%%Generacion del vector de características
ft=[rr,r,ics,mu,s,kurt,skew,imfs]';
%calculo de la salida
salida=net(ft);
[~,a]=size(salida);
news=[];
for i=1:a
    s=salida(:,i);
    [b,index]=max(s);
    if(b<0.5)
        s=zeros(7,1);
        s(index)=1;
    else
        s=round(s);
    end
    news=[news,s];
end

```

3.9.4 Red Neuronal

```

function [Y,a0,Xp1]=redNeuronal(X)
%#codegen
Q=1;

% Input 1
x1_step1_xoffset = load('x1_step1_xoff');

```

```

x1_step1_gain = load('x1_step1_gain');
x1_step1_ymin = load('x1_step1_ymin');
%% Pesos y Cesgos
% capa 1
b1 = load('b1');
IW1_1 = load('w1');
% capa 2
b2 = load('b2');
LW2_1 = load('w2');
% capa 3
b3 = load('b3');
LW3_2 = load('w2');
%% Adecuar entradas
Xp1 = mapminmax_apply(X, x1_step1_gain, x1_step1_xoffset, ...
x1_step1_ymin);
%% Salidas
% capa 1
a0= repmat(b1,1,Q) + IW1_1*Xp1;
a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

% capa 2
a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

% capa 3
a3 = softmax_apply(repmat(b3,1,Q) + LW3_2*a2);

% salida 1
Y = a3;
end

```

```
function y = mapminmax_apply(x, settings_gain ,...  
settings_xoffset , settings_ymin )  
    y=(x-settings_xoffset).* settings_gain+settings_ymin ;  
end
```

% Funcion Softmax

```
function a = softmax_apply(n)  
    nmax = max(n, [], 1) ;  
    n = bsxfun(@minus, n, nmax) ;  
    numer = exp(n) ;  
    denom = sum(numer, 1) ;  
    denom(denom == 0) = 1 ;  
    a = bsxfun(@rdivide, numer, denom) ;  
end
```

% Funcion sigmoide

```
function a = tansig_apply(n)  
    a = 2 ./ (1 + exp(-2*n)) - 1 ;  
end
```

CAPÍTULO IV

Pruebas y Análisis de Resultados

4.1 Pruebas sobre registros de la base de datos MIT-BIH

4.1.1 Escenario de pruebas

Las pruebas se realizaron sobre 21 registros de la base de datos MIT-BIH. La ejecución de las pruebas consistió en la clasificación de latidos mediante el uso de la interfaz de usuario diseñada en el Capítulo III. Se utilizaron los archivos de atributos proporcionados por *Physionet* para comparar los resultados obtenidos de la clasificación con los valores reales. También se utilizó la base de datos de Elgendi Elgendi et al. (2015) para segmentar el ECG con los puntos de las ondas P y T. El procedimiento de la ejecución de las pruebas se muestra en la **Figura 38**.

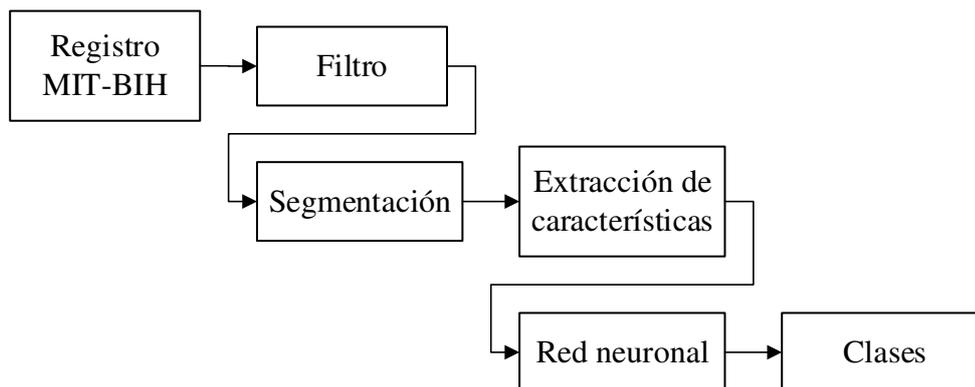


Figura 38. Diagrama de bloques del procedimiento para la clasificación de latidos de los registros de la base de datos MIT-BIH.

4.1.2 Realización de pruebas

Las pruebas fueron realizadas utilizando como herramienta la interfaz de usuario. En la **Figura 39** y **Figura 40** se muestra el procedimiento realizado sobre el registro Ecg 100. El archivo de resultados generado al pulsar el botón de impresión se muestra en la **Figura 41**.

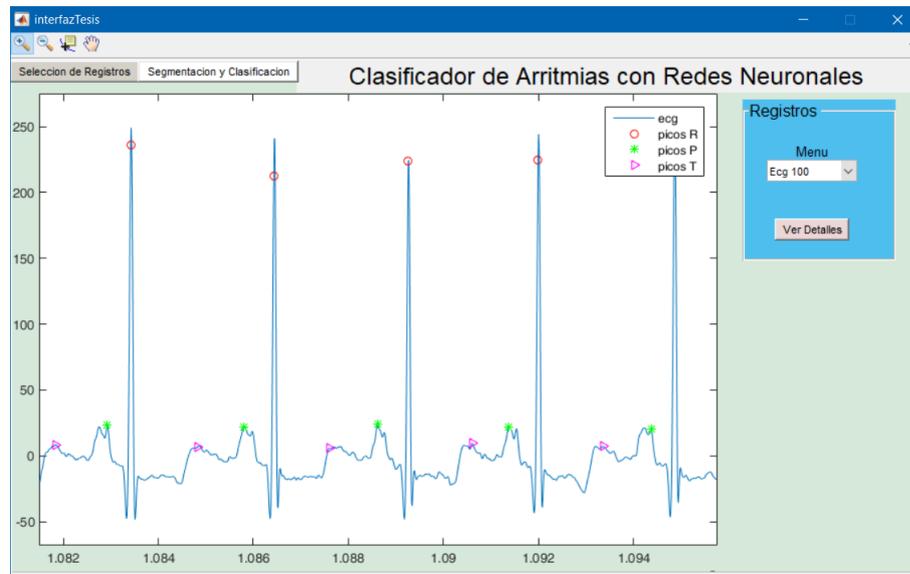


Figura 39. Selección y visualización del registro ECG en la primera pestaña de la interfaz de usuario.

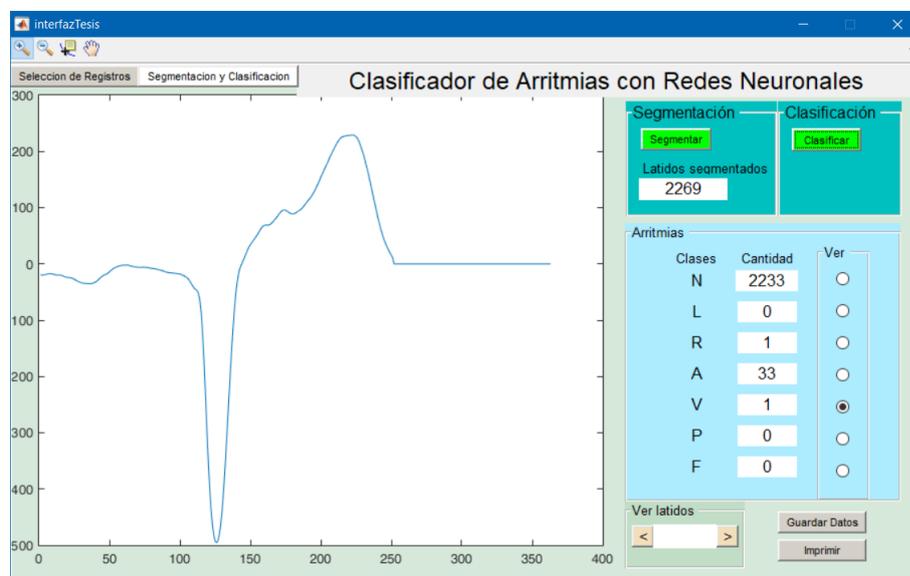


Figura 40. Segmentación y clasificación de latidos del registro ECG 100. La cantidad de latidos segmentados es de 2269.

tipo	clase_N	clase_L	clase_R	clase_A	clase_V	clase_P	clase_F
cant real	2235	0	0	33	1	0	0
cant pred	2234	0	1	33	1	0	0

Figura 41. Hoja de cálculo generada por el programa. Muestra las cantidades reales y predichas de las arritmias clasificadas. El archivo actual es una captura de los resultados del registro Ecg 100.

Tabla 10
Resultados de las pruebas realizadas

Grabación	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

Resultados de la clasificación en 21 registros de la base de datos MIT-BIH. Re. representa la cantidad de arritmias descritas en la base de datos MIT-BIH, Pr. representa la cantidad de arritmias clasificadas por el algoritmo.

Los resultados obtenidos al realizar las pruebas a los 21 registros de la base de datos MIT-BIH se muestran en la **Tabla 10**. En la tabla se detalla en la columna Re. las cantidades reales proporcionadas por *Physionet* de todas las clases de arritmias, y en la columna Pr. las cantidades de arritmias predichas por la aplicación.

4.2 Métricas de desempeño del clasificador

Los clasificadores se evalúan en base a una serie de parámetros o métricas de desempeño que se calculan a partir de los resultados que se obtienen de un conjunto de datos de prueba.

4.2.1 Matriz de confusión

La matriz de confusión presenta en una tabla bidimensional la relación entre las predicciones y los actuales, donde una predicción es la salida del clasificador para una clase y un actual es el valor verdadero para esa clase. La matriz de confusión se utiliza en problemas de clasificación de 2 o más clases. Se construye de la siguiente manera como se muestra en la **Tabla 11**.

TP son los verdaderos positivos (*True Positives*) y representa la cantidad de predicciones positivas cuando la clase es positiva (acierto). FP son los falsos positivos (*False Positive*), es la cantidad de predicciones positivas cuando la clase es negativa (error). FN son los falsos negativos (*False Negative*) y representan la cantidad de predicciones negativas cuando la clase es positiva (error). TN son los verdaderos negativos (*True Negative*) y es la cantidad predicciones negativas cuando la clase es negativa (acierto). Estos parámetros se utilizan para calcular otras métricas de desempeño.

Tabla 11
Ejemplo de matriz de confusión

	Actuales	
Predicciones	Positivos	Negativos
Positivos	TP	FP
Negativos	FN	TN

Ejemplo de construcción de una matriz de confusión de 2 clases. El problema de clasificación es el de predecir cuando un elemento pertenece a la clase positiva o no pertenece, es decir, pertenece a la clase negativa.

4.2.2 Exactitud

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

$$E = \frac{TP + TN}{TP + TN + FP + FN}$$

4.2.3 Precisión

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

$$P = \frac{TP}{TP + FP}$$

4.2.4 Sensitividad

La sensitividad 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.

$$S = \frac{TP}{TP + FN}$$

4.2.5 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.

$$Es = \frac{TN}{TN + FP}$$

4.3 Resultados del Clasificador

Después de realizar las pruebas a los 21 registros, los resultados obtenidos se detallan en una matriz de confusión como se muestra en la **Tabla 12**. Las métricas del clasificador en base los resultados obtenidos se muestran en la **Tabla 13**. El algoritmo fue probado en una computadora portátil marca Asus modelo ROG GL552VW, procesador Intel(R) Core(TM) i7-6700HQ @2.6Ghz de 64 bits y 16 GB de RAM. El tiempo de procesamiento para la extracción de características de un latido es de 1.25 milisegundos (ms) en promedio. El tiempo de procesamiento para la clasificación de un latido es de 8.89ms en promedio.

Tabla 12
Matriz de confusión del clasificador

Clase	N	L	R	A	V	P	F
N	27263	0	14	13	4	0	68
L	29	5966	9	0	15	0	60
R	40	2	3927	21	12	0	7
A	71	4	27	1515	37	0	1
V	24	54	11	7	1362	8	41
P	2	20	6	0	27	2063	0
F	61	6	8	1	118	2	577

Matriz de confusión del clasificador donde se detallan los resultados obtenidos de las pruebas a los 21 registros de la base de datos MIT-BIH.

Se obtuvieron mejores resultados que los presentados en la **Tabla 14**; salvo el caso de la última clase, debido a la reducida cantidad de latidos de tipo fusión presentes en la base de datos MIT-BIH. Se obtienen mejores resultados en la clasificación cuando

Tabla 13
Métricas del clasificador

Clase	Exactitud	Sensitividad	Especificidad	Precisión
N	99.27 %	99.17 %	99.43 %	99.64 %
L	99.56 %	98.58 %	99.71 %	98.14 %
R	99.69 %	98.13 %	99.85 %	98.42 %
A	99.64 %	98.57 %	99.68 %	91.54 %
V	99.20 %	92.50 %	99.65 %	94.77 %
P	99.85 %	99.52 %	99.87 %	97.40 %
F	99.17 %	76.53 %	99.56 %	74.74 %
Promedio	99.48 %	94.71 %	99.67 %	93.52 %

Tabla 14
Comparativa de resultados con trabajos anteriores

Autor	Exactitud	Sensitividad	Especificidad	Precisión
Salah	94.97 %	95.36 %	96.99 %	95.04 %
Wang et al.	99.61 %	89.94%	98.27 %	99.43 %
Ghorbani et al.	99.17 %	93.3 %	88.96 %	97.58 %
Castillo et al.	97.33 %	98.7 %	96.66 %	99.31 %
Saini	98 %	98 %	99.5 %	97.79 %
Elhaj et al.	98.91 %	98.91 %	97.85 %	98.90 %
Li et al.	98.80 %	98.50 %	99.69 %	98.91 %
Khalaf et al.	98.6 %	99.2 %	99.7 %	99.9 %
Übeyli	98.06 %	98.06 %	99.34 %	98.6 %
Leppe	99.48 %	94.71 %	99.67 %	93.52 %

las clases son separables y están definidas o agrupadas. Las características extraídas deben proporcionar la información necesaria para lograr la separabilidad de clases.

CAPÍTULO V

Conclusiones

En el presente trabajo se aplicó ICA a un latido normal para calcular 20 componentes independientes. La combinación lineal de estos componentes independientes y un vector de pesos da como resultado un latido, donde los pesos se toman como nuevas características. Se aplicó EMD a la derivada de un latido normal, dando como resultado 6 funciones de modo intrínseco. La combinación lineal de estas funciones y un vector de pesos da como resultado cualquier latido, estos pesos se toman como nuevas características.

Las medidas estadísticas: media, desviación estándar, curtosis y asimetría son usadas para encontrar 4 nuevas características. Los intervalos RR anterior y posterior y la relación entre ambos se toman como 3 nuevas características. El sistema describe una señal ECG con un total de 33 características. Estas características ingresan a una red neuronal formada por 4 capas, la capa de entrada con 33 neuronas, dos capas ocultas de 80 neuronas cada una y la capa de salida con 7 neuronas.

El sistema alcanzó una exactitud promedio de 99.2 % al utilizar el algoritmo ICA en las primeras primeras pruebas de clasificación. Demostrándose de esta manera que ICA es un método de análisis de datos muy efectivo para la reducción de dimensionalidad y extracción de características de un conjunto de señales biológicas como los latidos cardiacos.

El algoritmo PCA resulta muy efectivo para suavizar un conjunto de señales ECG, removiendo componentes no deseadas que representan ruido al reconstruir una señal con sus componentes más importantes. De esta manera se obtuvieron bases de datos con latidos suavizados y libres de ruido para el entrenamiento de la red neuronal. Además el algoritmo PCA se utilizó para remover el ruido aleatorio agregado a los latidos con una relación señal a ruido de 5 dB. Las métricas alcanzadas al ingresar

estos latidos con ruido al sistema de clasificación fueron inferiores en un promedio de 2 % a las métricas alcanzadas con señales sin ruido.

La morfología de un latido de tipo APC, o latido prematuro, es semejante a la morfología de un latido normal, o no prematuro. Para un latido no prematuro la relación entre sus intervalos RR es 1, mientras que para un latido prematuro es mayor a 1,2. En la literatura médica se menciona que una de las características de los latidos del tipo APC es la ausencia de ondas P, o bien la fusión de ondas P y ondas T del anterior latido. Sin embargo, el algoritmo de detección y segmentación de arritmias usado por Elgendi et al. (2015), con el que se creó la base de datos de entrenamiento usada en este trabajo, no consigue discriminar ondas P y T fusionadas ni la ausencia de ondas P. Debido a esto, los latidos de tipo APC sí presentan una falsa onda P. Por lo tanto la característica que diferencia a ambas clases es la relación entre los intervalos RR anterior y posterior. Es por eso que los intervalos RR son características muy importantes en la clasificación de latidos normales y APC.

Se utilizó una red neuronal artificial directa por la facilidad de implementación. El entrenamiento de la red neuronal se realizó con el algoritmo RPROP, consiguiendo tiempos de entrenamiento muy bajos, al rededor de 30 segundos. La red neuronal diseñada consta de cuatro capas. Estas capas son representadas con matrices que contienen los pesos y cesgos calculados en el entrenamiento. El resultado de cada capa se reduce al cálculo de multiplicaciones y sumas de matrices y vectores. Las funciones de activación para calcular la salida de cada capa son funciones exponenciales. En la capa de entrada y las capas ocultas se utiliza la funcion sigmoide tangente hiperbólica. En la ultima capa se utilizó la función de activación softmax debido a la facilidad para calcular la probabilidad de ocurrencia de cada clase.

Los resultados obtenidos al ejecutar el sistema de clasificación de arritmias entrenado con el algoritmo RPROP a los 21 registros de la base de datos MIT-BIH

permitieron verificar la exactitud del sistema de clasificación desarrollado en el presente trabajo. Este sistema logró alcanzar métricas de desempeño más altas que anteriores trabajos, con una exactitud promedio de 99.48 % para 7 tipos de arritmias cardíacas de la base de datos MIT-BIH.

Los resultados alcanzados en el presente trabajo permiten concluir que se han cumplido con los objetivos propuestos en el mismo, puesto que se han logrado métricas superiores a las métricas obtenidas en otros trabajos relacionados.

REFERENCIAS BIBLIOGRÁFICAS

- Arrhythmia Alliance. (n.d.). *Types of Arrhythmia - Arrhythmia Alliance*. Retrieved 2018-10-23, from <http://www.heartrhythmalliance.org/aa/uk/types-of-arrhythmia>
- Asimetría y curtosis*. (2014). Retrieved 2019-04-22, from <https://www.universoformulas.com/estadistica/descriptiva/asimetria-curtosis/>
- Baker, K. (2005). *Singular Value Decomposition Tutorial*. Retrieved from <https://davetang.org/file/Singular{ }Value{ }Decomposition{ }Tutorial.pdf>
- Bee, M. A., & Micheyl, C. (2008, aug). The cocktail party problem: what is it? How can it be solved? And why should animal behaviorists study it? *Journal of comparative psychology (Washington, D.C. : 1983)*, 122(3), 235–51. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/18729652><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC2692487> doi: 10.1037/0735-7036.122.3.235
- Berg, J., Tymoczko, J. L., & Stryer, L. (2008). *Bioquímica*. Reverte. Retrieved from <https://books.google.es/books?id=HRr4MNH2YssC{ }pg=PA362{ }dq=Un+potencial+de+acci{ }n+impulso+el{ }ctrico{ }hl=es{ }sa=X{ }ved=0ahUKEwjZ1M637anXAhXIShQKHSM1BQQQ6AEIOjAD{ }#v=onepage{ }q=Unpotencialdeacci{ }nimpulsoel{ }ctrico{ }f=false>
- Castillo, O., Melin, P., Ramírez, E., & Soria, J. (2011). International competitiveness, the demand for exports and real effective exchange rates in developing countries. *Hybrid intelligent system for cardiac arrhythmia classification with Fuzzy K-Nearest Neighbors and neural networks combined with a fuzzy system*, 41(2), 377–398. Retrieved from <http://dx.doi.org/10.1016/j.eswa.2011.08.156> doi: 10.1016/j.eswa.2011.08.156
- Cruces, S., & Nuñez, J. (2005). *Fundamentos básicos del Análisis de Componentes Independientes* (Proyecto fin de carrera, Universidad de

- Sevilla). Retrieved from <http://bibing.us.es/proyectos/abreproy/11088/fichero/Proyecto+Fin+de+Carrera{%}252F5.pdf>
- De los Nietos, M. (2007). *Nociones Básicas de Anatomía, Fisiología y Patología Cardíaca: Bradiarritmias y Taquiarritmias* (Tech. Rep.). Madrid: Hospital Fundación Alcorcón. Retrieved from <https://www.enfermeriaencardiologia.com/wp-content/uploads/4001.pdf>
- Elgendi, M., Eskofier, B., & Abbott, D. (2015). Fast T wave detection calibrated by clinical knowledge with annotation of P and T waves. *Sensors (Switzerland)*, *15*(7), 17693–17714. doi: 10.3390/s150717693
- Elhaj, F. A., Salim, N., Harris, A. R., Swee, T. T., & Ahmed, T. (2016). Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals. *Computer Methods and Programs in Biomedicine*, *127*, 52–63. Retrieved from <http://dx.doi.org/10.1016/j.cmpb.2015.12.024> doi: 10.1016/j.cmpb.2015.12.024
- Empendium. (n.d.). *Electrocardiograma estándar*. Retrieved 2019-04-29, from <https://empendium.com/manualmibe/chapter/B34.V.25.1.1>.
- Espinosa, A. V., Carpio Toro, M. D., & Vintimilla Garate, J. F. (2017). Arritmias Cardíacas en Corazón Estructuralmente Sano Diagnosticadas por Monitoreo Holter Electrocardiográfico y la Correlación Clínica en Pacientes Ambulatorios. *REVISTA MÉDICA HJCA*, *9*, 270–274. Retrieved from <http://revistamedicahjca.med.ec/ojs/index.php/RevHJCA/article/view/383/355>
- Fajuri, D. A. (2018). *Arritmias* (Tech. Rep.). Retrieved from <https://medicina.uc.cl/wp-content/uploads/2018/06/ManualArritmias.pdf>
- García, J., Castillo, R., Buitrón, E., Paredes, M., Nabernegg, M., Boada, M., & Sempértegui, B. (2016). Compendio Estadístico 2016. *Instituto Nacional de Estadísticas y Censos*, *1*, 418. Retrieved from <http://>

www.ecuadorencifras.gob.ec/documentos/web-inec/Bibliotecas/Compendio/Compendio-2016/Compendio2016DIGITAL.pdf

Garza, A. L., Ibarra, A., & Guzman, R. (2015). *Biopotenciales* (Tech. Rep.). Ciudad Juarez: Universidad Autónoma de Ciudad Juarez. Retrieved from <http://arelyvaib.weebly.com/uploads/4/8/9/1/48919343/biopotenciales.pdf>

Gävert, H., Hurri, J., Särelä, J., & Hyvärinen, A. (2005). *FastICA*. Helsinki: Helsinki University of Technology. Retrieved from <https://research.ics.aalto.fi/ica/fastica/about.shtml>

Ghorbani, R., Azarnia, G., & Tinati, M. A. (2016). Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals. *Pattern Recognition Letters*, *70*, 45–51. Retrieved from <http://dx.doi.org/10.1016/j.patrec.2015.11.018> doi: 10.1016/j.patrec.2015.11.018

Haykin, S., & Chen, Z. (2005). The cocktail party problem. *Neural Computation*, *17*(9), 1875–1902. doi: 10.1162/0899766054322964

Hu, S., Wei, H., Chen, Y., & Tan, J. (2012). A real-time cardiac arrhythmia classification system with wearable sensor networks. *Sensors (Switzerland)*, *12*(9), 12844–12869. doi: 10.3390/s120912844

Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... Liu, H. H. (1998, mar). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, *454*(1971), 903–995. Retrieved from <https://royalsocietypublishing.org/doi/10.1098/rspa.1998.0193> doi: 10.1098/rspa.1998.0193

Hughes, N. P., Tarassenko, L., & Roberts, S. J. (2002). *Markov Models for Automated ECG Interval Analysis* (Tech. Rep.).

- Hyvärinen, A., Karhunen, J., & Oja, E. (2001). *Independent Component Analysis*. Helsinki: JOHN WILEY & SONS, INC. Retrieved from <https://www.cs.helsinki.fi/u/ahyvarin/papers/bookfinal{ }ICA.pdf>
- Hyvärinen, A., & Oja, E. (2000). *Independent Component Analysis: Algorithms and Applications* (Vol. 13; Tech. Rep. No. 5). Retrieved from <https://www.cs.helsinki.fi/u/ahyvarin/papers/NN00new.pdf>
- Jayaraman, S., Sangareddi, V., Periyasamy, R., Joseph, J., & Shanmugam, R. M. (2017). Modified limb lead ECG system effects on electrocardiographic wave amplitudes and frontal plane axis in sinus rhythm subjects. *Anatolian Journal of Cardiology*, *17*(1), 46–54. doi: 10.14744/AnatolJCardiol.2016.6843
- Jolliffe, I. (2002). *Principal Component Analysis, Second Edition* (2nd ed. ed.). Aberdeen: Springer. Retrieved from [http://cda.psych.uiuc.edu/statistical{ }learning{ }course/JolliffeI.PrincipalComponentAnalysis\(2ed.,Springer,2002\)\(518s\){ }MVsa{ }.pdf](http://cda.psych.uiuc.edu/statistical{ }learning{ }course/JolliffeI.PrincipalComponentAnalysis(2ed.,Springer,2002)(518s){ }MVsa{ }.pdf)
- Khalaf, A. F., Owis, M. I., & Yassine, I. A. (2015). A novel technique for cardiac arrhythmia classification using spectral correlation and support vector machines. *Expert Systems with Applications*, *42*(21), 8361–8368. Retrieved from <http://dx.doi.org/10.1016/j.eswa.2015.06.046> doi: 10.1016/j.eswa.2015.06.046
- Laguna, P., Jané, R., & Caminal, P. (1994). Automatic detection of wave boundaries in multilead ECG signals: Validation with the CSE database. *Computers and Biomedical Research*, *27*(1), 45–60. doi: 10.1006/cbmr.1994.1006
- Li, H., Yuan, D., Wang, Y., Cui, D., & Cao, L. (2016). Arrhythmia classification based on multi-domain feature extraction for an ECG recognition system. *Sensors (Switzerland)*, *16*(10). doi: 10.3390/s16101744
- López, J. F. (n.d.). *Varianza - Definición, qué es y concepto* | *Economipedia*. Retrieved 2019-04-22, from <https://economipedia.com/definiciones/varianza.html>

- Luz, E. J. d. S., Schwartz, W. R., Cámara-Chávez, G., & Menotti, D. (2016). ECG-based heartbeat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine*, 127, 144–164. Retrieved from <http://dx.doi.org/10.1016/j.cmpb.2015.12.008> doi: 10.1016/j.cmpb.2015.12.008
- Manka, R. (2017). *Arritmia cardíaca - Diagnóstico y tratamiento - Mayo Clinic*. Retrieved 2018-11-09, from <https://www.mayoclinic.org/es-es/diseases-conditions/heart-arrhythmia/diagnosis-treatment/drc-20350674>
- Martínez, A., Alcaraz, R., & Rieta, J. J. (2010, nov). Application of the phasor transform for automatic delineation of single-lead ECG fiducial points. *Physiological measurement*, 31(11), 1467–85. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/20871135> doi: 10.1088/0967-3334/31/11/005
- Martínez, J., Almeida, R., Olmos, S., Rocha, A. P., & Laguna, P. (2004). A Wavelet-Based ECG Delineator: Evaluation on Standard Databases. *IEEE Transactions on Biomedical Engineering*, 51(4). doi: 10.1109/TBME.2003.821031
- Martínez, M. A., & Morales, S. (n.d.). *Electrocardiografía Clínica Básica* (Tech. Rep.). Ciudad de México: Facultad de Medicina UNAM. Retrieved from <http://paginas.facmed.unam.mx/deptos/icm/images/cecam/04.p.otros/ELECTROCARDIOGRAFIA-CLINICA-BASICA.pdf>
- Meyer-Baese, A., & Schmid, V. (2014). Feature Selection and Extraction. In *Pattern recognition and signal analysis in medical imaging* (pp. 21–69). Elsevier. Retrieved from <https://linkinghub.elsevier.com/retrieve/pii/B9780124095458000029> doi: 10.1016/B978-0-12-409545-8.00002-9
- National Heart, Lung, & (NHLBI), B. I. (n.d.). *Arritmia*. Retrieved 2018-10-23, from <https://www.nhlbi.nih.gov/health-topics/espanol/arritmia>
- Navarro, X. (2002). Fisiología del sistema nervioso autónomo Peripheral nerve regeneration View project Pharmacological treatment for spasticity and neuropathic

- pain View project. *Revista Neurol*, 553–562. Retrieved from <https://www.researchgate.net/publication/228749829>
- Nielsen, M. (2018). *Neural Networks and Deep Learning* (Tech. Rep.). Retrieved from <http://neuralnetworksanddeeplearning.com> doi: 10.1201/b22400-15
- Noda, U. R., Komano, K. M., & Reali, A. T. (1996). *Anaerobically induced genes of Escherichia coli* (Vol. 5; Tech. Rep.). Retrieved from <http://www.saber.ula.ve/bitstream/handle/123456789/21743/articulo3.pdf?sequence=1&isAllowed=y>
- OMS. (2017). *Enfermedades cardiovasculares*. Retrieved 2018-10-23, from [http://www.who.int/es/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](http://www.who.int/es/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- Porteous, B. M. (1983). *Introduction to Digital Resampling*.
- Prieto, A. (n.d.). *Electrocardiograma*. Retrieved 2019-04-25, from <http://www.cenetec.gob.mx/cd{ }inter/guiapaciente/electrocardiograma.pdf>
- Rahhal, M. M. A., Bazi, Y., Alajlan, N., Malek, S., Al-Hichri, H., Melgani, F., & Zuair, M. A. A. (2015, may). Classification of AAMI heartbeat classes with an interactive ELM ensemble learning approach. *Biomedical Signal Processing and Control*, 19, 56–67. Retrieved from <https://linkinghub.elsevier.com/retrieve/pii/S1746809415000464> doi: 10.1016/j.bspc.2015.03.010
- Riedmiller, M. (1994). *Rprop - Description and Implementation Details* (Tech. Rep.). Karlsruhe. Retrieved from <http://www.inf.fu-berlin.de/lehre/WS06/Mustererkennung/Paper/rprop.pdf>
- Rojas, R. (1996). *The Backpropagation Algorithm 7.1 Learning as gradient descent* (Tech. Rep.). Berlin.
- Saini, I., & Saini, B. S. (2012). Cardiac Arrhythmia Classification Using Error Back Propagation Method. *International Journal of Computer Theory and Engineering*, 4(3), 462–464.

- Salah, H. (2015). Cardiac Arrhythmia Classification by Wavelet Transform. *International Journal of Advanced Research in Artificial Intelligence*, 4(5), 18–20.
- Salinas, H. (2011). *Clase 2: Estadística* (Tech. Rep.). Retrieved from <http://www.mat.uda.cl/hsalinas/cursos/2011/2do/clase2.pdf>
- Singh, Y. N., & Gupta, P. (2008). ECG to individual identification. In *Btas 2008 - iee 2nd international conference on biometrics: Theory, applications and systems*. doi: 10.1109/BTAS.2008.4699343
- Sun, Y., Chan, K. L., & Krishnan, S. M. (2005, sep). Characteristic wave detection in ECG signal using morphological transform. *BMC Cardiovascular Disorders*, 5. doi: 10.1186/1471-2261-5-28
- Svozil, D., Kvasnieka, V., & Pospichal, J. (1997). *Introduction to multi-layer feed-forward neural networks* (Vol. 39; Tech. Rep.).
- Tomasi, C. (2003). *Convolution, Smoothing, and Image Derivatives*. Durham. Retrieved from <https://www2.cs.duke.edu/courses/spring03/cps296.1/handouts/ImageProcessing.pdf>
- Tompkins, W., & Pan, J. (1985). A Real-Time QRS Detection Algorithm. *IEEE Transactions on Biomedical Engineering*, BME-32, 230–236.
- Torosa, A. (n.d.). *Sistema Cardiovascular* (Tech. Rep.). Barcelona: Col·legi Oficial Infermeres I Infermers Barcelona. Retrieved from <https://www.infermeravirtual.com/files/media/file/100/Sistematicardiovascular.pdf?1358605522>
- Übeyli, E. D. (2009). Combining recurrent neural networks with eigenvector methods for classification of ECG beats. *Digital Signal Processing: A Review Journal*, 19(2), 320–329. Retrieved from <http://dx.doi.org/10.1016/j.dsp.2008.09.002> doi: 10.1016/j.dsp.2008.09.002

Universo Formulas. (2016). *Media (promedio o media aritmética)*. Retrieved 2019-04-22, from <https://www.universoformulas.com/estadistica/descriptiva/media/>

Wang, J. S., Chiang, W. C., Hsu, Y. L., & Yang, Y. T. C. (2013). ECG arrhythmia classification using a probabilistic neural network with a feature reduction method. *Neurocomputing*, *116*, 38–45. Retrieved from <http://dx.doi.org/10.1016/j.neucom.2011.10.045> doi: 10.1016/j.neucom.2011.10.045