



Desarrollo de un Clasificador de Normalidad Cardíaca Basado en las Técnicas de Monitorización Ambulatoria de Electrocardiografía y Presión Arterial a Partir de Señales ECG

Carlos Santiago Erazo Rivera
Codigo: 20561914010

Universidad Antonio Nariño
Programa de Ingeniería Biomédica.
Facultad de Ingeniería Mecánica, Electrónica y Biomédica.
Popayán, Colombia
Cauca
2023

Desarrollo de un Clasificador de Normalidad Cardíaca Basado en las Técnicas de Monitorización Ambulatoria de Electrocardiografía y Presión Arterial a Partir de Señales ECG

Carlos Santiago Erazo Rivera

Proyecto de grado presentado como requisito parcial para optar al título de:
Ingeniero Biomédico

Director(a):
Ph.D., Guido Gómez Peña

Línea de investigación:
Bioinstrumentación, Procesamiento de bioseñales
Grupo de investigación:
Bioinstrumentación

Universidad Antonio Nariño
Programa de Ingeniería Biomédica.
Facultad de Ingeniería Mecánica, Electrónica y Biomédica.
Popayán, Cauca
2023

NOTA DE ACEPTACIÓN

El trabajo de grado titulado,
Desarrollo de un Clasificador de Normalidad Cardíaca
Basado en las Técnicas de Monitorización Ambulatoria
de Electrocardiografía y Presión Arterial a Partir de
Señales ECG, cumple con los requisitos para optar al
título de Ingeniero biomédico.

Firma del Director

Firma Jurado

Firma Jurado

Popayán, 24 de enero de 2024

El éxito es la suma de pequeños esfuerzos,
repetidos día tras día.

Robert Collier

Agradecimientos

En primer lugar, deseo expresar mi profundo agradecimiento a las personas que han sido mi mayor fuente de inspiración, guía y fuerza a lo largo de este viaje académico. A mi padre, Oveimar Erazo, a mi madre, Cristina Rivera, y a mi segunda madre, Monica Rosero, les agradezco por su apoyo incondicional y constante, mi gratitud por ser una presencia valiosa en mi vida, brindándome aliento y apoyo sin reservas. Sin ustedes, este logro no habría sido posible, cada día me esforce por ser mejor gracias a su amor y ejemplo.

Hoy, después de cinco años, los resultados de todo ese esfuerzo se vuelven visibles, y estoy agradecido por el impacto que han tenido en mi desarrollo personal y académico. También quiero rendir homenaje a aquellos que ya no están físicamente presentes pero que han sido fundamentales en mi camino. A mi abuelo Cornelio Erazo y mi abuela Elvira López, agradezco por su amor incondicional, sus sabios consejos y su apoyo constante. Aunque hayan partido, siento su presencia y se que cuidan de mí desde el cielo.

A mis profesores, les estoy profundamente agradecido por su contribución a mi crecimiento académico y personal. Agradezco su dedicación al compartir su conocimiento, su disposición para responder a mis preguntas y su constante estímulo para alcanzar metas más altas. En especial, quiero expresar mi más sincero agradecimiento a mi mentor, el PhD. Guido Gómez Peña. Su guía, paciencia y palabras de apoyo han sido fundamentales a lo largo del desarrollo de este proyecto de grado. Además, le agradezco por inspirarme a convertirme en investigador, motivarme para ser mejor y su disposición constante para resolver cualquier duda que se me presentó. Su influencia ha dejado una marca significativa en mi trayectoria académica y en mi desarrollo profesional.

Además quiero agradecer a mis amigos y seres queridos por su apoyo moral, así como por su impulso en los momentos de frustración y desánimo. Su presencia ha enriquecido mi experiencia y ha hecho posible superar los desafíos con determinación y gratitud.

Este logro no solo es mío, sino también de aquellos que han dejado una huella imborrable en mi corazón. Su legado y enseñanzas han sido mi luz en los momentos más oscuros. Agradezco a cada uno de ellos por ser mi inspiración y por contribuir a la persona que soy hoy.

Listado de símbolos y abreviaturas

AV Aurículo-Ventriculares

SL Semi-lunares

PA Presión Arterial

PAS Presión Arterial Sistólica

PAD Presión Arterial Diastólica

ACV Accidente Cerebro Vascular

SNA Sistema Nervioso Autónomo

BHS British Hypertension Society

ABP Presión Sanguínea Arterial

HTA Hipertensión Arterial

IA Inteligencia Artificial

EEG Electroencefalografía

NIBP Presión Arterial No Invasiva

RPG Regresión de Procesos Gaussianos

PG Proceso Gaussiano

Resumen

Desarrollo de un Clasificador de Normalidad Cardíaca Basado en las Técnicas de Monitorización Ambulatoria de Electrocardiografía y Presión Arterial a Partir de Señales ECG

Las enfermedades cardíacas e hipertensivas son unas de las principales causas de muerte en Colombia y el mundo. Debido a esto, se incluyen en los objetivos de desarrollo sostenible de la agenda 2030 de la OMS como una problemática de alta prioridad. En este sentido, el estudio de la dinámica cardíaca es esencial para comprender las enfermedades cardíacas y desarrollar diagnósticos y tratamientos efectivos, así la monitorización ambulatoria de presión arterial (MAPA) y el Holter cardíaco son técnicas importantes para evaluar la actividad cardíaca en condiciones diarias. Las enfermedades cardiovasculares y la hipertensión son problemas de salud significativos, y la falta de detección temprana es preocupante. El objetivo de este trabajo es desarrollar un algoritmo que combine señales de electrocardiografía (ECG) y la estimación de la Presión Arterial (PA) para clasificar la dinámica cardíaca como normal o anormal. El algoritmo se basa en el análisis de señales ECG y la estimación inteligente de la presión arterial a través de la derivada DII de esta señal. El propósito es mejorar el diagnóstico temprano y prevenir enfermedades cardiovasculares. Se emplea aprendizaje automático y la metodología cuantitativa para extracción y clasificación de datos. Como resultado del estudio, se derivaron dos modelos de regresión de procesos gaussianos (RPG) para estimar la presión arterial, específicamente el modelo de presión arterial sistólica exhibió un coeficiente de determinación (R^2) de 0.83 y un error cuadrático medio de 8.4, mientras que el modelo de presión arterial diastólica mostró un R^2 de 0.88 y un RMSE de 3.54. En conjunto, estos modelos de regresión arrojaron un RMSE acumulado de 11.94, cumpliendo así con los estándares establecidos por la Sociedad Británica de Hipertensión (BHS) y clasificándose como de tipo C. Por consiguiente, el modelo de estimación de la presión arterial posee la viabilidad para su implementación en entornos clínicos.

En lo que respecta al clasificador de normalidad cardíaca, se empleó un modelo de clasificación Bagged Trees que demostró una exactitud del 96.6%, permitiendo la clasificación efectiva de señales ECG normales entre cinco tipos de arritmias. Finalmente, a través de una clasificación binaria que considera los valores estimados de presión arterial, la frecuencia cardíaca y los resultados de la clasificación de normalidad, se determina si la

dinámica cardíaca se encuentra dentro de los parámetros normales o si presenta alguna anomalía mecánica o eléctrica.

Palabras clave: ECG, clasificador de normalidad ECG, Hipertensión, enfermedades cardíacas, análisis tiempo-frecuencia, algoritmos inteligentes

Abstract

Development of a Cardiac Normality Classifier Based on Ambulatory Electrocardiographic and Blood Pressure Monitoring Techniques from ECG Signals

Heart and hypertensive diseases are among the leading causes of death in Colombia and the world. Because of this, they are included in the Sustainable Development Goals of the WHO's 2030 agenda as a high priority issue. The study of cardiac dynamics is essential to understand heart disease and develop effective diagnostics and treatments. Ambulatory blood pressure monitoring (ABPM) and cardiac Holter are important techniques to assess cardiac activity under daily conditions. Cardiovascular disease and hypertension are significant health problems, and the lack of early detection is of concern. The aim of this work is to develop an algorithm that combines ECG and blood pressure estimation to classify cardiac dynamics as normal or abnormal. The algorithm is based on ECG signal analysis and intelligent blood pressure estimation through the DII derivative of this signal. The purpose is to improve early diagnosis and prevent cardiovascular diseases. Machine learning and quantitative methodology will be used for data extraction and classification. As a result of the study, two Gaussian process regression (GPR) models were derived to estimate blood pressure, specifically the systolic blood pressure model exhibited a coefficient of determination (R^2) of 0.83 and a mean square error of 8.4, while the diastolic blood pressure model showed an R^2 of 0.88 and an RMSE of 3.54. Together, these regression models yielded a cumulative RMSE of 11.94, thus meeting the standards established by the British Hypertension Society (BHS) and classifying as type C. Therefore, the blood pressure estimation model possesses the feasibility for implementation in clinical settings.

Regarding the cardiac normality classifier, a Bagged Trees classification model was employed and demonstrated an accuracy of 96.6%, allowing effective classification of normal ECG signals among five types of arrhythmias. Finally, through a binary classification that considers the estimated values of arterial pressure, heart rate and the results of the normality classification, it is determined whether the cardiac dynamics are within normal parameters or whether they present any mechanical or electrical abnormality.

Keywords: ECG, ECG normality classifier, Hypertension, heart disease, time-frequency analysis, smart algorithms

Lista de figuras

1.1. Esquema general de algoritmos de aprendizaje automático para la estimación de presión arterial. Adaptado de [1]	3
2.1. Sistema eléctrico del corazón. Tomado de [2]	10
2.2. Pulso de un ciclo cardiaco de la señal ABP. Adaptado de [3]	11
2.3. Triángulo de Einthoven. Tomado de [4]	14
2.4. Ondas e intervalos de la señal ECG. Tomado de [5]	15
2.5. diagrama de bloques algoritmo Pan-Tompkins. Adaptado de [6]	16
2.6. Etapas del algoritmo Pan-Tompkins. Adaptado de [6]	17
2.7. Estructura de una neurona artificial. Adaptado de [7]	23
3.1. Procedimiento de selección de registros MIMIC II/III.	29
3.2. Proceso general de extracción de características de la señal ECG y ABP. .	30
3.3. Proceso de extracción de características de la señal ECG con arritmias. . .	33
3.4. Proceso de extracción de características de la señal ECG y ABP.	37
3.5. Umbrales verticales para detección de valores máximos y mínimos de la señal ABP.	38
3.6. Proceso de estimación de los valores de presión arterial.	40
3.7. Proceso de evaluación de modelos de regresión.	41
3.8. Proceso de clasificación de normalidad cardíaca	42
3.9. Proceso de de evaluación de modelos de clasificación.	43
3.10. Separación de datos con validación cruzada con 4 interacciones. adaptado de [8]	44
3.11. Jumping jack. Tomado de [9]	45
4.1. valor estimado vs real - modelos de estimación de presión arterial.	51
4.2. Morfología de señales ECG que se clasifican	52
4.3. Clasificación de atributos usando algoritmo MRMR.	53
4.4. matriz de confusion Bagged Trees ampliada.	56

4.5. Curva ROC clase 0.	57
4.6. Curva ROC clase 1.	58
4.7. Curva ROC clase 2.	59
4.8. Curva ROC clase 3.	60
4.9. Curva ROC clase 4.	61
4.10. Matriz de confusión del modelo Bagged Trees - Test.	62
4.11. Toma de señal ECG y valores de presión arterial en reposo.	64
4.12. Período de ejercicio.	64
4.13. Toma de señales post ejercicio al paciente 6.	65
4.14. Comparación de Señal ECG paciente 2 en reposo y post-ejercicio.	66
4.15. Comparación de gráficas de presión paciente 2 en reposo y post-ejercicio.	67
4.16. Comparación de Señal ECG paciente 6 en reposo y post-ejercicio.	68
4.17. Comparación de gráficas de presión paciente 6 en reposo y post-ejercicio.	69
4.18. Comparación de valores de presión arterial medidos vs valores estimados	72

Lista de tablas

1.1. Técnicas de machine learnig citadas por Hammad et al. [10]	4
1.2. Comparación de tiempos de entrenamiento, precisión de clasificación y precisión con validación cruzada [11].	5
2.1. Clasificación de la PA en adultos. Tomado de [12]	12
2.2. Criterios de clasificación de la Sociedad Británica de Hipertensión (BHS). Tomado de [13].	13
2.3. Descripción de ondas, segmentos e intervalos de la señal ECG. Tomado de [14]	16
4.1. Muestra de valores de características temporales extraídas	46
4.2. Muestra de valores de características de complejidad extraídas	47
4.3. Distribución de clases para entrenamiento de los modelos de regresión	48
4.4. Evaluación de modelos de regresión de Matlab para estimar el valor de presión sistólica	48
4.5. Evaluación de modelos de regresión de Matlab para estimar el valor de presión diastólica	50
4.6. Distribución de clases	53
4.7. Evaluación de modelos de Clasificación de matlab	54
4.8. Comparación de métricas de evaluación de los modelos mejor valorados	55
4.9. Clases en matriz de confusión	55
4.10. Datos y valores de presión arterial de los pacientes	63
4.11. Comparación entre presión medida y presión estimada en reposo	69
4.12. Comparación entre presión medida y presión estimada después del ejercicio	71
4.13. Métricas del modelo de estimación de PAS al ser evaluado con datos de pacientes	73
4.14. Métricas del modelo de estimación de PAD al ser evaluado con datos de pacientes	73

Contenido

Agradecimientos	II
Listado de símbolos y abreviaturas	III
Resumen	IV
Abstract	VI
Lista de figuras	IX
Lista de tablas	X
Contenido	XIII
1. Aspectos generales del proyecto	1
1.1. Introducción	1
1.2. Antecedentes	2
1.3. Planteamiento del problema	5
1.4. Justificación	7
1.5. Objetivos	8
1.5.1. Objetivo General	8
1.5.2. Objetivos Específicos	8
2. Marco Teórico	9
2.1. El Corazón	9
2.1.1. Diástole	9
2.1.2. Sístole	9
2.1.3. Sistema eléctrico del corazón	10
2.2. Presión Arterial	10

2.2.1. Clasificación de la Presión Arterial	11
2.2.2. Hipertensión arterial	12
2.2.3. Monitorización Ambulatoria de Presión Arterial	12
2.2.4. British Hypertension Society (BHS)	13
2.3. Electrocardiograma	14
2.3.1. Derivaciones	14
2.3.2. Ondas e Intervalos en el ECG	15
2.4. Arritmias cardíacas	15
2.5. Algoritmo Pan–Tompkins	16
2.6. Medidas de complejidad	17
2.6.1. Parámetros de Hjorth	18
2.6.2. Dimensión fractal	19
2.6.3. Entropía de Shannon	19
2.7. Machine Learning	20
2.7.1. Modelos de regresión de procesos gaussianos	20
2.7.2. Redes neuronales	23
2.8. Base de datos	24
2.8.1. MIMMIC III	25
2.8.2. MIT-BIH Arrhythmia Database	25
2.8.3. PTB-XL+	25
2.8.4. CHARIS	26
3. Metodología	27
3.1. Recopilación de Datos	27
3.1.1. Selección de Bases de Datos de Señales ECG de Diversas Condi- ciones Cardíacas	27
3.1.2. Selección de Base de Datos de Señales ECG y PA	28
3.2. Extracción de Características de la señal ECG y ABP	28
3.2.1. Preprocesamiento	29
3.2.2. Algoritmo de extracción de características de las señales ECG con arritmias	32
3.2.3. Algoritmo de extracción de características de las señales ECG y ABP	36
3.3. Estimación de Valores de Presión Arterial	39
3.3.1. Evaluación de Modelos de Regresión en MATLAB	39
3.4. Desarrollo del Clasificador de Normalidad	40
3.4.1. Evaluación de Modelos de Clasificación en MATLAB	40

3.4.2. Clasificador corto	42
3.4.3. Clasificador Largo	42
3.5. Validación del Algoritmo de Estimación y Clasificador de Normalidad	43
3.6. Protocolo de toma de datos a pacientes	44
4. Resultados y análisis de resultados	46
4.1. Extracción de Características	46
4.1.1. Características de señales ECG con arritmias	46
4.1.2. Características para el entrenamiento del estimador de presión . . .	47
4.2. Estimador de presión Arterial	48
4.3. Clasificador de normalidad	51
4.4. Pruebas con pacientes	62
4.4.1. Toma de presión arterial y señal ECG	62
4.4.2. Prueba del estimador de presión arterial con datos de pacientes . .	68
5. Conclusiones	74
Referencias Bibliográficas	76
A. Anexo 1	81
A.1. Consentimiento Informado	81
B. Apéndice 1	83

1 Aspectos generales del proyecto

1.1 Introducción

El estudio de la dinámica cardíaca es fundamental para comprender las bases fisiológicas y patológicas de las enfermedades cardíacas, así como para el desarrollo de diagnósticos y tratamientos efectivos. Para esto, es fundamental replicar las condiciones de la vida diaria, para obtener información útil sobre la actividad eléctrica y mecánica del corazón y así detectar posibles trastornos o alteraciones en su funcionamiento con mayor fiabilidad. Esto, con el objetivo principal de contribuir en el campo de la cardiología, proporcionando conocimientos que ayudan a mejorar la salud y la calidad de vida de las personas.

A nivel mundial las enfermedades cardiovasculares (ECV) son la principal causa de muerte, ocasionando aproximadamente 17.9 millones de fallecimientos cada año [15]. Entre estas, la hipertensión arterial es uno de los principales factores de riesgo para las ECV y contribuye a alrededor de 7.5 millones de muertes al año en todo el mundo [16], [17], dado que causa daños en los vasos sanguíneos y en el músculo cardíaco (miocardio), lo que aumenta las probabilidades de desarrollar enfermedades cardíacas o empeorar una condición existente [18], [19]. Un dato que genera preocupación, entregado por la Organización Mundial de la Salud (OMS), es que el 46 % de los adultos hipertensos desconocen su condición y sólo uno de cada cinco la tiene bajo control [20]. La hipertensión a menudo se conoce como el asesino silencioso porque no presenta síntomas en las etapas iniciales y se diagnostica generalmente cuando ya han surgido complicaciones derivadas de esta [21], [22].

Debido al impacto significativo y al aumento en el número de casos de ECV e hipertensión arterial, estas problemáticas han sido incluidas como prioridades en los Objetivos de Desarrollo Sostenible de la OMS para el año 2030 [23]. En Colombia, según el Departamento Nacional de Estadística (DANE), se registraron aproximadamente 52.000 muertes relacionadas con ECV en 2021 [24]. Y al igual que lo reportado por la OMS, la hipertensión es una condición común en la población colombiana que muchos desconocen

padecer o no la controlan adecuadamente. Lo que evidencia la necesidad de controlar la presión arterial (PA) para prevenir y tratar enfermedades cardíacas. En ese sentido, el estudio de la dinámica cardíaca es fundamental para el desarrollo de técnicas, equipos médicos y métodos de monitorización continua para el diagnóstico temprano y control de las enfermedades cardiovasculares y la hipertensión arterial. Esto se debe a que el estudio de la dinámica cardíaca permite comprender los procesos y fenómenos relacionados con el funcionamiento del corazón y el flujo sanguíneo. Siendo este conocimiento necesario para desarrollar técnicas que permitan medir y analizar los parámetros cardíacos a fin de reconocer indicadores de la salud cardiovascular. Por una parte, la vigilancia continua de las variaciones en la PA en un contexto ambulatorio ha arrojado evidencia contundente en cuanto a su utilidad como marcador de hipertensión, en contraposición a las mediciones puntuales realizadas en entornos clínicos. Este enfoque adquiere relevancia debido a su capacidad para mitigar el efecto de la respuesta de "bata blanca", fenómeno que se manifiesta en aproximadamente el 20 % de los individuos con hipertensión, donde las lecturas elevadas de la PA resultan de la ansiedad asociada al entorno clínico más que de condiciones hipertensivas genuinas [25]. Para facilitar la evaluación de la hipertensión en un entorno ambulatorio, se necesitan nuevos métodos y dispositivos para la estimación no invasiva de la PA que, idealmente, evitarían la necesidad de un manguito insuflador.

Por otra parte, el análisis del ECG proporciona una técnica no invasiva para estudiar la actividad del corazón en diversas condiciones tales como: arritmias cardíacas, infarto de miocardio, isquemia cardíaca, miocardiopatías, condiciones de las válvulas cardíacas, alteraciones electrolíticas, entre otras [26]. Siendo que este análisis puede extenderse a una monitorización continua por periodos largos de tiempo (horas, inclusive días) a fin de encontrar anomalías durante la realización de actividades propias del sujeto.

1.2 Antecedentes

En la literatura científica, existen numerosas técnicas para la clasificación, identificación y diagnóstico de enfermedades cardiovasculares e hipertensión mediante el uso de equipos de monitorización continua como el holter. No obstante, hasta la fecha de este trabajo, no se ha encontrado en la literatura una técnica que incluya los valores de presión arterial como parámetros de entrada en los modelos de clasificación.

Asimismo, aunque existen numerosos artículos que detallan métodos para estimar la presión arterial (PA) de forma no invasiva a partir de la señal electrocardiográfica (ECG), no se ha encontrado en la literatura evidencia de la aplicación de estos métodos a las señales capturadas mediante un holter cardíaco con el fin de obtener una estimación de la tensión arterial ambulatoria (monitorización ambulatoria de presión MAPA).

A continuación, se mencionan los artículos más relevantes identificados en la búsqueda

bibliográfica:

En [1], Zhao et al. realizan una revisión de las tecnologías que permiten las plataformas de monitorización de la PA portátiles y sin brazaletes, abarcando tanto los nuevos diseños de sensores como los algoritmos de extracción de la PA. En la sección dedicada al análisis de modelos, se presentan los métodos algorítmicos contemporáneos de estimación de la PA para mediciones latido a latido y la extracción de la forma de onda de la PA continua. Se comparan los enfoques principales, como los modelos analíticos basados en el tiempo de tránsito del pulso (que requieren la correlación de 2 o más señales) y los métodos de aprendizaje automático, en términos de sus modalidades de entrada, características, algoritmos de implementación y desempeño.

Se puede notar que la mayoría de los algoritmos para la estimación de la presión arterial requieren el uso de más de un sensor, y solo el método descrito por Simjanoska et al. en [27] permite estimar la presión arterial utilizando exclusivamente parámetros extraídos de la señal ECG.

Además, se observa una metodología común para la estimación de la presión arterial en los métodos de aprendizaje automático, que se representa en la figura 1.1.

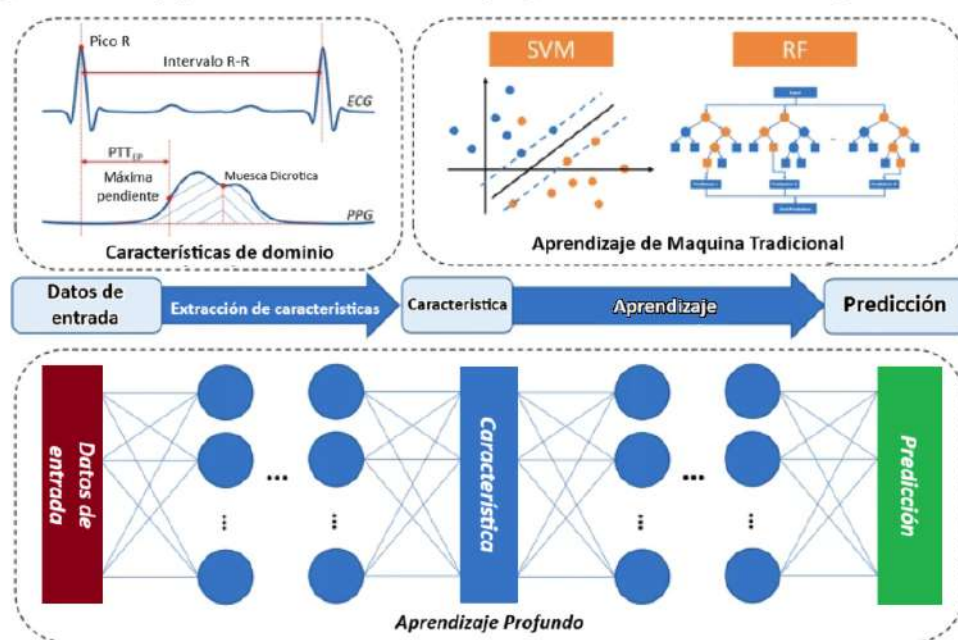


Fig. 1.1. Esquema general de algoritmos de aprendizaje automático para la estimación de presión arterial. Adaptado de [1]

Fan et al. en [28] destacaron la importancia de la monitorización de la PA a largo plazo en entornos domiciliarios y se señalan los problemas prácticos que presenta el método

tradicional con brazalete cuando se busca llevar a cabo un seguimiento continuo de la PA. En el artículo se propone la implementación de una red bidireccional de memoria a corto y largo plazo (BiLSTM) basada en la atención, con un esquema de ponderación, para estimar la presión arterial mediante el análisis y modelado de una sola derivación (DII) de la señal ECG. El porcentaje acumulativo de error de estimación (PAEE) clasifica al modelo de estimación de la PA como nivel B según el estándar de evaluación de dispositivos de medición PA de la *British Hypertension Society (BHS)*. ver tabla 2.2.

En el estudio llevado a cabo por Hammad et al. [10], se presenta un enfoque de aprendizaje profundo basado en el aprendizaje automático para la detección de infartos de miocardio (IM) y desórdenes de conducción (DC) utilizando un extenso conjunto de datos de electrocardiograma (ECG) obtenido de la base de datos PTB-XL de PhysioBank. Las señales de ECG de PTB-XL son sometidas a un proceso de filtrado, y las señales que contienen IM y DC son introducidas en un modelo de aprendizaje profundo, una red neuronal convolucional (CNN), para extraer características profundas. Estas características se utilizan posteriormente como entrada para un clasificador externo, en este caso, una máquina de vectores de soporte (SVM), con el fin de lograr la detección de IM y DC.

Los autores además, se llevaron a cabo una revisión bibliográfica de los métodos de detección automática de IM y DC, clasificándolos según su enfoque, en dos categorías, machine learning y deep learning. Las principales técnicas de machine learning citadas por los autores se muestran en la tabla 1.1.

Tabla. 1.1. Técnicas de machine learning citadas por Hammad et al. [10]

Artículo	Año	Base de datos	Clasificadores	% Precisión
Sharma et al.	2017	PTB	KNN SVM	81.71
Fatimah et al.	2021	PTB	FDM	99.65

En [11], Patiño et al. llevan a cabo una comparación y evaluación de los tiempos de aprendizaje y la precisión de los algoritmos de aprendizaje basados en redes neuronales artificiales (ANN), redes neuronales convolucionales (CNN) y XGBoost. Estos algoritmos se evalúan utilizando bases de datos de señales ECG clasificadas con arritmias e infartos agudos de miocardio de las bases de datos MIT-BIH y PTB de PhysioBank. El propósito principal de este estudio es determinar cuál de estos algoritmos es más adecuado para la clasificación de alteraciones cardíacas y si puede ser implementado en tiempo real. Los resultados de esta evaluación se presentan en la tabla 1.2 para facilitar la comparación de la validez y la fiabilidad de las predicciones.

Entre las conclusiones del estudio se destaca que las señales normales pueden ser reconocidas de manera consistente entre diferentes bases de datos, pero las señales de ECG anormales no son interoperables entre una base de datos y otra. Además, se

Tabla. 1.2. Comparación de tiempos de entrenamiento, precisión de clasificación y precisión con validación cruzada [11].

Criterio		ANN	CNN	XGBoost
Tiempo de entrenamiento		46 min	3h, 30 min	26 min
Precisión de clasificación	MIT-BIH	97 %	99 %	91 %
	PTB	97 %	99 %	93 %
Precisión con DB cruzada	Normal	83 %	-	85 %
	Arritmia	15 %	-	11 %

concluye que, a pesar del tiempo prolongado requerido para el entrenamiento, las redes neuronales convolucionales (CNN) muestran una precisión significativamente superior (99 %) en comparación con los otros algoritmos. Le siguen las redes neuronales artificiales (ANN) con un 97 % de precisión, mientras que el algoritmo XGBoost alcanza una precisión del 91 %.

En este sentido, la presente propuesta de investigación propone el desarrollo de un algoritmo de clasificación de normalidad de la dinámica cardíaca, cuyas características diferenciadoras son extraídas de la derivación DII de la señal ECG, en tanto y con base en esta, realizar el cálculo de la PA. Para cumplir con el propósito de la clasificación, diversas técnicas de inteligencia artificial serán testadas y puestas a disposición.

1.3 Planteamiento del problema

En casos de enfermedad cardíaca e hipertensión, se ha comprobado que la monitorización continua de las variables fisiológicas que influyen en la dinámica cardíaca proporciona indicadores mucho más sólidos en comparación con las mediciones aisladas realizadas en entornos clínicos [29].

La monitorización ambulatoria de la presión arterial (MAPA) generalmente se lleva a cabo durante períodos que oscilan entre 24 y 48 horas. Durante este período, se registran lecturas de la presión arterial cada 30 minutos durante el día y cada hora durante la noche. Esto se logra mediante un brazalete inflable colocado en el brazo, que se infla y libera gradualmente para medir la presión arterial [30]. Además de que las mediciones suelen ser ruidosas, incómodas y pueden alterar el sueño, un estudio realizado por Viera et al. [31] con 60 adultos reveló que el inflado del brazalete provocó alteraciones en el sueño en más del 70 % de los voluntarios, y aproximadamente un tercio de ellos declararon haber sufrido hematomas. Además, Wax et al. [32] evidencian diferencias significativas en las mediciones de presión arterial entre el método no invasivo de medición de presión arterial

(NIBP, mediante el uso de un brazalete) y el método invasivo (ABP), encontrando valores más altos de presión arterial con NIBP en casos de hipotensión y valores más bajos en casos de hipertensión. Estos hallazgos sugieren la necesidad de buscar nuevos métodos de medición que representen de manera precisa el comportamiento de la presión arterial cuando se registra de forma no invasiva.

En el campo de la cardiología, la evaluación de la normalidad de la dinámica cardíaca es esencial para la detección temprana de posibles trastornos cardíacos y la promoción de la salud cardiovascular [33].

La necesidad de llevar a cabo una monitorización continua de la dinámica cardíaca ha impulsado el desarrollo de algoritmos automáticos de identificación y clasificación. Estos algoritmos se centran en analizar tanto el ritmo como la morfología de la señal ECG, prestando especial atención a las variaciones que indican patologías en comparación con la normalidad. Sin embargo, es importante destacar que estos enfoques no han incorporado aún los valores de presión arterial como descriptor [10], [34, 35]. Así mismo, la revisión bibliográfica revela que existen diversas técnicas de procesamiento de señales que permiten extraer valores de PA a partir de la señal ECG, utilizando sólo una derivación. Sin embargo, hasta la presentación de esta propuesta, no se reportan desarrollos que alcancen la clasificación de grado médico, que realicen de forma unificada, la monitorización de ECG y MAPA al mismo tiempo. Sumado a lo anterior, al revisar los algoritmos de clasificación de señales ECG presentados en los antecedentes, se encuentra el uso de descriptores temporales, tiempo-frecuencia y estadísticos (HRV, RR medio, SDNN, SDANN, RMSSD, pNN50 %, PSD, AR, FFT, entre otros) [34], pero no se encontró el uso de los valores de PA como descriptor.

1.4 Justificación

Este trabajo integral de grado responde a la necesidad apremiante de avanzar en el desarrollo de algoritmos para el diagnóstico temprano de enfermedades cardiovasculares (ECV). En ese sentido, se plantea el objetivo principal de crear un algoritmo inteligente y escalable que combine la monitorización ambulatoria de electrocardiografía (ECG) y la presión arterial (PA) mediante la estimación de PA a partir de la señal ECG. Este algoritmo utilizará valores de estimación que cumplan con los estándares de la Sociedad Británica de Hipertensión (BHS) [13], junto con características temporales y de tiempo-frecuencia, como entrada para un sistema clasificador de la normalidad de la dinámica cardíaca. El propósito central es mejorar la capacidad de clasificar el riesgo cardiovascular al incorporar información sobre la presión arterial, ya que se reconoce su relación directa con las enfermedades cardíacas y su contribución a una mejor comprensión de la salud cardíaca general.

Esta técnica elimina la necesidad de utilizar un brazalete inflable para la medición no invasiva de la presión arterial, abordando así problemas de incomodidad y molestias reportados en la literatura [31]. Esto reduce significativamente la incomodidad experimentada por los pacientes y evita los riesgos asociados con el uso del brazalete y el inflado repetido.

El algoritmo propuesto no solo puede ser implementado para procesos de monitorización, sino que también incluye un clasificador de la normalidad de la dinámica cardíaca mediante algoritmos de machine learning. Esto proporcionará informes completos sobre la dinámica cardíaca de los usuarios, mejorando los modelos actuales de identificación y clasificación de arritmias cardíacas y contribuyendo a la creación de modelos predictivos más sólidos.

En última instancia, esta investigación tiene un impacto significativo en la promoción de la salud cardiovascular y en la mejora de la calidad de vida de las personas, al tiempo que contribuye a la reducción de los costos del sistema de salud mediante la prevención y el diagnóstico temprano. Esta alineación con los Objetivos de Desarrollo Sostenible, en particular el Objetivo 3, refleja el compromiso de esta propuesta con la promoción del bienestar y la vida saludable para todas las edades [23].

1.5 Objetivos

1.5.1 Objetivo General

Desarrollar un sistema de clasificación de normalidad de la dinámica cardíaca basado en señales cardíacas ECG mediante la combinación de las técnicas de holter cardíaco y monitorización ambulatoria de presión arterial (MAPA) con el fin de mejorar la capacidad de clasificar el riesgo cardiovascular al incorporar información sobre la presión arterial, ya que se reconoce su relación directa con las enfermedades cardíacas y su contribución a una mejor comprensión de la salud cardíaca general.

1.5.2 Objetivos Específicos

1. Implementar un algoritmo de extracción de características en el dominio del tiempo y tiempo -frecuencia de la dinámica cardíaca a través de la señal ECG.
2. Desarrollar un algoritmo inteligente para estimar los valores de PA empleando la señal ECG, garantizando que el margen de error en dicha estimación se ajuste a los criterios establecidos por el estándar British Hypertension Society (BHS) [13].
3. Implementar un algoritmo inteligente de clasificación de normalidad que tome como entradas, los valores de PA estimados y características temporales y espectrales extraídas.
4. Validar el algoritmo de estimación de PA y el clasificador de normalidad de la dinámica cardíaca, empleando conjuntos de datos recopilados mediante el uso del polifisiógrafo AdInstruments PowerLab 26T.

2 Marco Teórico

2.1 El Corazón

El corazón es un órgano muscular hueco que bombea sangre a todo el cuerpo, por acción de la contracción del miocardio, manteniendo el flujo sanguíneo unidireccional. Está compuesto por cuatro cámaras: dos aurículas y dos ventrículos. El corazón se divide en dos hemisferios por el tabique cardiaco, cada hemisferio cuenta con la unión de una aurícula y un ventrículo separada por una válvula aurículo-ventriculares (AV) que impide el retorno de la sangre del ventrículo a la aurícula y una válvula semilunar (SL) que impide el retorno desde las arterias a los ventrículos. El hemisferio derecho que recibe la sangre desoxigenada de las venas y la envía a los pulmones, el izquierdo que recibe la sangre oxigenada procedente de los pulmones y la envía hacia los tejidos del cuerpo mediante las arterias. [36]

Las aurículas y los ventrículos se contraen y relajan de forma ordenada y coordinada, produciendo un latido cardíaco rítmico. Cada latido cardíaco consta de dos partes

2.1.1 Diástole

Los ventrículos se relajan y se llenan de sangre mientras aurículas se contraen, vaciando la sangre el interior de los ventrículos. [36]

2.1.2 Sístole

Los ventrículos se contraen y bombean sangre del corazón mientras las aurículas se relajan, volviéndose a llenar de sangre. [36]

2.1.3 Sistema eléctrico del corazón

La activación mecánica del corazón responde a un sistema eléctrico de control de forma que el nódulo sinoauricular **(1)** inicia un impulso eléctrico que fluye a través de las aurículas derecha e izquierda **(2)** y las contrae. Cuando el impulso eléctrico alcanza el nódulo auriculoventricular **(3)**, este se retrasa ligeramente. El impulso desciende a través del haz de His **(4)**, que se divide en el haz derecho para el ventrículo derecho **(5)** y el haz izquierdo para el ventrículo izquierdo **(5)**. El impulso se propaga a continuación a través de los ventrículos y los contrae.




Fig. 2.1. Sistema eléctrico del corazón. Tomado de [2]

2.2 Presión Arterial

La sangre que sale del corazón se bombea a través de una red de vasos sanguíneos denominados arterias, generando una fuerza contra sus paredes. Esta fuerza se conoce como presión arterial (PA).

Los valores de PA se presentan como una relación de dos valores: la presión arterial sistólica (PAS), determinada por el impulso que generan las contracciones del ventrículo izquierdo y que indica cuánta presión está ejerciendo la sangre contra las paredes arteriales cuando el corazón se contrae; y la presión arterial diastólica (PAD), que depende de la resistencia que oponen las arterias al paso de la sangre e indica la presión ejercida contra las paredes cuando el corazón se relaja.

La PA depende de dos factores principales: el volumen de sangre que bombea el corazón y la resistencia al flujo que ofrecen las arterias y arteriolas. Estos factores están controlados por el sistema nervioso autónomo (SNA) que puede aumentar o disminuir la frecuencia cardíaca, el diámetro de las arterias, la viscosidad de la sangre, etc. Así mismo, el balance de agua y sal filtrado en los riñones también influye en la PA. Cuando el cuerpo retiene agua y sal, el volumen de sangre aumenta, lo que aumenta la PA. [37]

El cambio en la PA que se produce a lo largo del ciclo cardíaco se representa en la señal de presión sanguínea arterial (ABP), cuya morfología típica se muestra en la figura 2.2.




Fig. 2.2. Pulso de un ciclo cardíaco de la señal ABP. Adaptado de [3]

En la Figura 2.2 se observa que la PAS está representada por el pico máximo de la señal, mientras que la PAD se representa por el punto más bajo de la señal. También puede observarse una onda dicrótica de reflexión más pequeña producto de una onda refleja. [3]

2.2.1 Clasificación de la Presión Arterial

La presión arterial varía según la edad, género, raza y etnia, y generalmente tiende a aumentar con la edad. No existe un límite claro entre la presión arterial normal y la hipertensión arterial (HTA), pero de manera consensuada, se considera HTA cuando los valores son persistentemente iguales o superiores a 140/90 mmHg.

Para establecer una referencia en la clasificación de la presión arterial en adultos a lo largo de este trabajo, se adoptarán los niveles de presión arterial definidos en el informe del American College of Cardiology / American Heart Association [12]. Estos niveles se detallan en la Tabla 2.1.

Tabla. 2.1. Clasificación de la PA en adultos. Tomado de [12]

Categoría	PAS (mmHg)	Lógica	PAD (mmHg)
Normal	<120	Y	<80
Prehipertensión	120 - 139	O	80 - 89
Hipertensión			
Etapa 1	140 - 160	O	90 - 99
Etapa 2	>160	O	>100

2.2.2 Hipertensión arterial

La hipertensión arterial es una enfermedad que puede evolucionar sin manifestar ningún síntoma o presentar síntomas leves, por lo que se le conoce también como “el asesino silencioso”.

Lo anterior indica que se puede tener hipertensión arterial y no sentir ninguna manifestación. Por esta circunstancia, se estima que alrededor de un 46 % de los adultos hipertensos desconocen su condición y sólo uno de cada cinco la tiene bajo control [20].

A largo plazo, la HTA produce lesiones arteriales y sobrecarga cardíaca, que se traduce en daño cardiovascular. Todas las regiones de las arterias y arteriolas son susceptibles de sufrir el impacto de las altas presiones, produciendo accidentes cerebrales o ictus; infartos agudos de miocardio por afectación de las arterias coronarias; o nefropatías crónicas por enfermedad vascular hipertensiva. La hipertensión también puede afectar a los grandes vasos, generando aneurismas o lesiones que implican rigidez o estrechamiento en arterias periféricas. [3]

Algunas condiciones propias de cada persona, pueden favorecer el desarrollo de la hipertensión arterial. A estas condiciones se les conoce como factores de riesgo. Entre los que destacan: Exceso de peso, falta de actividad física, Consumo excesivo de sal y alcohol, Ingesta insuficiente de potasio, Tabaquismo, Estrés, Presión arterial fronteriza (130-139/85-89 mmHg) y antecedentes familiares de hipertensión. [37]

2.2.3 Monitorización Ambulatoria de Presión Arterial

El monitoreo ambulatorio de presión arterial (MAPA), también llamado holter de tensión arterial, es un método no invasivo que pretende obtener una medición de la presión arterial durante un periodo de 24 hasta 48 horas y de forma ambulatoria (siempre fuera de la consulta u hospital). Los datos de tensión arterial recogidos se dividen en dos períodos: diurno desde las 7:00 am hasta 10:00 pm y nocturno desde este horario hasta el

amanecer [38].

El monitoreo ambulatorio de presión arterial (MAPA) debe usarse para detectar hipertensión de bata blanca (PA alta en consulta pero PA fuera de servicio normal) e hipertensión enmascarada (PA normal en consulta pero PA alta fuera de la consulta) [18]. La hipertensión de capa blanca se asocia con un riesgo de ACV que se aproxima al de la PA normal, mientras que la hipertensión enmascarada conlleva un riesgo de ACV similar al de la hipertensión sostenida [12].

2.2.4 British Hypertension Society (BHS)

El estándar de la British Hypertension Society (BHS) [39] es ampliamente utilizado para evaluar dispositivos de medición y modelos de estimación de la presión arterial, incluido el propuesto en este proyecto. El estándar de la BHS clasifica el modelo de estimación de la presión arterial en niveles A, B o C según el porcentaje acumulado (PC) de errores de estimación que no superen los ± 5 , ± 10 y ± 15 mmHg, respectivamente [13]. (Ver tabla 2.2).

Tabla. 2.2. Criterios de clasificación de la Sociedad Británica de Hipertensión (BHS). Tomado de [13].

Categoría	Diferencia absoluta entre el modelo y el dispositivo de prueba (mmHg)		
	≤ 5	≤ 10	≤ 15
Porcentaje acumulativo de lecturas			
A	60	85	95
B	50	75	90
C	40	65	85
D	Peor que C		

Para medir el rendimiento del método de estimación de la PA propuesto, en el estudio se utiliza una métrica estimada de desviación global denominada error cuadrático medio (RMSE), que se define como:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |(y_i - \hat{y}_i)|^2} \quad (2.1)$$

Donde:

N es el número total de muestras.

y_i es el vector de valores reales.

\hat{y}_i es el vector de valores predichos.

Esta métrica se utiliza para evaluar cuán cerca están las estimaciones del modelo de los valores reales de la presión arterial. Un valor de RMSE más bajo indica una mejor precisión en las estimaciones.

2.3 Electrocardiograma

Es el trazado de la actividad eléctrica de las células del corazón. Un electrocardiograma (ECG) Registra en papel los cambios que ocurren en las pequeñas corrientes eléctricas que se producen en el corazón con cada latido. Se utiliza para el diagnóstico y la evaluación de las afecciones cardíacas [40].

2.3.1 Derivaciones

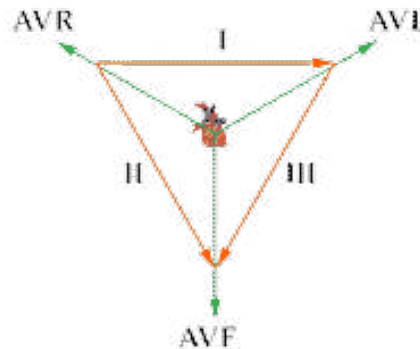


Fig. 2.3. Triángulo de Einthoven. Tomado de [4]

Las derivaciones del ECG pueden ser monopolares (AVI, AVR, AVf) o bipolares (DI, DII, DIII) y vienen dadas por el triángulo de Einthoven ilustrado en la Figura 2.3. El triángulo de Einthoven establece los vértices del triángulo (RA, LA, LL) de referencia para la ubicación de los electrodos para el ECG y una referencia de tierra. En todas las conexiones de

derivación, la diferencia de potencial medida entre dos electrodos se refiere siempre a un tercer punto del cuerpo [41].

2.3.2 Ondas e Intervalos en el ECG

El registro electrocardiográfico, manifestado en la señal ECG se compone de cinco ondas (P,Q,R,S,T), dos segmentos (PR, ST) y dos intervalos (PR, QT), Descritos en la tabla 2.3. La amplitud y duración de estas ondas brindan información valiosa al personal de salud para analizar el funcionamiento del corazón y emitir un diagnóstico.

La representación de la actividad eléctrica en un ciclo cardíaco normal se puede apreciar en la Figura 2.3.




Fig. 2.4. Ondas e intervalos de la señal ECG. Tomado de [5]

2.4 Arritmias cardíacas

Una arritmia es cualquier alteración en el ritmo normal de contracción del corazón. Detectar estas irregularidades tempranamente y proporcionar una advertencia anticipada de su inicio puede permitir el tratamiento y la reversión de episodios peligrosos. En ocasiones, puede ocurrir irritación en los ventrículos, lo que provoca que el impulso se propague por un camino más lento y diferente en lugar de pasar a través del nodo AV. Esto resulta en un ensanchamiento del complejo QRS y se clasifica como ritmo ectópico ventricular [41].

El análisis minucioso de los registros de ECG ha revelado que las anomalías en el funcionamiento cardíaco se reflejan en la forma de las ondas de ECG. Las arritmias se pueden detectar de dos maneras:

Tabla. 2.3. Descripción de ondas, segmentos e intervalos de la señal ECG. Tomado de [14]

Nombre		Descripción
Onda	P	Representa la despolarización auricular
	QRS	Representa la despolarización ventricular, la onda de la repolarización auricular queda oculta por el complejo QRS
	T	Representa la repolarización ventricular.
Segmento	PR	Período entre el comienzo de la despolarización auricular y la despolarización ventricular.
	ST	Representa la despolarización completa del miocardio ventricular.
Intervalo	PR	Intervalo entre el comienzo de la despolarización auricular y la despolarización ventricular.
	QT	Intervalo entre el comienzo de la despolarización ventricular y el final de la repolarización ventricular.

1. Evaluando la morfología de la señal del ECG, que se basa en el análisis de las formas de onda del ECG para describir el funcionamiento de las masas musculares.
2. Examinando el ritmo de la señal del ECG, que se enfoca en la localización y velocidad del marcapasos cardíaco y la propagación de los impulsos a través del sistema de conducción.

2.5 Algoritmo Pan–Tompkins

El algoritmo Pan-Tompkins es una técnica de procesamiento de señales diseñada para la detección de complejos QRS en electrocardiogramas (ECG). Su principal objetivo es identificar los picos característicos que representan la actividad eléctrica del corazón, lo que facilita la medición de la frecuencia cardíaca y la detección de arritmias cardíacas. El proceso se basa en una serie de etapas de procesamiento, como se muestra en la Figura 2.5. El algoritmo consta de las siguientes etapas:

**Fig. 2.5.** diagrama de bloques algoritmo Pan-Tompkins. Adaptado de [6]

Filtrado: En esta etapa, se aplica un filtro paso banda (entre 5 y 15 Hz) para resaltar las componentes de frecuencia del complejo QRS. Esto ayuda a reducir las falsas detecciones

causadas por interferencias presentes en las señales ECG.

Derivador: Se calcula la derivada de la señal filtrada para resaltar los cambios rápidos. Esto permite diferenciar la onda R de las ondas T y P, ya que su cambio suele ser más brusco y de mayor pendiente.

Cuadrado y ventana móvil de integración: La señal se eleva al cuadrado para convertirla en positiva y resaltar los picos. Luego, se aplica una ventana móvil de integración para suavizar la señal y obtener una representación simplificada de los picos, en particular, para detectar el pico del complejo QRS, es decir, la onda R.

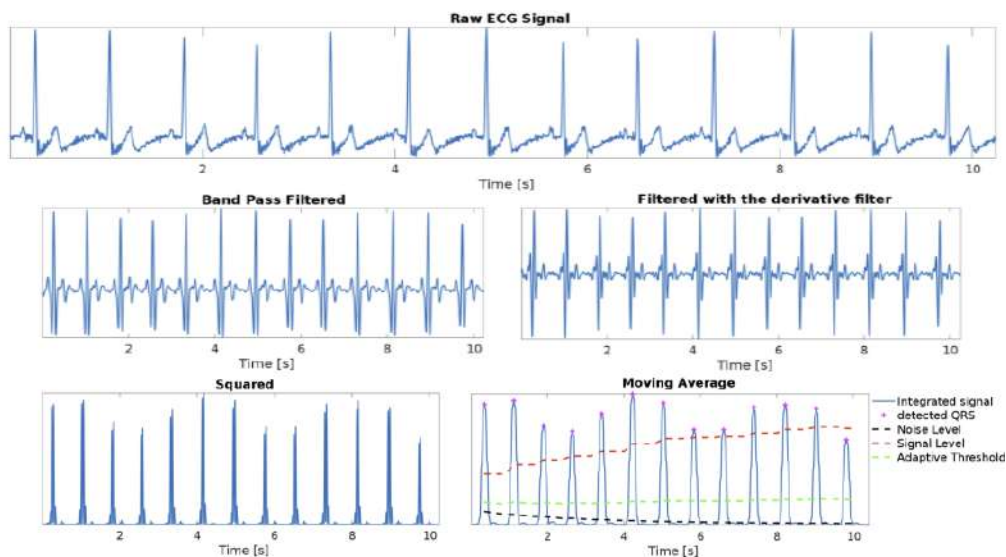


Fig. 2.6. Etapas del algoritmo Pan-Tompkins. Adaptado de [6]

2.6 Medidas de complejidad

Las medidas de complejidad de señal son métricas o indicadores utilizados para cuantificar y evaluar la complejidad de una señal, es decir, la cantidad de estructura, variabilidad y características no aleatorias que contiene una señal.

2.6.1 Parámetros de Hjorth

Los parámetros de Hjorth son una familia de parámetros estadísticos que se utilizan para caracterizar las propiedades del dominio del tiempo de una señal. Se utilizan comúnmente en el análisis de señales bioeléctricas para describir y diferenciar diferentes estados o condiciones basados en las propiedades de la señal. El análisis de estos parámetros de Hjorth puede ayudar en la caracterización de señales bioeléctricas, detectar anomalías, y evaluar la complejidad de una bioseñal [42].

Movilidad de la señal

La movilidad de la señal es una medida de la frecuencia media de una señal. Se calcula como la raíz cuadrada de la relación entre la varianza de la primera derivada de la señal y la varianza de la señal.

$$Mobility = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N \dot{x}_i^2}}{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}} \quad (2.2)$$

Donde:

\dot{x}_i representa cada uno de los elementos de la primera derivada de la señal.

x_i representa cada uno de los elementos de la señal.

N es la longitud de la señal.

Complejidad de la Señal

La complejidad de la señal es una medida del ancho de banda de una señal. Se calcula como la relación entre la movilidad de la primera derivada de la señal y la movilidad de la señal.

$$Complexity = \frac{Mobility(\dot{x}_i)}{Mobility(x)} \quad (2.3)$$

2.6.2 Dimensión fractal

La dimensión fractal es una medida de la autosimilitud de una señal. Una señal autosimilar es una señal que se parece a sí misma a diferentes escalas. Esto significa que la señal tiene patrones fundamentales que se repiten a lo largo de la señal. Para este trabajo la dimensión fractal será calculada haciendo uso del método de Higuchi [43] [44] con el parámetro $k = 60$, siguiendo la indicación de [45].

La señal se divide en subseries temporales de longitud k . Esto implica tomar segmentos consecutivos de la señal, cada uno de longitud k . Estas subseries temporales se utilizan para calcular la longitud media $L(k)$.

$$L(k) = \frac{1}{(N-k)k} \sum_{m=1}^{N-k} \sum_{i=0}^{k-1} |x(m+i) - x(m+i+k)| \quad (2.4)$$

teniendo la longitud media $L(k)$, se calcula la dimensión fractal

$$D_k = \frac{\log \frac{N}{k}}{\log(k \cdot L(k))} \quad (2.5)$$

Donde:

- D_k es la dimensión fractal de Higuchi.
- $L(k)$ es la longitud media de las subseries temporales en la escala k .
- N es el número total de puntos en la serie temporal.
- k es la longitud de cada subserie temporal utilizada en el cálculo.
- $x(m)$ es el valor en el punto m de la serie temporal..

2.6.3 Entropía de Shannon

La aleatoriedad de la señal se expresa a través de la entropía. La disminución de la entropía suele indicar una enfermedad [46]. La Entropía se define como una medida de incertidumbre promedio [47]. Sea P_i la probabilidad de cada resultado x_i dentro de la señal para $i = 1, \dots, N - 1$. Entonces, la entropía se calcula como:

$$Entropy = \sum_{i=0}^{N-1} p_i \log\left(\frac{1}{p_i}\right) \quad (2.6)$$

2.7 Machine Learning

El machine learning (aprendizaje automático) representa una faceta de la inteligencia artificial (IA) que capacita a un sistema para aprender a partir de datos en lugar de depender únicamente de la programación explícita. No obstante, el proceso de machine learning es intrincado. A medida que el algoritmo se nutre de datos de entrenamiento, tiene la capacidad de crear modelos más precisos basados en la información contenida en esos datos. En el aprendizaje automático, un 'modelo' se refiere a la salida de información que se produce al entrenar un algoritmo con datos específicos. Una vez que el modelo ha sido entrenado, al proporcionarle una entrada, este será capaz de generar una salida correspondiente [48].

Aprendizaje supervisado El aprendizaje supervisado inicia con un conjunto de datos predefinido y un conocimiento previo sobre cómo se clasifican estos datos. Su objetivo principal es descubrir patrones en los datos que puedan aplicarse en análisis posteriores. Estos datos están caracterizados por etiquetas que proporcionan información sobre el significado de los datos [48].

Aprendizaje no supervisado El aprendizaje no supervisado se utiliza cuando se manejan grandes volúmenes de datos sin etiquetas, empleando algoritmos para clasificar datos basados en patrones y clústeres sin intervención humana [48].

2.7.1 Modelos de regresión de procesos gaussianos

Los modelos de regresión de procesos gaussianos (RPG) son modelos probabilísticos no paramétricos basados en núcleos (kernels). Dado un conjunto de datos de entrenamiento $D = (x_i, y_i), i = 1, \dots, n$ donde x_i es el vector de entrada e y_i la salida real, extraída de una distribución desconocida. Un modelo RPG aborda la cuestión de predecir el valor de una variable de respuesta y_{nuevo} dado el nuevo vector de entrada x_{nuevo} y los datos de entrenamiento. Un modelo de regresión lineal es de la forma

$$y = x^T \beta + \epsilon \quad (2.7)$$

donde $\epsilon \sim N(0, \sigma^2)$. La varianza del error σ^2 y los coeficientes β se estiman a partir de los datos. Un modelo RPG explica la respuesta introduciendo variables latentes, $f(x_i)$, $i = 1, 2, \dots, n$, de un proceso gaussiano (PG), y funciones base explícitas, h . La función de covarianza de las variables latentes captura la suavidad de la respuesta y las funciones base proyectan las entradas x en un espacio de características p -dimensional.

Un PG es un conjunto de variables aleatorias, tal que cualquier número finito de ellas tiene una distribución gaussiana conjunta. Si $\{f(x), x \in \mathbb{R}^d\}$ es un PG, entonces dadas n observaciones x_1, x_2, \dots, x_n , la distribución conjunta de las variables aleatorias $f(x_1), f(x_2), \dots, f(x_n)$ es gaussiana. Un PG se define por su función media $m(x)$ y su función de covarianza, $k(x, x')$. Es decir, si $\{f(x), x \in \mathbb{R}^d\}$ es un proceso gaussiano, entonces $E(f(x)) = m(x)$ y $Cov[f(x), f(x')] = E[f(x) - m(x)f(x') - m(x')] = k(x, x')$.

Consideremos ahora el siguiente modelo:

$$h(x)^T \beta + f(x) \quad (2.8)$$

donde $f(x) \sim GP(0, k(x, x'))$, es decir, $f(x)$ proviene de un Proceso Gaussiano con media cero y función de covarianza $k(x, x')$. $h(x)$ son un conjunto de funciones base que transforman el vector de características original x en \mathbb{R}^d en un nuevo vector de características $h(x)$ en \mathbb{R}^p . β es un vector $p \times 1$ de coeficientes de funciones base. Este modelo representa un modelo de Regresión de Proceso Gaussiano (RPG). Una instancia de respuesta y_i puede modelarse como

$$P(y_i | f(x_i), x_i) \sim \mathcal{N}(y_i | h(x_i)^T \beta + f(x_i), \sigma^2). \quad (2.9)$$

Por lo tanto, un modelo de Regresión de Proceso Gaussiano (RPG) es un modelo probabilístico. Hay una variable latente $f(x_i)$ introducida para cada observación x_i , lo que hace que el modelo de Regresión de Proceso Gaussiano (RPG) sea no paramétrico. En forma vectorial, este modelo es equivalente a

$$P(y | f, X) \sim \mathcal{N}(y | H\beta + f, \sigma^2 I), \quad (2.10)$$

Por lo tanto, un modelo GPR es un modelo probabilístico. Se introduce una variable latente $f(x_i)$ para cada observación x_i , lo que hace que el modelo GPR no sea paramétrico. En forma vectorial, este modelo equivale a:

$$P(y | f, X) \sim \mathcal{N}(y | H\beta + f, \sigma^2 I),$$

donde

$$X = \begin{pmatrix} x_1^T \\ x_2^T \\ \vdots \\ x_n^T \end{pmatrix}, y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, H = \begin{pmatrix} h(x_1^T) \\ H(x_2^T) \\ \vdots \\ h(x_n^T) \end{pmatrix}, f = \begin{pmatrix} f(x_1) \\ f(x_2) \\ \vdots \\ f(x_n) \end{pmatrix}.$$

La distribución conjunta de las variables latentes $f(x_1), f(x_2), \dots, f(x_n)$ en el modelo RPG es la siguiente:

$$P(f|X) \sim \mathcal{N}(f|0, K(X, X))$$

cercano a un modelo de regresión lineal, donde $K(X, X)$ tiene el siguiente aspecto:

$$K(X, X) = \begin{pmatrix} k(x_1, x_1) & k(x_1, x_2) & \cdots & k(x_1, x_n) \\ k(x_2, x_1) & k(x_2, x_2) & \cdots & k(x_2, x_n) \\ \vdots & \vdots & \vdots & \vdots \\ k(x_n, x_1) & k(x_n, x_2) & \cdots & k(x_n, x_n) \end{pmatrix}. \quad (2.11)$$

La función de covarianza $k(x, x')$ suele estar parametrizada por un conjunto de parámetros del núcleo(kernel) o hiperparámetros, θ . A menudo, $k(x, x'|\theta)$ se escribe así para indicar explícitamente la dependencia de θ [49].

En *Matlab*, la función *fitrgp* estima los coeficientes de la función base, β , la varianza del ruido, σ^2 y los hiperparámetros, θ , de la función kernel a partir de los datos mientras se entrena el modelo RPG. a su vez, el usuario puede especificar la función base, la función kernel (covarianza) y los valores iniciales de los parámetros [50].

Kernel exponencial cuadrado

cualquier función kernel se puede usar como función de covarianza.

$$k_{SE}(x, x') = \exp\left(-\frac{1}{2\tau^2} \|x - x'\|^2\right) \quad (2.12)$$

Donde:

- $h(x)$ y $h(x')$ tienen alta covarianza cuando x y x_0 están cercanos en el espacio de entrada, i.e., $\|x - x'\| = |x - x'| \approx 0$ y $k_{SE}(x, x') = \exp(-\frac{1}{2\tau^2} \|x - x'\|^2) \approx 1$
- $h(x)$ y $h(x')$ tienen baja covarianza cuando x y x_0 están separados en el espacio de entrada, i.e., $\|x - x'\| \gg 0$ y $k_{SE}(x, x') = \exp(-\frac{1}{2\tau^2} \|x - x'\|^2) \approx 0$ [51]

2.7.2 Redes neuronales

Las redes neuronales, son modelos matemáticos bioinspirados en el funcionamiento del cerebro humano para realizar tareas de aprendizaje automático. Las redes neuronales utilizan un enfoque más generalizado y adaptable para aprender y realizar funciones, mediante un proceso de aprendizaje continuo.

De acuerdo a la estructura de una red neuronal se puede dividir en tres capas que conectadas entre sí a través de pesos sinápticos. La capa de entrada: responsable de recibir datos del entorno externo. La capa oculta: compuesta por neuronas que se encargan de extraer patrones asociados al sistema que se está analizando. La capa de salida: compuesta por neuronas y por lo tanto es responsable de producir y presentar las salidas finales de la red [52].

Cada neurona dentro de una red neuronal realiza una operación matemática que implica una suma ponderada de las entradas que recibe, utilizando pesos que representan la importancia de cada entrada. Esta suma ponderada se somete a una función de activación no lineal que introduce la capacidad de la red para modelar relaciones complejas y no lineales en los datos. La estructura de una red neuronal se muestra a continuación. (ver figura 2.7).

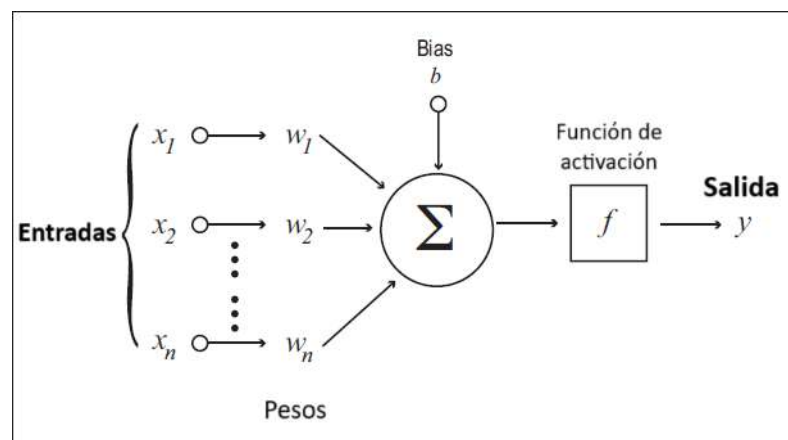


Fig. 2.7. Estructura de una neurona artificial. Adaptado de [7]

su modelo matemático se describe como:

$$y = f\left(\sum_{i=1}^n w_i \cdot x_i + b\right) \quad (2.13)$$

Donde:

y es la salida de la neurona.

x_i son las entradas.

w_i son los pesos correspondientes a las entradas.

b es el sesgo (bias).

f es la función de activación, que introduce no linealidad en la neurona..

La elección de la función de activación determina cómo la neurona responde a la entrada y es fundamental para la capacidad de aprendizaje de la red neuronal.

2.8 Base de datos

PhysioBank alberga más de 90,000 grabaciones, equivalentes a más de 4 terabytes de señales fisiológicas digitalizadas y series temporales, organizadas en más de 80 bases de datos. Estas bases de datos se dividen en dos categorías principales:

Bases de Datos Clínicas: Contienen datos de entornos clínicos de cuidados intensivos, incluyendo datos demográficos, mediciones de constantes vitales, resultados de pruebas de laboratorio, procedimientos médicos, medicaciones, notas del cuidador, imágenes e informes de diagnóstico por imagen, y mortalidad (hospitalaria y extrahospitalaria).

Bases de Datos de Formas de Onda: Consisten en registros continuos de alta resolución de señales fisiológicas. Estas bases de datos se organizan según los tipos de señal y anotación, e incluyen:

- Bases de datos multiparamétricas que pueden contener señales como ECG, presión arterial invasiva continua, respiración, saturación de oxígeno y EEG, entre otras.
- Bases de datos de ECG.

- Bases de datos de intervalos entre latidos (RR) que contienen anotaciones de latidos obtenidas a partir de grabaciones de ECG.
- entre otras.

2.8.1 MIMMIC III

La base de datos de formas de onda MIMIC-III contiene 67.830 registros de aproximadamente 30.000 pacientes de la UCI. Casi todos los conjuntos de registros incluyen un registro de forma de onda que contiene señales digitalizadas (que suelen incluir ECG, PAA, respiración y SpO2, y con frecuencia otras señales) y un registro "numérico" que contiene series temporales de mediciones periódicas, cada una de las cuales presenta un registro casi continuo de las constantes vitales de un único paciente a lo largo de una estancia en la UCI (normalmente de unos pocos días, pero muchas tienen una duración de varias semanas) [53].

2.8.2 MIT-BIH Arrhythmia Database

La base de datos de arritmias MIT-BIH contiene 48 extractos de media hora de registros de ECG ambulatorios de dos canales, obtenidos de 47 sujetos estudiados por el Laboratorio de Arritmias BIH entre 1975 y 1979. Veintitrés registros fueron elegidos al azar de un conjunto de 4000 registros de ECG ambulatorios de 24 horas recogidos de una población mixta de pacientes hospitalizados (alrededor del 60 %) y ambulatorios (alrededor del 40 %) en el Hospital Beth Israel de Boston; los 25 registros restantes fueron seleccionados del mismo conjunto para incluir arritmias menos comunes pero clínicamente significativas que no estarían bien representadas en una pequeña muestra aleatoria [54].

2.8.3 PTB-XL+

La base de datos PTB-XL+ es un completo conjunto de datos de características que complementa al conjunto de datos de ECG PTB-XL. Incluye características de ECG extraídas mediante dos algoritmos comerciales y uno de código abierto en un formato armonizado, así como latidos medios o, en su caso, puntos fiduciales extraídos por los algoritmos respectivos. Además, proporciona declaraciones de diagnóstico automático de un algoritmo comercial de análisis de ECG en diferentes niveles de procesamiento que están listas para ser utilizadas para el entrenamiento y la evaluación de modelos de aprendizaje automático [55].

2.8.4 CHARIS

La base de datos CHARIS contiene registros multicanal de ECG, presión arterial (PA) y presión intracraneal (PIC) de pacientes diagnosticados de traumatismo craneoencefálico (TCE). Los datos son aportados por miembros del proyecto CHARIS, cuyo objetivo es sistematizar el análisis de señales fisiológicas relevantes y crear algoritmos basados en datos para buscar posibles predictores de eventos clínicos agudos en pacientes con lesión cerebral aguda [56].

3 Metodología

La metodología que guiará este proyecto es de naturaleza cuantitativa, comparativa y correlacional. La elección de esta metodología permitirá obtener mediciones precisas y generalizables de las señales de ECG, analizar diferencias y similitudes en patrones cardíacos entre grupos de pacientes, y explorar las relaciones entre diversas variables cardíacas. Esta combinación de enfoques enriquecerá la investigación, brindando una comprensión más completa y robusta de la normalidad cardíaca y sentando las bases para un clasificador efectivo.

Para alcanzar los objetivos propuestos se establecen las siguientes etapas:

3.1 Recopilación de Datos

Para llevar a cabo este proyecto, se optó por utilizar bases de datos de acceso público disponibles en línea, las cuales fueron adquiridas a través de la plataforma "PhysioBank". Esta plataforma alberga una colección de más de 90,000 grabaciones de señales fisiológicas digitalizadas y series temporales, organizadas en más de 80 bases de datos diferentes.

3.1.1 Selección de Bases de Datos de Señales ECG de Diversas Condiciones Cardíacas

Después de llevar a cabo una exhaustiva revisión bibliográfica, se han elegido dos bases de datos específicas, MIT-BIH [54] y PTB-XL [55], para realizar el entrenamiento del modelo de clasificación de la normalidad de la dinámica cardíaca. La elección de estas bases de datos se basa en su amplia citación en la literatura científica [57].

La base de datos MIT-BIH consiste en registros de electrocardiograma (ECG) de

pacientes con arritmias cardíacas. Por otro lado, la base de datos PTB-XL es más reciente y abarca una diversidad de registros de ECG de una amplia gama de pacientes, incluyendo aquellos con arritmias cardíacas. La razón principal detrás de la selección de estas bases de datos radica en que contienen una amplia diversidad de registros de pacientes con arritmias, lo cual permite entrenar un modelo robusto y generalizable capaz de lidiar con nuevos datos de manera efectiva.

3.1.2 Selección de Base de Datos de Señales ECG y PA

Por otro lado, para el entrenamiento del modelo de estimación de la presión arterial, se ha decidido utilizar las bases de datos MIMIC II/III [53] y CHARIS DB [56]. Estas bases de datos han sido seleccionadas debido a que contienen registros de pacientes que incluyen tanto la derivada DII de la señal ECG como los registros de la señal ABP, lo que resulta fundamental para los objetivos de este proyecto.

En el caso de la base de datos MIMIC II/III, que abarca diversos registros de señales fisiológicas, y no siempre se encuentran disponibles simultáneamente la derivada DII de la señal ECG y la señal ABP. Para seleccionar los registros pertinentes, se implementó un procedimiento detallado en la figura 3.1.

3.2 Extracción de Características de la señal ECG y ABP

La presente sección se dedica a detallar el proceso de preprocesamiento de las señales fisiológicas extraídas de los registros. El objetivo principal es la extracción de características relevantes tanto de la señal ECG como de la señal ABP. El preprocesamiento y procesamiento de los datos de los registros de señales ECG y ABP se realiza utilizando el software de cálculo y computación científico para ingeniería MATLAB (MathWorks, MA, USA).

En la figura 3.2 se muestra el proceso general de extracción de características de las señales ECG y ABP

En el desarrollo de este TIG, utiliza dos grupos de bases de datos, cada uno con una frecuencia de muestreo distinta. El primer grupo consta de señales ECG en derivación DII y señales de presión arterial invasiva (ABP) usados en 3.2.3, mientras que el segundo grupo incluye señales ECG de la derivación DII que presentan arritmias cardíacas, usados en 3.2.2.

A continuación, se detallan dos algoritmos fundamentales utilizados para la extracción

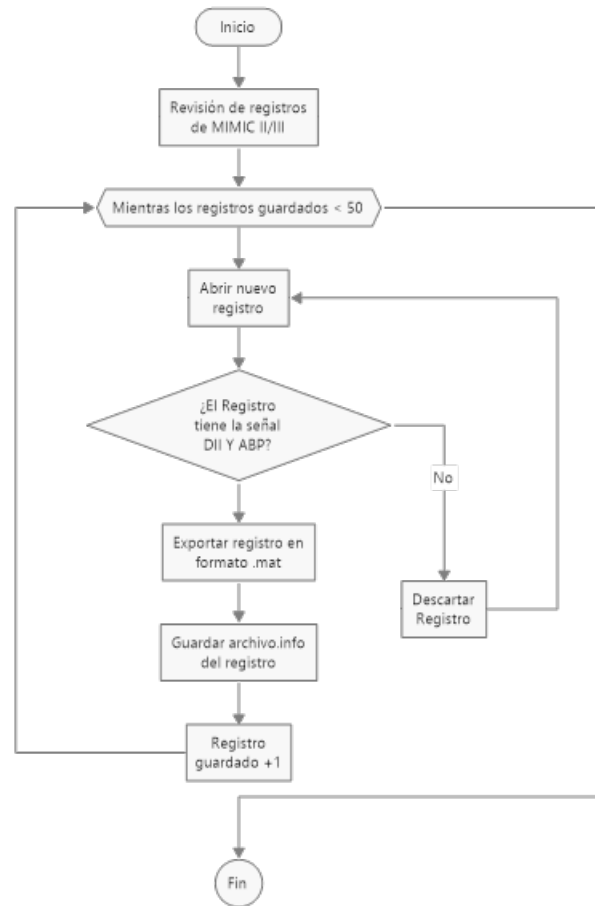


Fig. 3.1. Procedimiento de selección de registros MIMIC II/III.

de características en el proceso de entrenamiento del estimador de presión y el clasificador de normalidad. Ambos algoritmos comparten una etapa inicial de preprocesamiento, aunque presentan algunas diferencias particulares, las cuales se describen de manera específica en las secciones correspondientes a cada uno de ellos.

3.2.1 Preprocesamiento

En el caso de los registros del primer grupo, es importante destacar que el proceso de preprocesamiento de las señales ECG (derivación DII) y la señal ABP se lleva a cabo de manera conjunta, con la excepción del filtrado, que se aplica únicamente a la señal ECG. Además, la eliminación de artefactos se restringe a los registros de este grupo en particular.



Fig. 3.2. Proceso general de extracción de características de la señal ECG y ABP.

Inicialmente, es esencial extraer las señales de interés del conjunto de señales presentes en los registros del paciente y obtener los valores reales de las señales. Esto se logra mediante dos pasos: (1) la eliminación de la línea de base y (2) la corrección de la ganancia utilizada en la adquisición de los registros. La información necesaria para llevar a cabo estas operaciones se encuentra disponible en el archivo '.info' asociado a los registros de los pacientes que ofrece la base de datos.

$$X = \frac{X_{Raw} - B}{G} \quad (3.1)$$

donde:

- X_{Raw} es la señal en bruto disponible en PhysioBank.
- B es la línea de base.
- G es el factor de ganancia aplicada a la señal fisiológica original.
- X es el valor de la señal original tras eliminar la línea de base y la ganancia.

Remuestreo. El intervalo aceptado para la información del ECG es de 0,05 a 100 Hz [41], entonces para facilitar el procesamiento de las señales, se realiza un remuestreo (downsampling - Upsampling) de todas las señales a 250 Hz.

Filtrado. En el procesamiento de señales de ECG es común enfrentarse a diversos tipos de ruido, como el ruido de baja frecuencia, el ruido de alta frecuencia, el desplazamiento de la línea de base y el ruido de la red eléctrica. La eliminación eficaz de este ruido es esencial para preparar las señales de ECG para su posterior uso en la creación de modelos de regresión o clasificación.

Para identificar las frecuencias que contaminan la señal, se calcula la Transformada de Fourier de la señal ECG (DII). Una vez identificadas, se diseñan dos filtros digitales de Respuesta al Impulso Finito (FIR) [58] con respuesta Butterworth de cuarto orden.

Dado que las señales ECG en bruto se remuestrearon a 250 Hz, aplicando la teoría de muestreo de Nyquist [59] la frecuencia de corte máxima de los filtro no puede sobrepasar los 125 Hz. Entonces, se diseña un filtro digital pasa-bandas con frecuencias de corte en 1 y 100 Hz y otro filtro digital rechaza-bandas para eliminar el ruido asociado a la red eléctrica (60 Hz).

Normalización. Se considera como el proceso de escalamiento utilizado en el procesamiento de datos para transformar valores en un rango específico, generalmente entre 0 y 1. El propósito de la normalización Min-Max es asegurar que todos los valores estén en la misma escala y tengan un rango común, lo que facilita la comparación y el análisis de los datos.

El proceso de normalización Min-Max se realiza de la siguiente manera para un conjunto de datos:

$$x_i^{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3.2)$$

donde:

x_i^{norm}	es el valor normalizado del elemento i del segmento de ECG.
x_i	es el valor del elemento i del segmento de ECG.
x_{min}	es el valor mínimo en el segmento de ECG.
x_{max}	es el valor máximo en el segmento de ECG.

OBS. Las señales del grupo 2 continúan a la sección 3.2.2

Segmentación. Una vez la señal ECG ha sido filtrada, esta se sincroniza con la señal ABP y se divide inicialmente en segmentos de 10 segundos de duración, para iniciar el proceso de eliminación de artefactos.

Eliminación de Artefactos. Para eliminar las señales ECG y ABP con ruido de artefacto, se utiliza la asimetría [60], la cual se define por la ecuación (3.3), y permite evaluar la calidad de los segmentos de ambas señales. En concreto, los segmentos de ambas señales de 10 s de duración se recortan en subsegmentos mas cortos de 1 s. A continuación, se calcula la asimetría y la primera derivada discreta de cada subsegmento de 1 s. Si alguna de las asimetrías de los subsegmentos de 1 s es inferior a 0, o si al calcular la primera derivada discreta se encuentra algún elemento con valor igual a 0, se descarta el segmento de 10 s de duración correspondiente a ambas señales.

$$S_k = \frac{1}{N-1} \sum_{i=1}^N \frac{(x_i^{\text{señal}} - \bar{x}^{\text{señal}})^3}{SD(x^{\text{señal}})} \quad (3.3)$$

teniendo en cuenta que:

S_k	es la asimetría del k-ésimo subsegmento de duración de 1 s.
N	es el número de elementos de la señal de una duración de 1 s.
$x_i^{\text{señal}}$	es el valor del elemento i-ésimo de la señal.
$\bar{x}^{\text{señal}}$	es el valor medio de la señal.
$SD(\cdot)$	es la desviación estándar de la k-ésimo subsegmento de la señal.

Después de eliminar los artefactos de las señales, se procede a la reconstrucción de la señal completa mediante la unión de los segmentos previamente almacenados.

OBS. Las señales del grupo 1 continúan a la sección 3.2.3

3.2.2 Algoritmo de extracción de características de las señales ECG con arritmias

El algoritmo de extracción de características de las señales ECG con arritmias se describe de manera general en la figura 3.3. Las características extraídas a través de este algoritmo posteriormente serán utilizadas para el entrenamiento del clasificador de normalidad cardíaca.

El clasificador de normalidad cardíaca tiene 2 enfoques, (1) Clasificación por latido (corto) y, (2) Clasificación por HRV y presión arterial (mediano - largo)

Para la extracción de características, los datos se segmentan en ventanas de 5 y 30 minutos para el enfoque de clasificación basado en la variación de la frecuencia cardíaca y

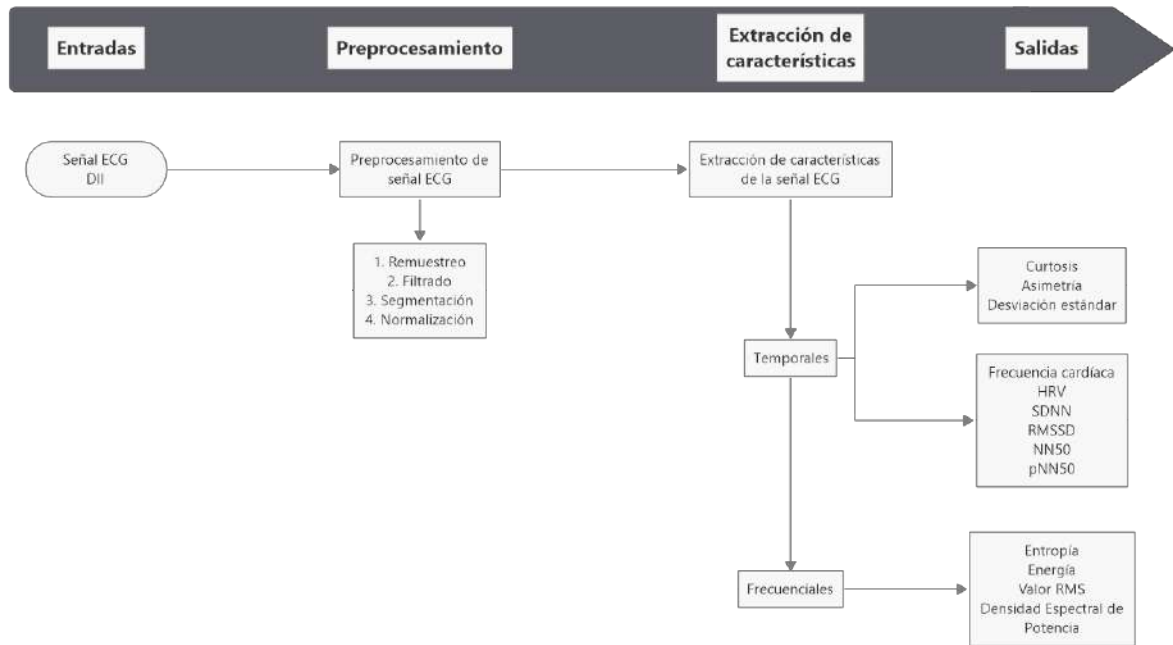


Fig. 3.3. Proceso de extracción de características de la señal ECG con arritmias.

en segmentos de 250 muestras centrada en el pico R de la señal ECG para la clasificación de latidos.

Para la detección de picos, se aplica el algoritmo de Pan-Tompkins [6]. Después de detectar los picos, se segmenta una ventana de 250 muestras alrededor del pico (P-124 a P+125 muestras) [61] sobre la cual se extraen características temporales y frecuenciales, dejando de lado la variabilidad cardíaca.

Extracción de características

Una vez las señales ECG fueron preprocesadas se procede con la extracción de características temporales, frecuenciales y de variabilidad de frecuencia cardíaca.

Características temporales

Curtosis. Es la medida de la distribución de los datos alrededor de la media. Se define como la cuarta potencia del valor estandarizado dividido por la desviación estándar elevada al cubo [62].

$$Curtois = \frac{\sum_{i=1}^n (x_i - \mu)^4}{\sigma^4} \quad (3.4)$$

Asimetría es una medida de la asimetría de la distribución de los datos alrededor de la media. Se define como la tercera potencia del valor estandarizado dividido por la desviación estándar elevada al cubo [62].

$$Asimetria = \frac{\sum_{i=1}^n (x_i - \mu)^3}{\sigma^3} \quad (3.5)$$

Desviación estándar. Medida de la dispersión de los datos alrededor de la media. Se define como la raíz cuadrada de la varianza [62].

$$\sigma = \sqrt{Var} \quad (3.6)$$

Características de la variabilidad de la frecuencia cardíaca (HRV)

Son medidas de la variación de la frecuencia cardíaca en el tiempo, que se utilizan como un indicador de la salud cardíaca [63].

HRV. La variabilidad de la frecuencia cardíaca (HRV, *del ingles Heart Rate Variability*) representa la variación de la frecuencia cardíaca en el tiempo [63].

SDNN. Es una métrica de la variabilidad de los intervalos entre latidos cardíacos (RR) durante un período de tiempo específico [63].

$$SDNN = \sqrt{\frac{1}{n} \sum_{i=1}^n (RR_i - \overline{RR})^2} \quad (3.7)$$

RMSSD. La raíz cuadrada de la media del cuadrado de la diferencia entre intervalos RR consecutivos (RMSSD) [63].

$$RMSSD = \sqrt{\frac{1}{n} \sum_{i=1}^n (RR_i - \overline{RR})^2} \quad (3.8)$$

NN50. Número de pares de intervalos RR adyacentes cuya diferencia es mayor que 50 ms, Mide la cantidad de cambios significativos en la frecuencia cardíaca [63].

$$NN50 = \sum_{i=1}^{N-1} \begin{cases} 1, & \text{si } |NN_{i+1} - NN_i| > 50 \text{ ms} \\ 0, & \text{en otro caso} \end{cases} \quad (3.9)$$

pNN50. El porcentaje de intervalos RR consecutivos que difieren en al menos 50 milisegundos se conoce como pNN50 [63].

$$pNN50 = \frac{NN50}{N} \times 100 \% \quad (3.10)$$

Características Frecuenciales

Entropía (basada en la densidad espectral de potencia) mide la incertidumbre o la complejidad de una señal.

$$Entropia_{PSD} = - \sum_{i=1}^N |x_i|^2 \cdot \log(|x_i|^2) \quad (3.11)$$

Energía. medida de la potencia de una señal. Se define como la suma de los valores cuadrados de la señal

$$E = \frac{1}{N} \sum_{i=1}^N x_i^2 \quad (3.12)$$

Valor RMS. El valor RMS es la raíz cuadrada de la media de los cuadrados de los valores de la señal. Se utiliza como una medida de la potencia de una señal.

$$ValorRMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3.13)$$

Densidad Espectral de Potencia. La densidad espectral de potencia (PSD) describe cómo se distribuye la potencia en diferentes frecuencias en una señal. Se define como la magnitud del espectro de potencia de la señal dividido por el ancho de banda del espectro [63].

$$PSD(f) = \frac{|X(f)|^2}{T} \quad (3.14)$$

3.2.3 Algoritmo de extracción de características de las señales ECG y ABP

El algoritmo de extracción de características de las señales ECG y ABP se describe de manera general en la figura 3.4. Para llevar a cabo este proceso, es fundamental que las señales de los registros estén sincronizadas. De esta manera, las características extraídas de la señal ECG corresponden a los segmentos de tiempo específicos en los que se registran los valores de presión sistólica y presión diastólica de la señal ABP.

En este algoritmo la señal reconstruida después de que se eliminaran los artefactos se divide nuevamente en segmentos de 30 segundos de duración. Este enfoque se basa en la evidencia empírica que ha demostrado que segmentos de 30 segundos de una bioseñal son adecuados para realizar estimaciones sólidas de su complejidad, como se ha señalado en investigaciones previas [64--67]. El propósito de esta división es extraer características de complejidad de la señal ECG y obtener los valores de presión arterial (PA) correspondientes. Estos valores de PA se utilizarán más adelante en el proceso de entrenamiento de los modelos de regresión para estimar la presión arterial sistólica y diastólica.

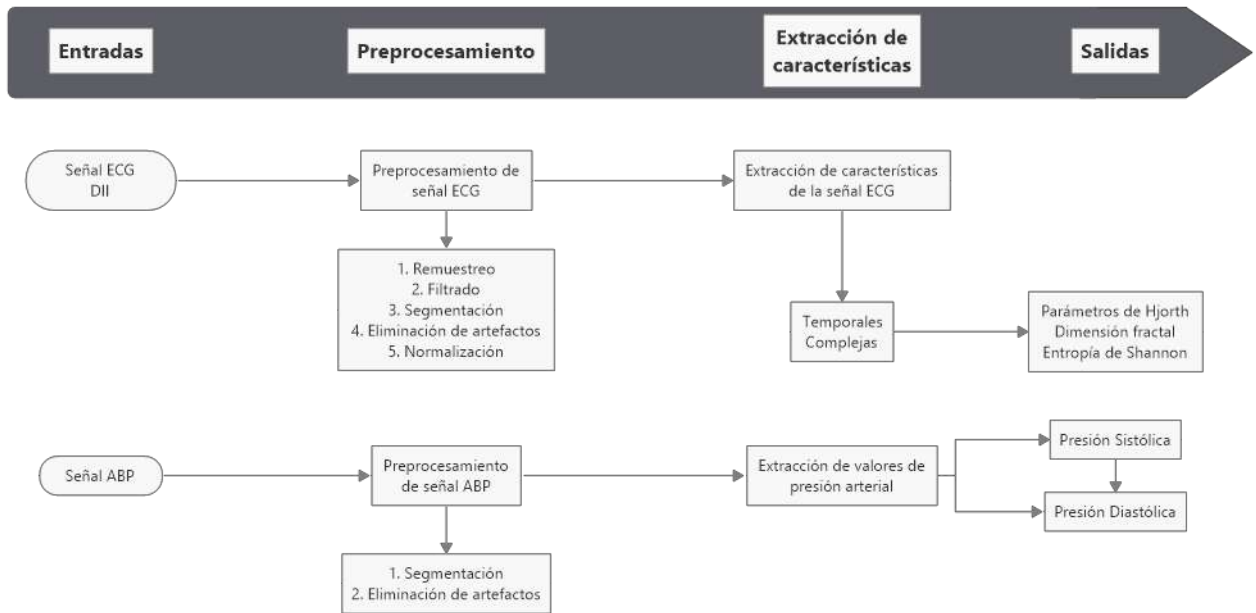


Fig. 3.4. Proceso de extracción de características de la señal ECG y ABP.

Extracción de características

Una vez las señales ECG y ABP son preprocesadas, se procede con la extracción de los valores de presión arterial de la señal ABP y las características de complejidad de la señal ECG

Valores de presión arterial de la señal ABP. Según lo observado en la figura 2.2, el valor de la presión arterial sistólica (PAS) corresponde al pico máximo de la onda de ABP en un ciclo cardíaco, mientras que la presión arterial diastólica (PAD) corresponde al punto más mínimo de la onda.

Siguiendo esta referencia, se desarrolló un algoritmo en *Matlab* diseñado para identificar los puntos mínimos y máximos en los segmentos de la señal ABP. El algoritmo utiliza dos umbrales: un umbral horizontal, que representa un número específico de muestras después del último pico detectado, durante el cual el algoritmo no busca picos máximos ni mínimos. Esto evita que se tomen las deflexiones de la señal ABP, causadas por el ruido de fondo, como valores de la presión arterial sistólica (PAS) o la presión arterial diastólica (PAD). El umbral vertical está relacionado con el período refractario cardíaco [68], que es el intervalo de tiempo posterior a la despolarización durante el cual la célula no es excitable.

El segundo umbral es el umbral horizontal, a partir del cual el algoritmo comienza a buscar los picos máximos y mínimos en la señal de ABP. Se puede observar una representación gráfica de estos umbrales en la figura 3.5.

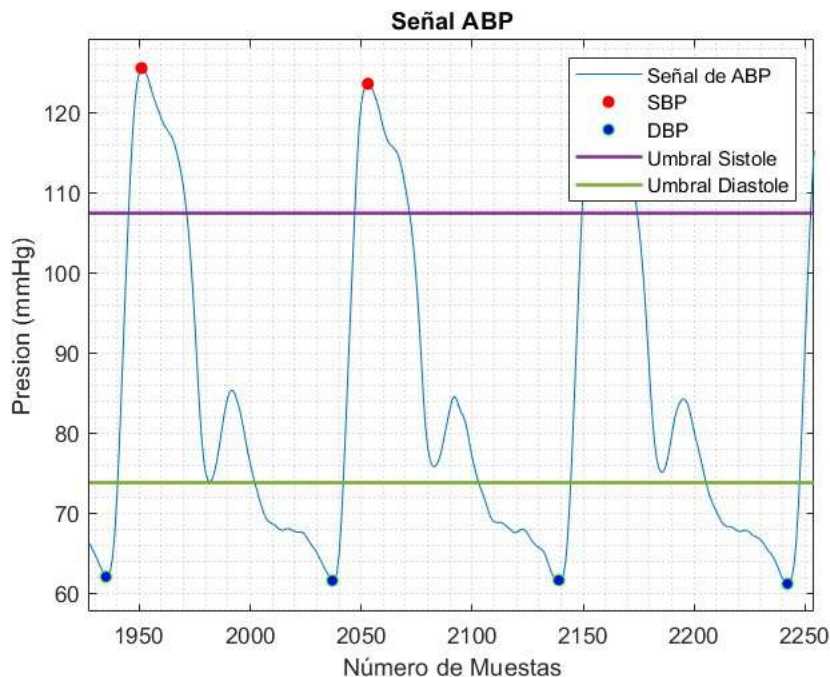


Fig. 3.5. Umbrales verticales para detección de valores máximos y mínimos de la señal ABP.

Valor de presión arterial sistólica. Para extraer los valores de la Presión Arterial Sistólica (PAS) de los segmentos de la señal de Presión Arterial ABP, se inicia estableciendo un umbral vertical. Este umbral se define como 1.7 veces la desviación estándar de la señal en relación con el valor máximo de la señal en el segmento. Luego, se utiliza este umbral como referencia para iniciar la búsqueda de los picos máximos en el segmento de la señal ABP.

Los valores de los picos se almacenan en un arreglo y, al final, se promedian para obtener un único valor de PAS para el segmento de la señal de presión arterial (ABP).

Valor de presión arterial diastólica. Para extraer los valores mínimos de la señal ABP, que corresponden a los valores de Presión Arterial Diastólica (PAD), se invierte el segmento de señal ABP y se establece un umbral vertical nuevamente. Este umbral se define como 1.5 veces la desviación estándar con respecto al valor medio de la señal en

el segmento. Luego, se utiliza este umbral como referencia para iniciar la búsqueda de los picos máximos en el segmento de la señal ABP invertida.

Los valores de los picos se almacenan en un arreglo y, al final, se promedian para obtener un único valor de PAD para el segmento de la señal de presión arterial (ABP).

Distribución de clases. Una vez se han obtenido los valores de presión arterial de cada uno de los segmentos de la señal ABP, se procede a etiquetar los datos de presión arterial como "normal"(0), "prehipertensos"(1), "hipertensos tipo I"(2) e "hipertensos tipo II"(3), según la tabla 2.1. Luego, los valores de PAS, PAD y la clase se agregan al vector de características del segmento.

Características de complejidad de la señal ECG. Se procede a cuantificar diversas métricas que modelan la complejidad de una señal ECG para cada uno de los segmentos de la señal de ECG, siguiendo el método propuesto por Simjanoska et al. en [27]. Estas métricas incluyen la Movilidad de la señal, definida en 2.2, la Complejidad de la señal, definida en 2.3, la Entropía de Shannon, definida en 2.6, y la Dimensión Fractal, cuya definición se encuentra en 2.5.

Posteriormente, estos valores se agregan al vector de características del segmento, junto con los valores de presión arterial sistólica y diastólica correspondientes.

Una vez se tienen todos los vectores de características del registro del paciente, estos se exportan a un archivo ".csv" para su uso posterior. Además, las señales preprocesadas se exportan a un archivo ".mat".

3.3 Estimación de Valores de Presión Arterial

El proceso de estimación de los valores de presión arterial diastólica (PAD) y de presión arterial sistólica (PAS) se especifica en la figura 3.6, así como el proceso de selección de los modelos de regresión utilizados en el presente trabajo, que se muestra en la figura 3.7.

3.3.1 Evaluación de Modelos de Regresión en MATLAB

En este trabajo, se propone llevar a cabo una revisión de la eficacia de varios modelos de regresión disponibles en la aplicación Matlab Regression Learner. La evaluación se centra en diversas familias de modelos, incluyendo regresión lineal, árboles de regresión,

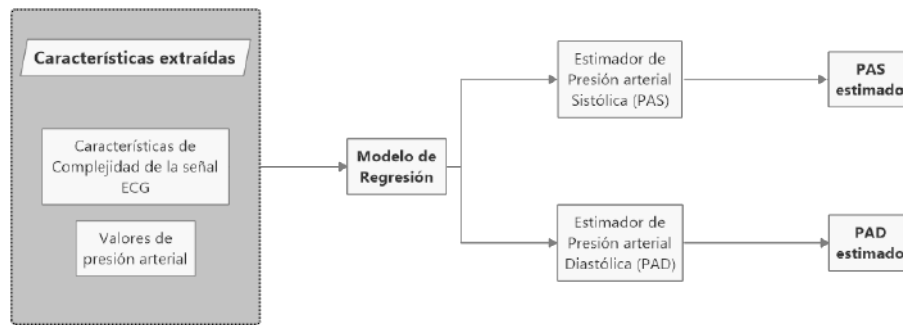


Fig. 3.6. Proceso de estimación de los valores de presión arterial.

máquinas de vectores de soporte (SVM), procesos de regresión gaussiana, modelos de regresión con aproximación de núcleos (kernels), bosques aleatorios y redes neuronales 3.7.

Las métricas de evaluación de los modelos incluyen el Error de Raíz Cuadrada Media ($RMSE$), el Error Cuadrático Medio (MSE), el Error Medio Absoluto (MAE) y el Coeficiente de Determinación (R^2). Estas métricas se calcularán tanto durante el entrenamiento como durante las pruebas de los modelos, utilizando una proporción de datos del 80 % para el entrenamiento y el 20 % para las pruebas.

Se seleccionarán dos modelos: uno para estimar la presión arterial diastólica (PAD) y otro para estimar la presión arterial sistólica (PAS). Es importante destacar que el modelo de regresión puede ser el mismo o diferente para ambas estimaciones, dependiendo de los resultados y el desempeño del modelo en cada caso.

3.4 Desarrollo del Clasificador de Normalidad

El proceso de clasificación de la normalidad cardíaca se especifica en la figura 3.8, así como el proceso de selección de los modelo de clasificación utilizado en el presente trabajo, que se muestra en la figura 3.9.

3.4.1 Evaluación de Modelos de Clasificación en MATLAB

En el marco de esta investigación, se plantea realizar una revisión de la eficacia de varios modelos de clasificación disponibles en la aplicación Matlab Classification Learner. Esta evaluación se enfocará en diversas familias de modelos, que incluyen árboles

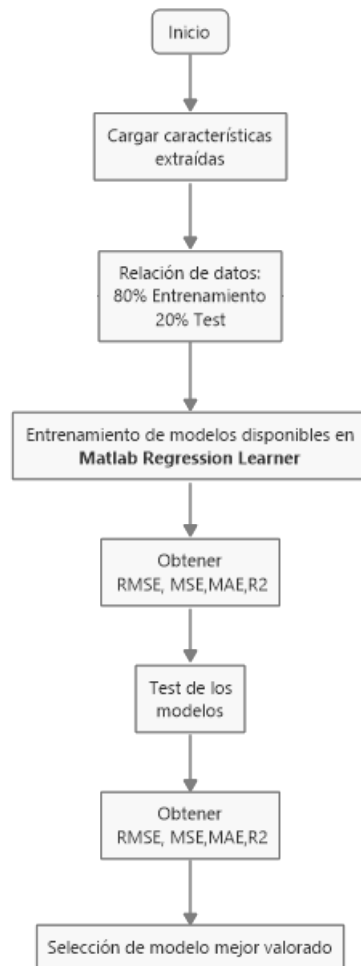


Fig. 3.7. Proceso de evaluación de modelos de regresión.

de decisión, análisis discriminante, clasificadores por regresión logística, Naive Bayes, máquinas de vectores de soporte (SVM), k-vecinos más cercanos (KNN), clasificadores por kernel de aproximación, clasificadores de conjuntos y redes neuronales.

La métrica de evaluación utilizada para los modelos será la precisión. Se ha empleado la estrategia de validación cruzada con 5 interacciones. Esta técnica implica entrenar múltiples modelos en los que se dividen subconjuntos de los datos de entrada disponibles y se evalúan con el subconjunto complementario de los datos obtenidos de diferentes partes del conjunto de datos, como se describe en [8]. En la Figura 3.10, se muestra un ejemplo de validación cruzada con 4 interacciones.

El modelo uno utiliza el primer 25 % de los datos para la evaluación y el 75 % res-



Fig. 3.8. Proceso de clasificación de normalidad cardíaca .

tante para el entrenamiento. El modelo dos utiliza el segundo subconjunto del 25 % (del 25 % al 50 %) para la evaluación y los tres subconjuntos restantes de los datos para el entrenamiento y así sucesivamente.

3.4.2 Clasificador corto

Para el entrenamiento del clasificador enfocado en el análisis de latidos individuales, se utilizan las características temporales y frecuenciales extraídas en la sección 3.2.2. Los datos se dividen en un 80 % para el entrenamiento y un 20 % para las pruebas del modelo.

El clasificador se centra en la clasificación de cinco clases de arritmias: Normal (N), Latido perdido (I), bloqueo de rama derecha (R), Bloqueo de rama izquierda (L) y Latido ventricular prematuro (V).

Para etiquetar los datos, se extraen las anotaciones de los registros individuales de la base de datos MIT-BIH. Estas anotaciones son etiquetas individuales de los complejos QRS, realizadas por un médico cardiólogo del Hospital Beth Israel de Boston (ahora Centro Médico Beth Israel Deaconess) [54].

3.4.3 Clasificador Largo

Para el entrenamiento del clasificador enfocado en el análisis de variabilidad de la frecuencia cardíaca y presión arterial, se utilizan todas las características temporales,

3. Metodología 3.5. Validación del Algoritmo de Estimación y Clasificador de Normalidad

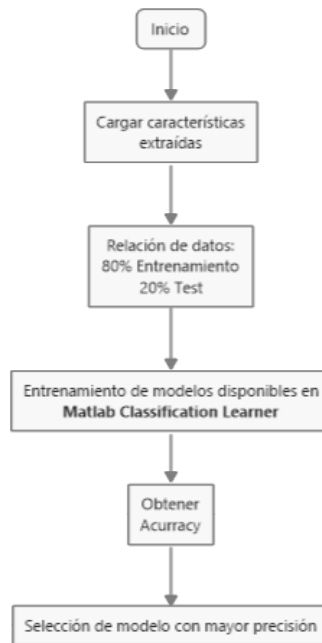


Fig. 3.9. Proceso de de evaluación de modelos de clasificación.

frecuenciales y de variabilidad de la frecuencia cardíaca extraídas en la sección 3.2.2.

Adicionalmente se emplea el estimador de presión arterial 3.3 para incluir los valores de presión arterial en los datos de entrenamiento. Los datos se dividen en un 80 % para el entrenamiento y un 20 % para las pruebas del modelo y se procede con el entrenamiento del modelo.

3.5 Validación del Algoritmo de Estimación y Clasificador de Normalidad

Para validar el modelo y verificar su capacidad de generalización, se llevarán a cabo dos acciones adicionales además de la validación cruzada empleada para evaluar los modelos de regresión para la estimación de la presión arterial y la clasificación de la normalidad de la dinámica cardíaca.

En primer lugar, se descargaron otros registros de la base de datos MIMIC II/III (4 registros), PTB (3 registros) y MIT-BIH (3 registros), que incluyen anotaciones de arritmias y/o valores de presión arterial. Estos registros se utilizarán para evaluar la capacidad de generalización del clasificador y el estimador de presión utilizando datos de bases de datos no empleados anteriormente.




Fig. 3.10. Separación de datos con validación cruzada con 4 interacciones. adaptado de [8]

En segundo lugar, se llevará a cabo la adquisición de señales ECG (DII) mediante el polifisiógrafo AdInstruments PowerLab 26T y los valores de presión arterial mediante el monitor de signos vitales Edan im8, a 5 estudiantes (presumibles como sanos) de la sede Popayán, con un intervalo de 3 horas a lo largo de una jornada laboral siguiendo el protocolo descrito en la sección 3.6. Este proceso permitirá evaluar el rendimiento y la efectividad del algoritmo en entornos específicos.

3.6 Protocolo de toma de datos a pacientes

1. Recibimiento del paciente, toma de datos personales, explicación del protocolo de toma de datos.
2. conexión de los electrodos y el tensiómetro.
3. Reposo (2-5 minutos): el paciente se sienta en un asiento designado y se le permite reposar durante un período de 2 a 5 minutos. Esto ayuda a que sus signos vitales, como la frecuencia cardíaca y la presión arterial, vuelvan a sus valores normales.
4. Toma de señales (5 minutos): se registra la señal ECG-DII del paciente, al inicio y cada 90 segundos se registra la presión arterial para realizar un seguimiento de los cambios.
5. Desconexión de los electrodos y el tensiómetro.
6. Ejercicio principal (1 minuto): Durante este minuto, el paciente deberá realizar el ejercicio físico conocido como *payasitos* o *jumping jacks*, a su propio ritmo. Este ejercicio tiene como objetivo aumentar tanto la frecuencia cardíaca como la presión arterial.
7. Conexión de los electrodos y el tensiómetro.

8. Toma de señales (5 minutos): se registra la señal ECG-DII del paciente, al inicio y cada 90 segundos se registra la presión arterial.




Fig. 3.11. Jumping jack. Tomado de [9]

Este proceso se repite en intervalos de 3 horas durante una jornada laboral para los 5 pacientes. El ejercicio "jumping jack" se lleva a cabo siguiendo la técnica descrita en la figura 3.11.

4 Resultados y análisis de resultados

4.1 Extracción de Características

Como resultado de este estudio, se ha desarrollado un algoritmo de extracción de características en el dominio del tiempo y frecuencia de la señal ECG. Este algoritmo incluye un módulo opcional que permite la extracción de valores de presión arterial sistólica y diastólica a partir de la señal de presión arterial invasiva (ABP), en caso de que el registro del paciente cuente con esta señal.

Base de Datos Como parte de los resultados, se pone a disposición una base de datos basada en registros de MIMIC II/III y CharisDB de physioNet. Esta base de datos consta de 50 registros, cada uno de los cuales incluye las señales ECG-DII y ABP. Cabe destacar que estas señales han sido sometidas a un proceso de filtrado para eliminar el ruido y los artefactos, garantizando así la calidad y la fiabilidad de los datos.

4.1.1 Características de señales ECG con arritmias

Características Temporales Extraídas

La Tabla muestra ejemplos de características temporales extraídas de la señal ECG.

Tabla. 4.1. Muestra de valores de características temporales extraídas

Desviación estándar	Valor RMS	Energía	Asimetría	Curtosis	Entropía	Shannon	Clase
0.064	0.506	0.256	4.185	22.500	122.542	8.441	0
0.066	0.448	0.201	5.184	32.609	112.669	8.419	0
0.074	0.348	0.121	3.742	23.941	87.748	8.337	0

0.145	0.432	0.187	1.558	4.560	96.238	8.132	1
0.136	0.431	0.186	1.285	3.762	98.390	8.181	1
0.131	0.431	0.185	1.141	3.419	99.495	8.206	1
0.085	0.515	0.265	-0.906	8.898	122.283	8.423	2
0.077	0.510	0.260	-0.503	9.423	122.365	8.432	2
0.079	0.512	0.262	-0.440	9.896	122.428	8.430	2
0.064	0.481	0.232	2.136	10.248	119.147	8.439	3
0.061	0.482	0.233	1.994	9.703	119.611	8.445	3
0.061	0.482	0.233	2.047	9.841	119.590	8.445	3
0.102	0.426	0.182	-0.691	4.986	105.185	8.346	4
0.104	0.426	0.182	-0.673	5.231	104.967	8.341	4
0.111	0.430	0.185	-0.795	5.085	104.974	8.326	4

4.1.2 Características para el entrenamiento del estimador de presión

Una muestra de los valores de las características de complejidad de señal extraídas para el entrenamiento del estimador de presión arterial se presenta en la Tabla 4.2. Las características extraídas proporcionan información sobre la naturaleza, la variabilidad y la complejidad de la señal del ECG. Ayudan a caracterizar la actividad cardíaca y a identificar patrones que se utilizarán para realizar la estimación de la presión arterial sistólica y diastólica más adelante.

Tabla. 4.2. Muestra de valores de características de complejidad extraídas

Mobilidad	Complejidad	Entropía	Dimensión Fractal	Sístole	Diástole	Clase
0.312	0.028	11.872	1.714	76	46	0
0.490	0.067	11.872	1.837	107	65	0
0.448	0.045	11.872	1.728	113	48	0
0.621	0.095	11.872	1.871	120	61	0
0.476	0.024	11.872	1.780	121	86	1
0.459	0.022	11.872	1.766	124	75	1
0.580	0.097	11.872	1.775	128	71	1
0.468	0.024	11.872	1.788	134	81	1
0.663	0.118	11.873	1.885	139	79	1
0.504	0.065	11.872	1.823	141	82	2
0.673	0.130	11.872	1.814	143	81	2
0.700	0.150	11.872	1.815	148	85	2
0.731	0.117	11.872	1.858	151	84	2
0.721	0.135	11.872	1.856	159	80	2

0.501	0.062	11.872	1.799	162	81	3
0.590	0.102	11.873	1.873	172	90	3
0.420	0.066	11.872	1.812	179	81	3
0.592	0.074	11.873	1.871	185	97	3
0.482	0.052	11.873	1.852	198	94	3

4.2 Estimador de presión Arterial

Para seleccionar el modelo que mejor se adapte a los datos extraídos, los diversos modelos de regresión disponibles en *MATLAB Regression Learner* fueron entrenados y testeados. Posteriormente, se eligió el modelo con mejores estadísticas. A continuación, se presentan el desempeño de los distintos modelos para estimar la Presión Arterial Sistólica (PAS) en la Tabla 4.4 y el desempeño de estimación la Presión Arterial Diastólica (PAD) en la Tabla 4.5.

Para el entrenamiento y test de los modelos de regresión fue utilizado un dataset de con 8464 instancias divididas en 4 clases, como se muestra en la tabla 4.3 siguiendo las reglas de etiquetado de valores de presión arterial descritas en la tabla 2.1, el 80 % de los datos se destino al entrenamiento y el 20 % al test del modelo, con

Tabla. 4.3. Distribución de clases para entrenamiento de los modelos de regresión

Clase	Número de instancias
Normal	3096
Prehipertensión	2576
Hipertensión etapa I	2047
Hipertensión etapa II	745

Tabla. 4.4. Evaluación de modelos de regresión de Matlab para estimar el valor de presión sistólica

Modelo		Presión arterial Sistólica							
		Entrenamiento				Test			
		RMSE	MSE	R ²	MAE	MAE	MSE	RMSE	R ²
Linear Regression	Linear	125,4	157**	-36,24	123,7	123,7	475,37	21,80	-36
	Interactions	125,4	157**	-36,24	123,7	123,7	443,37	21,06	-36
	Linear	125,4	157**	-36,24	123,7	123,7	443,37	21,06	-36

	Robust Linear	125,4	157**	-36,24	123,7	123,7	476,68	21,83	-36
	Stepwise Linear	19,9	395,7	0,06	15,7	15,7	443,32	21,06	0,06
Tree	Fine	11,6	135,4	0,68	6,7	6,7	108,52	10,42	0,68
	Medium	11,6	135,7	0,68	7,1	7,1	100,00	10,00	0,68
	Coarse	12,5	157,2	0,63	8,2	8,2	116,11	10,78	0,63
SVM	Linear	19,9	396,4	0,06	15,9	15,9	484,95	22,02	0,06
	Quadratic	20,6	423,1	0,00	15,4	15,4	456,99	21,38	0,00
	Cubic	684,1	467**	-1106	411,3	411,3	1383,58	37,20	-110
	Fine gaussian	9,7	94,2	0,78	6,0	6,0	123,35	11,11	0,78
	Medium gaussian	16,7	279,4	0,34	11,9	11,9	342,66	18,51	0,34
Ensemble	Coarse gaussian	19,7	386,9	0,08	15,3	15,3	427,00	20,66	0,08
	Boosted Trees	15,4	236,7	0,44	11,5	11,5	192,76	13,88	0,44
	Bagged Trees	9,7	94,5	0,78	5,9	5,9	80,00	8,94	0,78
Gaussian Process Regression	Squared Exponential	8,9	79,4	0,81	5,2	5,2	86,76	9,31	0,81
	Matern 5/2	8,7	75,6	0,82	5,0	5,0	82,09	9,06	0,82
	Exponential	8,4	70,9	0,83	4,8	4,8	84,68	9,20	0,83
	Rational Quadratic	8,5	72,2	0,83	4,9	4,9	83,86	9,16	0,83
Neural Network	Narrow	18,6	346,8	0,18	14,3	14,3	351,17	18,74	0,18
	Medium	17,8	315,6	0,25	12,0	12,0	360,50	18,99	0,25
	Wide	14,6	213,6	0,49	8,5	8,5	145,45	12,06	0,49
	Bilayered	19,0	362,4	0,14	11,9	11,9	489,49	22,13	0,14
	Trilayered	15,2	231,4	0,45	11,0	11,0	220,79	14,86	0,45
Kernel	SVM kernel	17,1	291,4	0,31	12,4	12,4	306,20	17,50	0,31
	LSR	15,8	251,2	0,41	11,8	11,8	232,77	15,26	0,41

El modelo de Regresión de Procesos Gaussianos (RPG) con kernel exponencial 4.1 demostró ser el más adecuado para ajustarse a los datos, logrando un coeficiente de determinación (R^2) de 0.83. Este resultado subraya la capacidad del RPG con kernel exponencial para capturar y modelar eficazmente la variabilidad presente en los datos.

Tabla. 4.5. Evaluación de modelos de regresión de Matlab para estimar el valor de presión diastólica

Modelo		Presión arterial Sistólica							
		Entrenamiento				Test			
		RMSE	MSE	R ²	MAE	MAE	MSE	RMSE	R ²
Linear Regression	Linear	62,00	3844,6	-36,27	61,17	72,29	5299	72,8	-36,3
	Interactions	62,00	3844,6	-36,27	61,17	72,29	5299	72,8	-36,3
	Linear	62,00	3844,6	-36,27	61,17	72,29	5299	72,8	-36,3
	Robust	62,00	3844,6	-36,27	61,17	72,29	5299	72,8	-36,3
Tree	Linear	9,73	94,74	0,08	8,00	14,23	246,4	15,7	0,08
	Stepwise	9,73	94,74	0,08	8,00	14,23	246,4	15,7	0,08
	Linear	9,73	94,74	0,08	8,00	14,23	246,4	15,7	0,08
	Linear	9,73	94,74	0,08	8,00	14,23	246,4	15,7	0,08
SVM	Fine	5,24	27,49	0,73	3,00	14,33	280,6	16,8	0,73
	Medium	5,32	28,26	0,73	3,20	11,58	223,5	14,9	0,73
	Coarse	5,74	32,94	0,68	3,67	12,65	277,2	16,6	0,68
SVM	Linear	9,91	98,14	0,05	8,09	15,79	303,7	17,4	0,05
	Quadratic	9,95	99,04	0,04	7,66	22,86	674,1	26,0	0,04
	Cubic	23,19	537,77	-2,83	17,3	33,49	1743	41,75	-10,4
	Fine gaussian	4,23	17,9	0,83	2,62	12,96	215,5	14,7	0,83
	Medium gaussian	7,92	62,7	0,39	5,57	7,59	86,2	9,3	0,39
Ensemble	Coarse gaussian	9,52	90,7	0,12	7,44	22,87	590,5	24,3	0,12
	Boosted Trees	6,94	48,17	0,53	5,20	10,71	194,2	13,9	0,53
	Bagged Trees	4,31	18,60	0,82	2,60	9,93	165,3	12,9	0,82
Gaussian Process Regression	Squared Exponential	3,73	13,91	0,87	2,22	12,01	189,5	13,8	0,87
	Matern 5/2	3,64	13,24	0,87	2,15	12,38	199,4	14,1	0,87
	Exponential	3,58	12,83	0,88	2,12	13,51	231,7	15,2	0,88
	Rational Quadratic	3,63	13,20	0,87	2,15	15,42	293,5	17,1	0,87
Neural Network	Narrow	14,18	201,2	-0,95	6,68	15,15	286,9	16,9	-0,95
	Medium	6,94	48,16	0,53	4,79	10,69	188,7	13,7	0,53
	Wide	7,43	55,21	0,46	3,75	29,23	1339,7	36,6	0,46
	Bilayered	7,18	51,59	0,50	5,10	8,99	136,1	11,7	0,50
	Trilayered	6,57	43,21	0,58	4,69	21,74	574,0	24,0	0,58
Kernel	SVM kernel	6,03	36,31	0,65	4,04	16,43	323,6	18,0	0,65
	LSR	5,83	34,04	0,67	4,12	9,30	147,0	12,1	0,67

El modelo de Regresión de Procesos Gaussianos (RPG) con kernel exponencial 4.1 demostró ser el más adecuado para ajustarse a los datos, logrando un coeficiente de determinación (R^2) de 0.88. Este resultado subraya la capacidad del RPG con kernel exponencial para capturar y modelar eficazmente la variabilidad de los datos de presión diastólica.

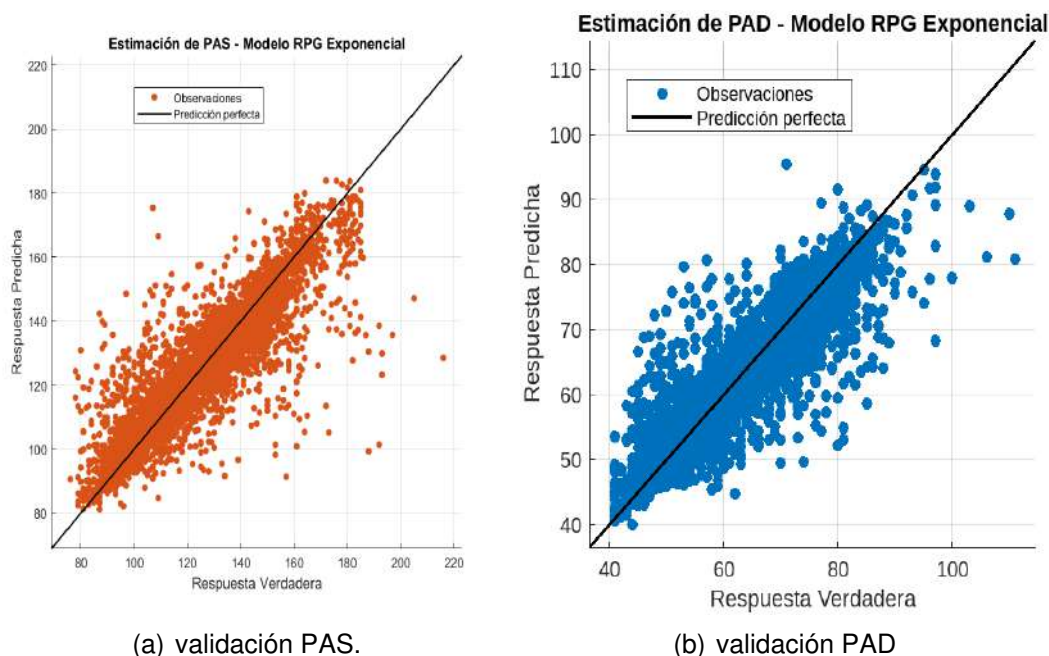


Fig. 4.1. valor estimado vs real - modelos de estimación de presión arterial.

Cabe destacar que al revisar los valores de RMSE de ambos modelos ambos presentan una desviación general menor a 15 (mmHg), por consiguiente ambos modelos cumplen con el criterio de la sociedad británica de hipertensión (BHS) [13].

4.3 Clasificador de normalidad

Como parte de la metodología propuesta, se realizó la revisión de la eficacia de los modelos de clasificación disponibles en *Matlab Classification Learner*, en la tabla 4.7 se observan los resultados de la evaluación.

La figura 4.2 representa de manera visual la morfología de las diversas clases de señales que son discriminadas por el clasificador. Esta visualización ofrece una perspectiva clara de las características distintivas presentes en las formas de onda asociadas a cada clase, facilitando la comprensión de cómo el clasificador realiza la distinción entre estas señales en el contexto del análisis de electrocardiogramas (ECG).

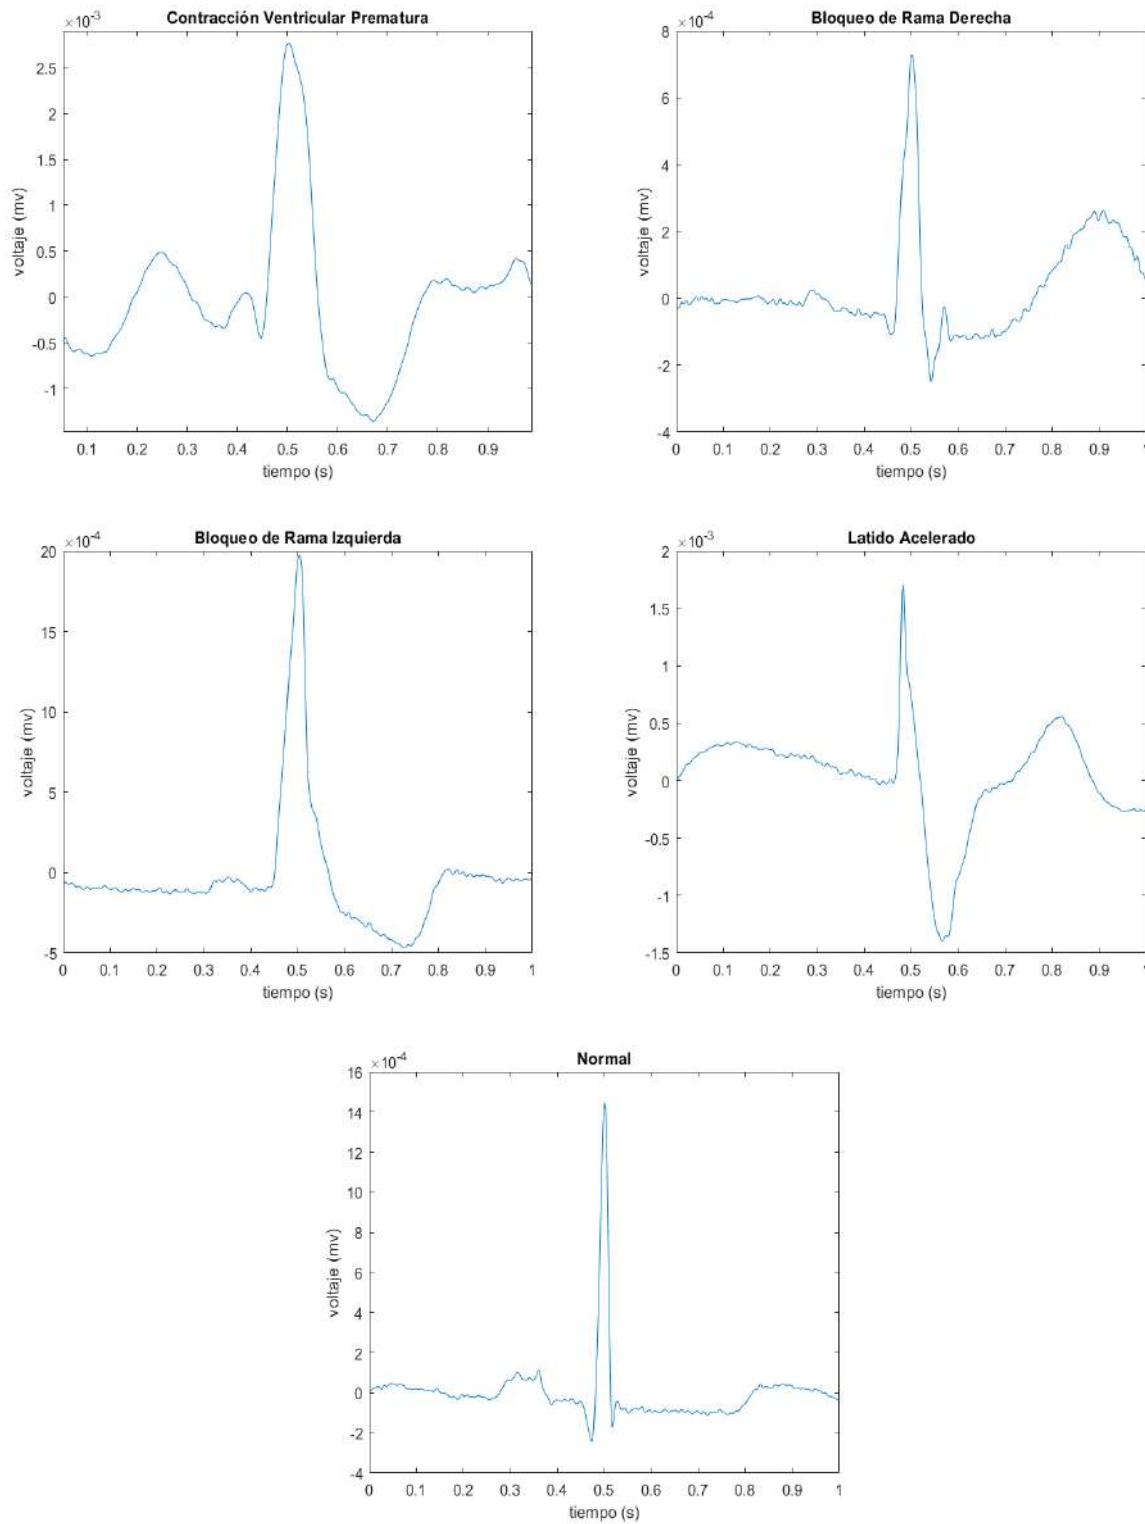


Fig. 4.2. Morfología de señales ECG que se clasifican

Para el entrenamiento y test del clasificador se utilizan un dataset de con 36027 instancias divididas en 5 clases como se muestra en la tabla 4.6, el 80 % de los datos se destino al entrenamiento y el 20 % al test del modelo.

Tabla. 4.6. Distribución de clases

Clase	Número de instancias
Normal	N 8000
Contracción Ventricular Prematura	V 7068
Bloqueo de rama derecha	R 7248
Bloqueo de rama izquierda	L 8269
Latido acelerado	/ 5641

En el proceso de selección de atributos para el clasificador, se implementó el algoritmo de posicionamiento MRMR (Minimum Redundancy Maximum Relevance)4.3. Este algoritmo ordena los atributos según su importancia al realizar una clasificación, asignándoles puntajes correspondientes.

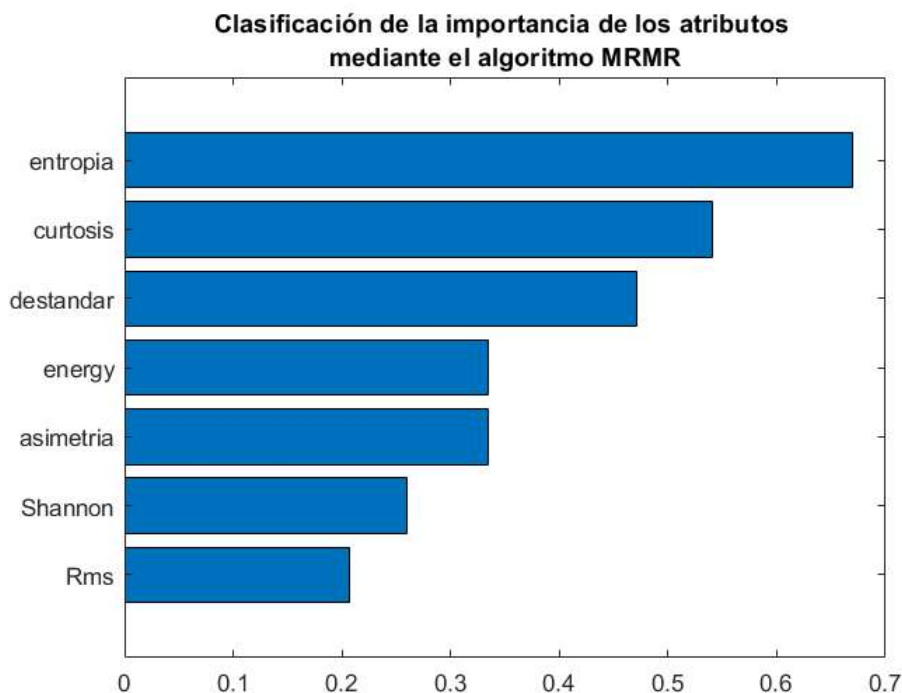


Fig. 4.3. Clasificación de atributos usando algoritmo MRMR.

La utilización de MRMR permitió identificar y priorizar aquellos atributos que contribuyen de manera más significativa a la capacidad del clasificador para realizar una clasificación

precisa. Este enfoque garantiza que solo se conserven los atributos más informativos y valiosos para la tarea de clasificación, eligiendo en este caso los cuatro mejor posicionados.

Tabla. 4.7. Evaluación de modelos de Clasificación de matlab

Clasificador de latidos		
	Modelo	Entrenamiento Accuracy (%)
Tree	Fine tree	90.3
	Medium tree	82.3
	Coarse tree	56.4
Linear Discriminant		59.2
Quadratic Discriminant		82.4
Efficient logistic regression		48.1
Efficient linear SVM		47.2
Naive bayes	Gaussian	69.3
	kernel	76.8
SVM	Linear	71
	Quadratic	73.1
	Cubic	75.7
	Fine gaussian	95.7
	Medium gaussian	90.5
	Coarse gaussian	77.6
KNN	Fine	96
	Medium	95.3
	Coarse	91.3
	Cosine	91.9
	Cubic	95
	Weighted	95.8
Ensemble	Boosted Trees	87.8
	Bagged Trees	96.6
	Subspace Discriminant	57
	Subspace KNN	83.1
	RUSBoosted Trees	83.6
Neural Network	Narrow	92
	Medium	95.3
	Wide	96.5
	Bilayered	94
	Trilayered	94.8

Kernel	SVM kernel	91.1
	Logistic Regression kernel	90

Los modelos con mejor exactitud en el entrenamiento fueron: Bagged Trees (Árboles empaquetados), Neural network wide (red neuronal amplia) y KNN fine (KNN fino) con 96.6 %, 96.5 % y 96 % de exactitud respectivamente. Sin embargo, para seleccionar el modelo más robusto, se realizó una evaluación adicional utilizando la matriz de confusión. Además de la exactitud, se calcularon la sensibilidad y la especificidad de los modelos con el objetivo de elegir el mejor modelo en función de estos tres parámetros 4.8.

Tabla. 4.8. Comparación de métricas de evaluación de los modelos mejor valorados

Modelo	% Exactitud	% Sensibilidad	% Especificidad
Bagged Trees	96.6	96.82	96.62
Neural network wide	96.5	96.6	96.54
KNN fine	96	96.1	96

La matriz de confusión ilustran los resultados de las predicciones del modelo Bagged Trees 4.4, donde los valores en la diagonal principal reflejan las predicciones correctas, mientras que los valores fuera de dicha diagonal señalan errores de clasificación.

Tabla. 4.9. Clases en matriz de confusión

Clase	Anormal				
	0	1	2	3	4
	N	V	R	L	/

La sensibilidad (TRP) refleja la capacidad del clasificador para identificar de manera precisa los casos positivos de cada clase. Por otro lado, la especificidad (PPV) indica la capacidad del clasificador para identificar de manera precisa los casos negativos. Ambos parámetros son fundamentales para evaluar el rendimiento de los modelos.

Las figuras 4.5, 4.6, 4.7, 4.8 y 4.9 ilustran las curvas ROC (Receiver Operating Characteristic) correspondientes a las clases 0, 1, 2, 3, y 4 del clasificador de normalidad modelo Bagged Trees. Estas curvas son herramientas gráficas empleadas para evaluar el rendimiento de un modelo de clasificación binaria en diversos umbrales de decisión. Cada curva representa la sensibilidad (tasa de verdaderos positivos) en función de la especificidad (1 - tasa de falsos positivos) para diferentes puntos de corte del clasificador.




Fig. 4.4. matriz de confusion Bagged Trees ampliada.

La proximidad de estas curvas al vértice superior izquierdo del gráfico indica un mejor rendimiento del modelo, reflejando una mayor capacidad para distinguir entre clases.

El Área bajo la curva (AUC) se utiliza como una medida común de la eficacia global del clasificador. Un AUC de 1.0 sugiere un rendimiento perfecto, mientras que un AUC de 0.5 indica un rendimiento similar al azar. El punto de operación óptima, ubicado en la curva ROC más cercana al vértice superior izquierdo, representa el equilibrio ideal entre sensibilidad y especificidad.

La figura 4.5 presenta la curva ROC correspondiente a la clase 0 (Normal). En esta representación gráfica, se destaca una curva que asciende de manera pronunciada hacia el vértice superior izquierdo, indicando un rendimiento destacado del clasificador. La presencia de un punto de operación óptima en proximidad al vértice superior izquierdo sugiere un equilibrio eficiente entre sensibilidad y especificidad. El valor del Área bajo la Curva (AUC) registrado como 0,9947 refuerza la calidad del rendimiento clasificatorio, ya que se acerca al valor máximo de 1.0. Estos resultados señalan un alto nivel de precisión

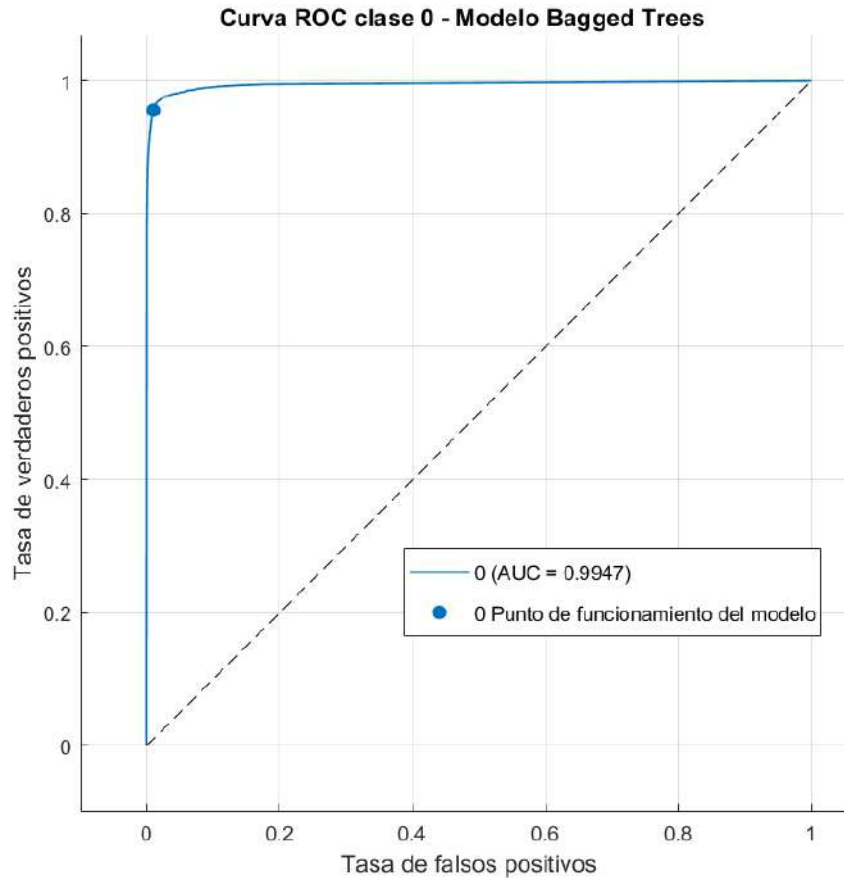


Fig. 4.5. Curva ROC clase 0.

y discriminación en la clasificación de la clase 0, respaldando la efectividad general del modelo.

La figura 4.6 presenta la curva ROC correspondiente a la clase 1 (Contracción ventricular prematura). En esta representación gráfica, se destaca una curva que asciende de manera pronunciada hacia el vértice superior izquierdo, indicando un rendimiento destacado del clasificador. La presencia de un punto de operación óptima en proximidad al vértice superior izquierdo sugiere un equilibrio eficiente entre sensibilidad y especificidad. El valor del Área bajo la Curva (AUC) registrado como 0,9909 refuerza la calidad del rendimiento clasificatorio, ya que se acerca al valor máximo de 1.0. Estos resultados señalan un alto nivel de precisión y discriminación en la clasificación de la clase 1 respaldando la efectividad general del modelo.

La figura 4.7 presenta la curva ROC correspondiente a la clase 2 (Bloqueo de rama derecha). En esta representación gráfica, se destaca una curva que asciende de manera

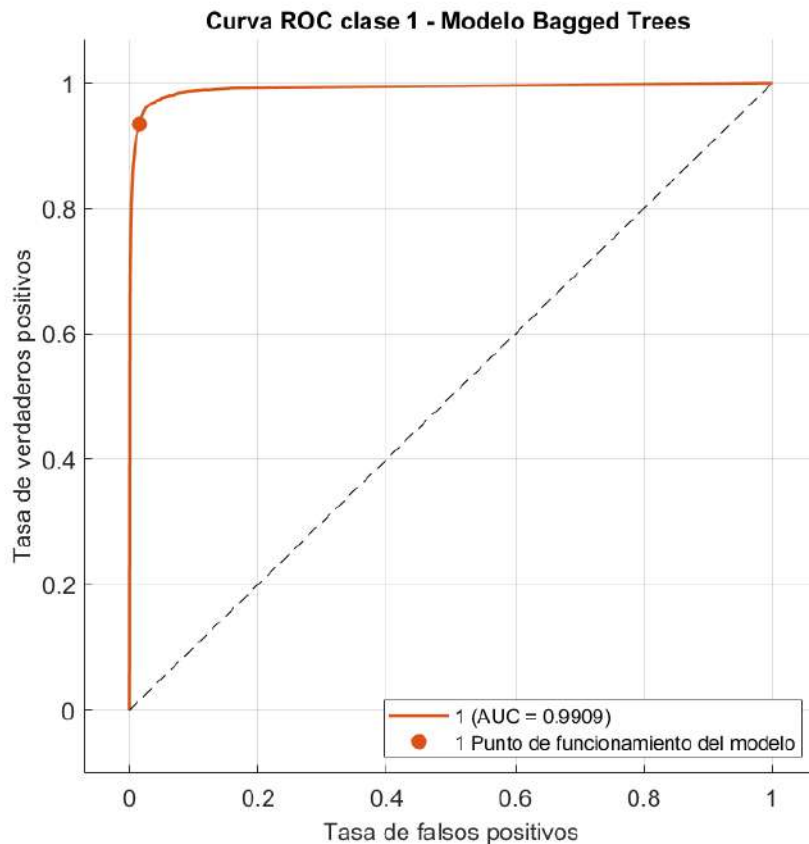


Fig. 4.6. Curva ROC clase 1.

pronunciada hacia el vértice superior izquierdo, indicando un rendimiento destacado del clasificador. La presencia de un punto de operación óptima en proximidad al vértice superior izquierdo sugiere un equilibrio eficiente entre sensibilidad y especificidad. El valor del Área bajo la Curva (AUC) registrado como 0,9983 refuerza la calidad del rendimiento clasificatorio, ya que se acerca al valor máximo de 1.0. Estos resultados señalan un alto nivel de precisión y discriminación en la clasificación de la clase 2, respaldando la efectividad general del modelo.

La figura 4.8 presenta la curva ROC correspondiente a la clase 3 (Bloqueo de rama izquierda). En esta representación gráfica, se destaca una curva que asciende de manera pronunciada hacia el vértice superior izquierdo, indicando un rendimiento destacado del clasificador. La presencia de un punto de operación óptima en proximidad al vértice superior izquierdo sugiere un equilibrio eficiente entre sensibilidad y especificidad. El valor del Área bajo la Curva (AUC) registrado como 0,9974 refuerza la calidad del rendimiento clasificatorio, ya que se acerca al valor máximo de 1.0. Estos resultados señalan un alto nivel de precisión y discriminación en la clasificación de la clase 3, respaldando la

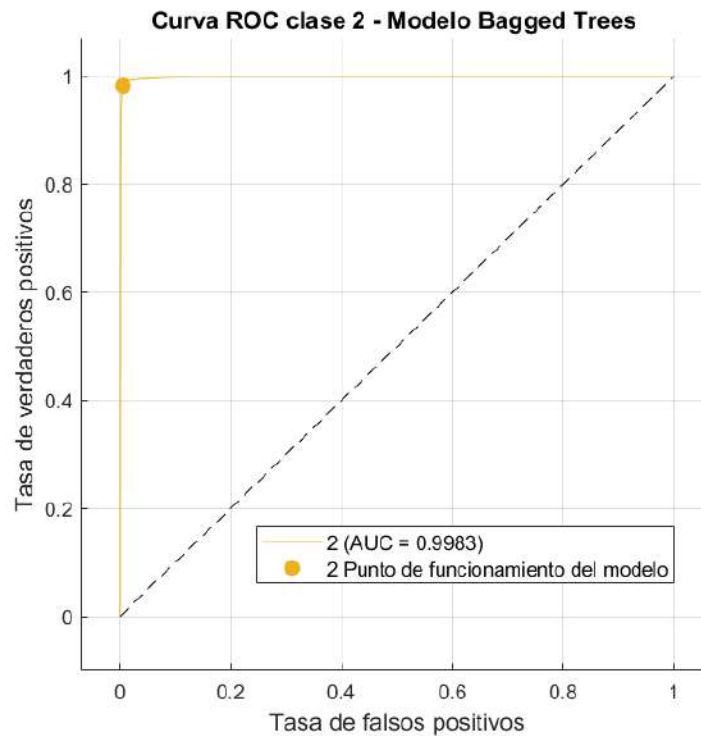


Fig. 4.7. Curva ROC clase 2.

efectividad general del modelo.

La figura 4.9 presenta la curva ROC correspondiente a la clase 4 (Pulso acelerado). En esta representación gráfica, se destaca una curva que asciende de manera pronunciada hacia el vértice superior izquierdo, indicando un rendimiento destacado del clasificador. La presencia de un punto de operación óptima en proximidad al vértice superior izquierdo sugiere un equilibrio eficiente entre sensibilidad y especificidad. El valor del Área bajo la Curva (AUC) registrado como 0,9983 refuerza la calidad del rendimiento clasificatorio, ya que se acerca al valor máximo de 1.0. Estos resultados señalan un alto nivel de precisión y discriminación en la clasificación de la clase 4, respaldando la efectividad general del modelo.

El modelo Bagged Trees empleado para la clasificación de las cinco clases demuestra una notable resistencia al overfitting, y esto se atribuye a varias decisiones estratégicas en el proceso de modelado. En primer lugar, se trabajó con un conjunto de datos equilibrado con aproximadamente 8000 datos por clase, asegurando una representación justa de cada clase. Este enfoque mitiga la posibilidad de que el modelo se sesgara hacia clases más frecuentes, promoviendo así una generalización más efectiva.

Adicionalmente, se implementó una validación cruzada de 5 folds durante el entre-

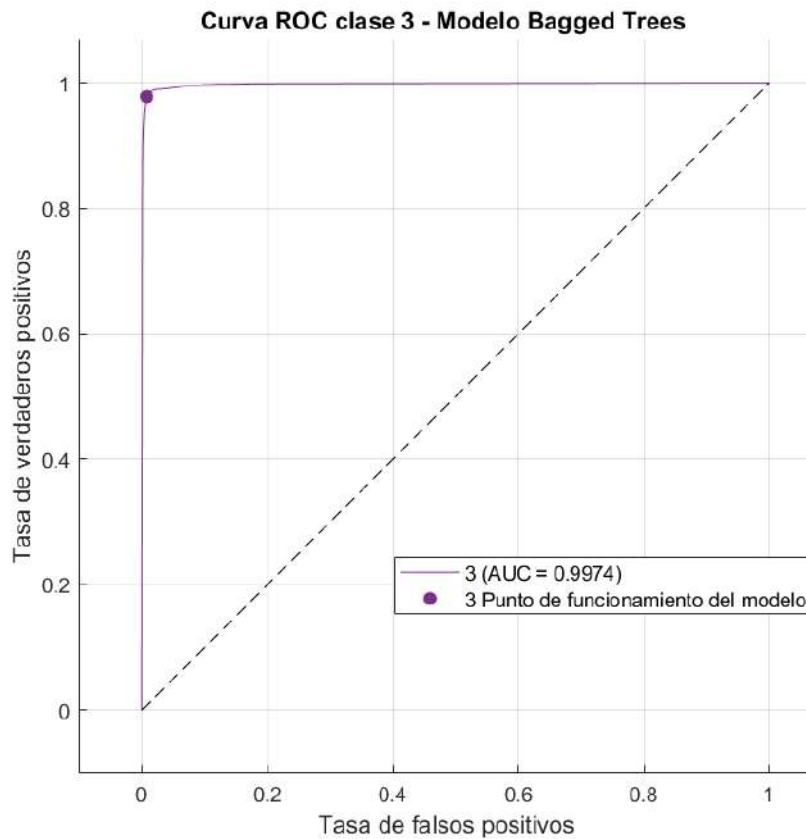


Fig. 4.8. Curva ROC clase 3.

namiento del modelo. La validación cruzada proporciona una evaluación más robusta del rendimiento del modelo, ya que evalúa su capacidad de generalización en múltiples conjuntos de datos de prueba.

La combinación de un conjunto de datos balanceado y la validación cruzada de 5 folds brinda una perspectiva integral sobre la capacidad del modelo Bagged Trees para clasificar las cinco clases, disminuyendo significativamente el riesgo de overfitting y respaldando la confiabilidad de sus resultados en diversos escenarios.

Las afirmaciones anteriores se respaldan con la presentación de la matriz de confusión del conjunto de prueba (test) del modelo Bagged Trees, la cual se muestra en la Figura 4.10. En esta figura, se destaca la capacidad del clasificador para asignar correctamente datos desconocidos, lo que demuestra su robustez y capacidad de generalización.

La clasificación de la señal ECG se realiza a través de un árbol de decisión, donde la salida del clasificador, los valores de presión arterial obtenidos de los estimadores de




Fig. 4.9. Curva ROC clase 4.

PAS y PAD, y la frecuencia arterial por minuto se convierten en factores determinantes. Se etiqueta la señal ECG como "Normal" si el 90 % o más de las señales ECG individuales analizadas por el clasificador corto son clasificadas como normales (clase 0), los valores de presión arterial se mantienen en los rangos de normalidad ($PA < 120/80$), y la frecuencia cardíaca se conserva entre 60 y 100 latidos por minuto durante al menos 3 minutos de los 5 minutos que dura el análisis. En caso contrario, se clasifica como "no normal". Este enfoque proporciona una evaluación integral que incorpora múltiples parámetros para determinar la condición de la dinámica cardíaca.

Modelo Bagged Trees

Clase Verdadera	0	6882	190	52	70	5	95.6%	4.4%
	1	158	5942	86	95	80	93.4%	6.6%
	2	47	64	6407	4	2	98.2%	1.8%
	3	38	96	6	7103	19	97.8%	2.2%
	4	8	55	3	26	4984	98.2%	1.8%
							TPR	FNR
PPV		96.5%	93.6%	97.8%	97.3%	97.9%		
FDR		3.5%	6.4%	2.2%	2.7%	2.1%		
		0	1	2	3	4		
		Clase Predicha						

Fig. 4.10. Matriz de confusión del modelo Bagged Trees - Test.

4.4 Pruebas con pacientes

4.4.1 Toma de presión arterial y señal ECG

Para la recolección de datos, se siguió el protocolo descrito en la sección 3.6. Los sujetos de estudio son estudiantes de la Universidad Antonio Nariño, sede Popayán. En total, se contó con la participación de 10 sujetos, de los cuales 3 son hombres y 7 son mujeres, con edades comprendidas entre 19 y 23 años. Todos los participantes se consideran presuntamente sanos.

A continuación, se presentan los datos obtenidos en la Tabla 4.10, que incluye los valores de presión arterial de los pacientes en reposo y la presión arterial después de realizado el ejercicio *jumping jack* que se utiliza para simular las alteraciones de la presión arterial.

Tabla. 4.10. Datos y valores de presión arterial de los pacientes

P	G	Edad	Presión Arterial en reposo				Presión arterial post-ejercicio			
			15	90	165	240	15	90	165	240
1	M	21	120/82	116/75	113/78	126/78	142/89	129/90	132/89	125/89
1	M	21	106/72	107/72	122/75	107/74	143/88	121/81	129/82	119/79
2	M	19	122/75	102/69	116/78	115/76	133/84	134/84	124/76	124/74
3	F	21	114/75	112/74	111/76	114/75	139/85	134/84	129/83	125/81
4	F	20	113/65	107/63	120/66	121/64	142/73	128/68	117/62	115/61
4	F	20	106/64	106/63	107/65	113/66	139/72	115/67	122/72	119/69
5	F	21	111/73	109/69	111/73	116/76	136/80	123/77	121/76	123/78
5	F	21	117/74	114/75	110/74	110/74	143/88	130/82	127/82	122/77
6	M	22	110/71	102/68	110/69	107/68	119/69	118/73	108/75	123/68
7	M	22	114/68	115/66	111/69	109/64	119/66	125/75	125/78	128/80
8	M	19	132/68	132/63	132/66	131/71	137/76	146/78	145/70	132/65
9	M	23	125/73	116/72	116/70	116/73	133/64	134/67	125/63	123/69
10	M	19	97/52	93/48	93/51	87/51	121/55	112/57	110/60	104/57

Proceso de toma de presión arterial y señal ECG

En las siguientes imágenes, se detalla el proceso de captura de señales, que incluye el registro de la señal ECG y la presión arterial. El procedimiento inicia con la recepción del paciente, su instrumentación y la toma inicial de la señal ECG junto con los valores de la presión arterial (ver Figura 4.11). Posteriormente, se muestra el período durante el cual el paciente realiza el ejercicio de Jumping Jack (ver Figura 4.12). Finalmente, se lleva a cabo la toma final de la señal ECG y los valores de presión arterial una vez concluido el ejercicio (ver Figura 4.13).

Señal ECG obtenidas

A continuación, se exhiben gráficas de las señales ECG de los pacientes en reposo y después del ejercicio, junto con representaciones de las variaciones en los valores de presión arterial sistólica (PAS) y presión arterial diastólica (PAD) antes y después de la actividad física. Estos datos post-ejercicio son particularmente relevantes para evaluar la eficacia de los estimadores de PAS y PAD al simular condiciones de pacientes hipertensos, un 20 % de los datos obtenidos fueron enviados para reforzar el entrenamiento de los estimadores de PA.



(a) Instrumentalización del paciente 7

(b) Instrumentalización del paciente 2

Fig. 4.11. Toma de señal ECG y valores de presión arterial en reposo.



(a) Paciente 10

(b) Paciente 8

Fig. 4.12. Período de ejercicio.



Fig. 4.13. Toma de señales post ejercicio al paciente 6.

Las gráficas de las señales ECG proporcionan una visualización clara de las respuestas eléctricas del corazón en ambos estados, destacando posibles cambios en la frecuencia cardíaca, amplitud de ondas y otros patrones característicos. Asimismo, las representaciones de las variaciones en la presión arterial ofrecen información valiosa sobre la respuesta cardiovascular al ejercicio, especialmente en el contexto de la simulación de condiciones hipertensas. Estos datos contribuyen a la evaluación de la eficiencia y robustez de los estimadores de presión arterial, permitiendo ajustes precisos en el monitoreo de la salud cardiovascular.

La figura 4.14 presenta una comparación de 5 segundos de la señal ECG del paciente 2. En la subfigura a) correspondiente al estado de reposo. Por otro lado, en la subfigura b) que representa el estado post-ejercicio tras realizar *jumping jacks*, se evidencia una disminución en la frecuencia cardíaca con respecto a la frecuencia cardíaca en estado de reposo, aunque se destaca un notable aumento en la amplitud de la onda T. En reposo, esta onda tenía un pico de señal de 0.4 mV, mientras que después de la realización del ejercicio, se incrementa a 0.8 mV. Estos cambios en la señal ECG sugieren una respuesta cardíaca y eléctrica característica asociada al ejercicio, donde la disminución en la frecuencia cardíaca contrasta con el aumento en la amplitud de la onda T.

La figura 4.15 presenta una comparación de los valores de PA obtenidos del paciente 2. En la subfigura a) correspondiente al estado de reposo, se observa una PA normal que varía entre 100 y 120 mmHg en sístole y entre 70 y 75 mmHg en diástole. Por otro lado, en la subfigura b) que representa el estado post-ejercicio tras realizar *jumping jacks*, en esta se observa como la PA sube debido al ejercicio pasan a variar ahora entre 125 y 130




Fig. 4.14. Comparación de Señal ECG paciente 2 en reposo y post-ejercicio.

mmHg en sístole y entre 75 y 85 mmHg en diástole.

La figura 4.16 presenta una comparación de 5 segundos de la señal ECG del paciente 6. En la subfigura a) correspondiente al estado de reposo, se observa que el pico de la onda R llega hasta aproximadamente los 2 mV y el pico de la onda T en 0.5 mV. Por otro lado, en la subfigura b) que representa el estado post-ejercicio tras realizar *jumping jacks*, se evidencia un aumento en la frecuencia cardíaca con respecto a la frecuencia cardíaca en reposo, así mismo, se destaca un notable disminución en la amplitud de la onda R, que disminuye cerca de 0.8 mV. Estos cambios en la señal ECG sugieren una respuesta cardíaca y eléctrica característica asociada al ejercicio, donde el aumento en la frecuencia

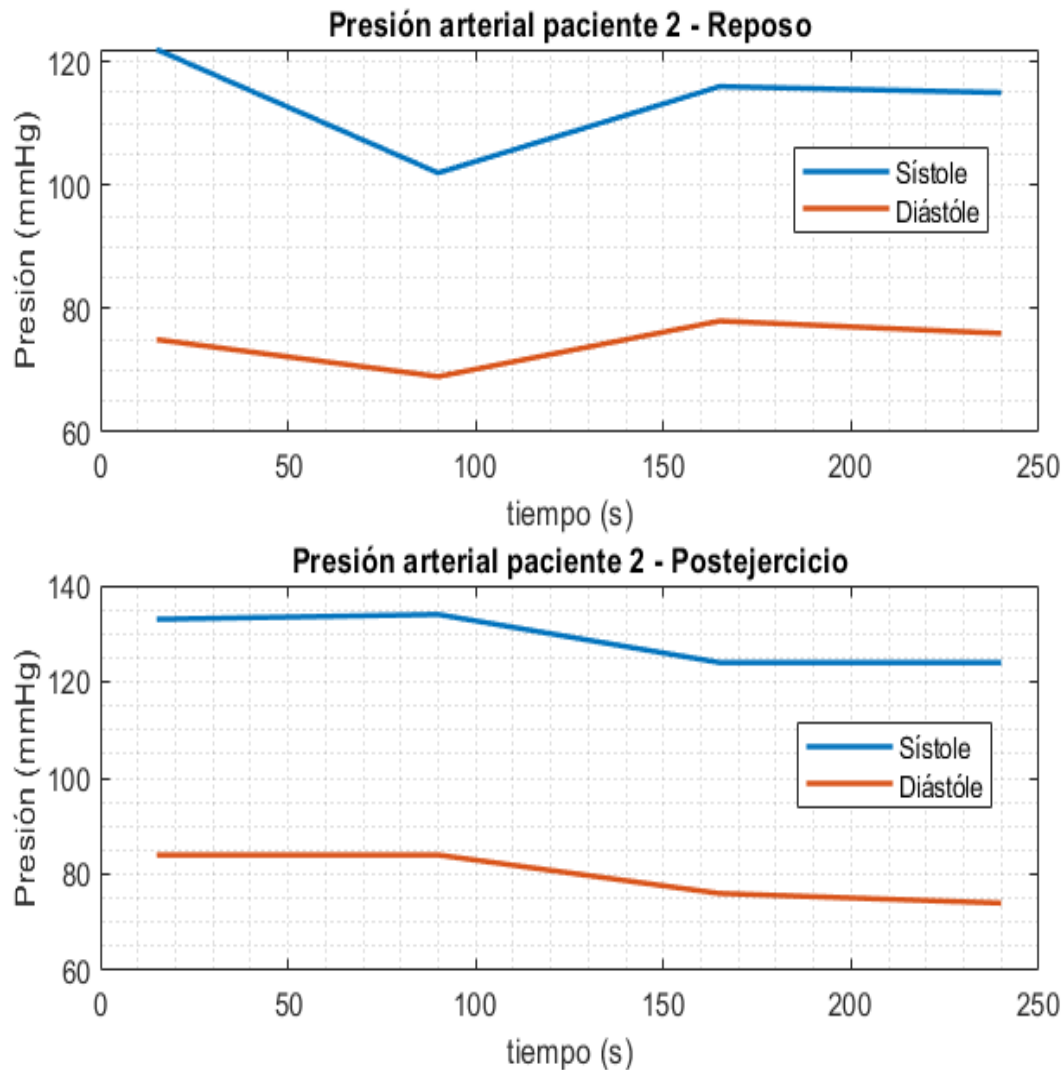


Fig. 4.15. Comparación de gráficas de presión paciente 2 en reposo y post-ejercicio.

cardíaca contrasta con la disminución en la amplitud de la onda R.

La figura 4.17 presenta una comparación de los valores de PA obtenidos del paciente 6. En la subfigura a) correspondiente al estado de reposo, se observa una PA normal que varía entre 100 y 110 mmHg en sístole y oscila en 70 mmHg en diástole. Por otro lado, en la subfigura b) que representa el estado post-ejercicio tras realizar *jumping jacks*, en esta se observa como la PA sube debido al ejercicio pasan a variar ahora entre 105 y 120 mmHg en sístole y entre 70 y 85 mmHg en diástole.

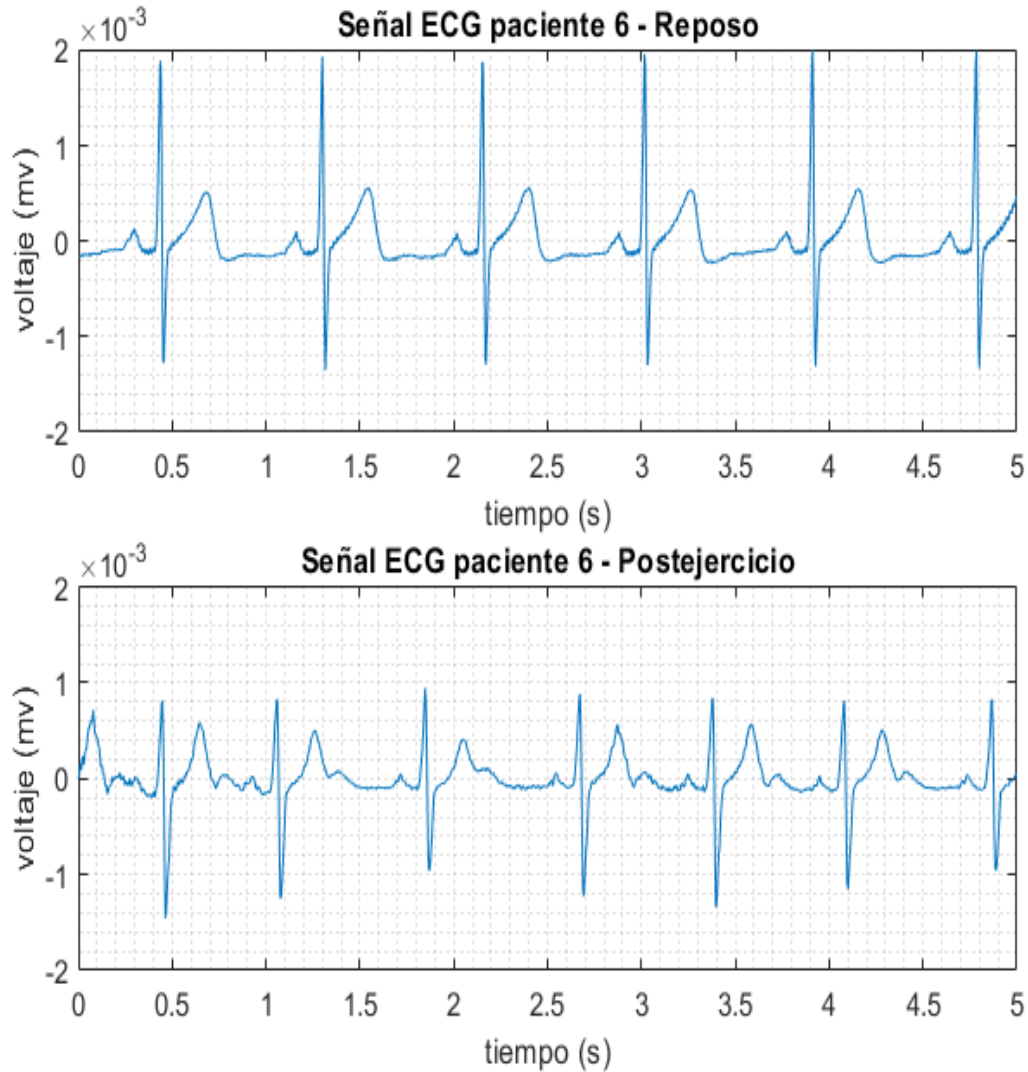


Fig. 4.16. Comparación de Señal ECG paciente 6 en reposo y post-ejercicio.

4.4.2 Prueba del estimador de presión arterial con datos de pacientes

En la tabla 4.11, se presenta una comparación entre los valores medidos y los valores estimados de presión arterial, junto con sus respectivos errores, para los datos adquiridos cuando los pacientes se encontraban en reposo.

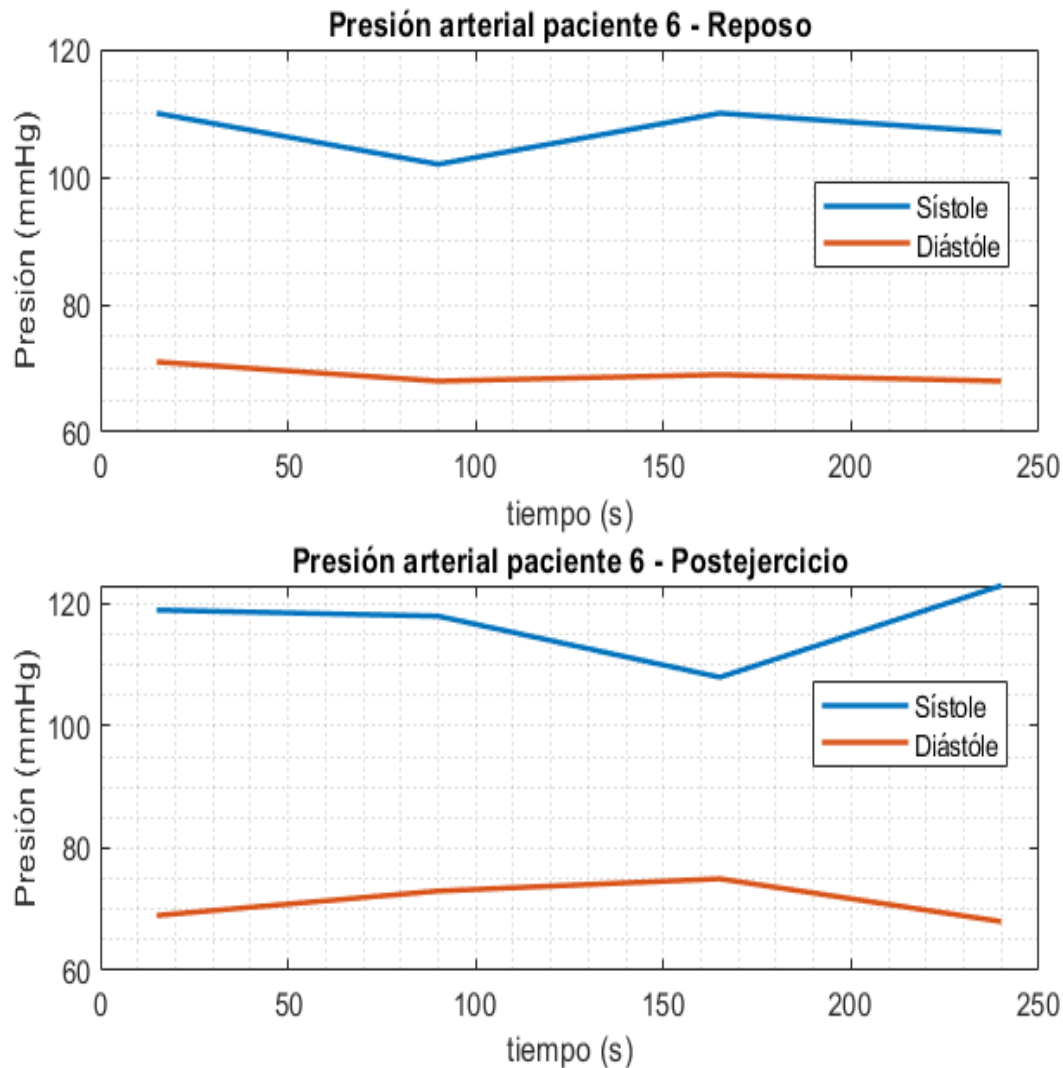


Fig. 4.17. Comparación de gráficas de presión paciente 6 en reposo y post-ejercicio.

Tabla. 4.11. Comparación entre presión medida y presión estimada en reposo

P	Presión Arterial en reposo								
		15	90	165	240				
1	Medida	120	82	116	75	113	78	126	78
	Estimada	122	78	116	75	113	78	126	78
	Error	2	-4	0	0	0	0	0	0
1	Medida	106	72	107	72	122	75	107	74
	Estimada	106	72	120	74	122	75	125	79

	Error	0	0	13	2	0	0	18	5
	Medida	122	75	102	69	116	78	115	76
2	Estimada	122	75	122	77	116	74	115	73
	Error	0	0	13	2	0	0	18	5
	Medida	114	75	112	74	111	76	114	75
3	Estimada	114	74	112	74	112	74	112	74
	Error	0	0	20	8	0	-4	0	-3
	Medida	113	65	107	63	120	66	121	64
4	Estimada	113	65	112	65	110	64	109	64
	Error	0	0	5	2	-10	-2	-12	0
	Medida	106	64	106	63	107	65	113	66
4	Estimada	106	64	106	63	107	63	108	64
	Error	0	-1	0	0	1	-2	-2	-1
	Medida	111	73	109	69	111	73	116	76
5	Estimada	119	74	109	69	111	73	116	76
	Error	8	1	0	0	0	0	0	0
	Medida	117	74	114	75	110	74	110	74
5	Estimada	124	74	121	74	123	73	110	74
	Error	7	0	7	-1	13	-1	0	0
	Medida	110	71	102	68	110	69	107	68
6	Estimada	110	71	107	69	107	70	108	66
	Error	0	0	5	1	-3	1	1	-2
	Medida	114	68	115	66	111	69	109	64
7	Estimada	110	65	111	66	111	69	109	64
	Error	-4	-3	-4	0	0	0	0	0
	Medida	132	68	132	63	132	66	131	71
8	Estimada	115	71	126	69	132	66	122	68
	Error	-17	3	-6	6	0	0	-9	-3
	Medida	125	73	116	72	116	70	116	73
9	Estimada	116	72	116	72	116	70	123	76
	Error	-9	-1	0	0	0	0	7	3
	Medida	97	52	93	48	93	51	87	51
10	Estimada	92	49	93	48	92	49	87	51
	Error	-5	-3	0	0	-1	-2	0	0

En la tabla 4.12, se presenta una comparación entre los valores medidos y los valores estimados de presión arterial, junto con sus respectivos errores, para los datos adquiridos

posteriormente del ejercicio realizado por los pacientes.

Tabla. 4.12. Comparación entre presión medida y presión estimada después del ejercicio

P		Presión Arterial después de ejercicio							
		15		90		165		240	
1	Medida	142	89	129	90	132	89	125	89
	Estimada	137	87	129	90	132	89	124	75
	Error	-5	-2	0	0	0	0	-1	-14
1	Medida	143	88	121	81	129	82	119	79
	Estimada	143	88	121	81	129	82	125	80
	Error	0	0	0	0	0	0	6	1
2	Medida	133	84	134	84	124	76	124	74
	Estimada	133	84	134	84	124	76	115	74
	Error	0	0	0	0	0	0	-9	0
3	Medida	139	85	134	84	129	83	125	81
	Estimada	121	71	130	82	129	82	125	81
	Error	-18	-14	-4	-2	0	-1	0	0
4	Medida	142	73	128	68	117	62	115	61
	Estimada	122	67	127	68	122	65	119	64
	Error	-20	-6	-1	0	5	3	4	3
4	Medida	139	72	115	67	122	72	119	69
	Estimada	129	69	127	68	122	72	119	68
	Error	-10	-3	12	1	0	0	0	-1
5	Medida	136	80	123	77	121	76	123	78
	Estimada	130	75	123	77	129	78	116	74
	Error	-6	-5	0	0	8	2	-7	-4
5	Medida	143	88	130	82	127	82	122	77
	Estimada	137	85	132	83	127	82	119	76
	Error	-6	-3	2	1	0	0	-3	-1
6	Medida	119	69	118	73	108	75	123	68
	Estimada	119	69	121	70	108	75	116	71
	Error	0	0	3	-3	0	0	-7	3
7	Medida	119	66	125	75	125	78	128	80
	Estimada	119	66	125	75	125	78	128	80
	Error	0	0	0	0	0	0	0	0
	Medida	137	76	146	78	145	70	132	65

	Estimada	137	76	146	78	145	70	135	72
	Error	0	0	0	0	0	0	3	7
	Medida	133	64	134	67	125	63	123	69
9	Estimada	130	65	131	67	125	63	124	70
	Error	-3	1	-3	0	0	0	1	1
	Medida	121	55	112	57	110	60	104	57
10	Estimada	113	66	112	57	110	60	104	57
	Error	-8	11	0	0	0	0	0	0

La figura 4.18, presenta los resultados de la comparación entre los valores de presión arterial medidos y los valores estimados mediante un modelo de regresión de procesos gaussianos. Esta representación visual ofrece una perspectiva clara de la capacidad del modelo para aproximar con precisión los niveles reales de presión arterial. Al observar la superposición de las curvas de presión medida y estimada, se puede evidenciar la calidad del ajuste y la capacidad del modelo para capturar las variaciones en los datos tomados a los pacientes de este estudio.

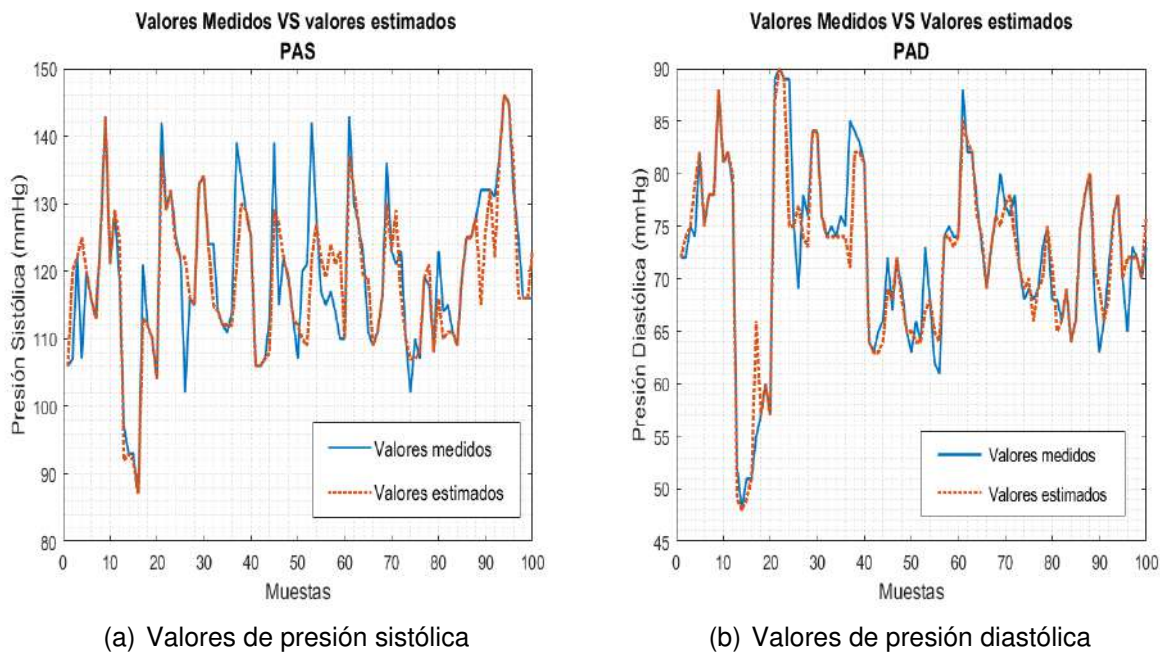


Fig. 4.18. Comparación de valores de presión arterial medidos vs valores estimados

Las tablas 4.13 y 4.14 presentan las métricas obtenidas por los modelos de regresión utilizados para estimar los valores de presión arterial sistólica (PAS) y diastólica (PAD), respectivamente. Estas métricas son resultado de la evaluación de los modelos al utilizar

los datos generados a partir de las señales de electrocardiograma (ECG) y los valores de presión arterial (PA) recopilados de los pacientes incluidos en el estudio. Dichas tablas proporcionan una visión detallada de cómo cada modelo se desempeña en términos de métricas específicas, ofreciendo así una evaluación cuantitativa de la eficacia de los modelos en la estimación de la presión arterial.

Tabla. 4.13. Métricas del modelo de estimación de PAS al ser evaluado con datos de pacientes

Estimación de Presión Sistólica			
R ²	RMSE	MAE	MSE
0.74	6.042	3.40	36.5

Tabla. 4.14. Métricas del modelo de estimación de PAD al ser evaluado con datos de pacientes

Estimación de Presión Diastólica			
R ²	RMSE	MAE	MSE
0.87	3.076	1.56	9.46

5 Conclusiones

Este proyecto ha alcanzado con éxito sus objetivos al desarrollar un sistema de clasificación de la normalidad de la dinámica cardíaca, aprovechando las señales cardíacas ECG para estimar una alta precisión los valores de presión arterial, permitiendo así la combinación las técnicas de holter cardíaco y monitorización ambulatoria de presión arterial (MAPA). Este enfoque mejora la capacidad de clasificar el riesgo cardiovascular al integrar información sobre la presión arterial, reconocida por su estrecha relación con las enfermedades cardíacas y su contribución significativa a la comprensión general de la salud cardíaca.

La implementación del algoritmo de extracción de características en el dominio del tiempo y tiempo-frecuencia de la señal ECG permitió obtener diversas características en el dominio temporal, como la desviación estándar, curtosis, asimetría y entropía, y en el dominio de la frecuencia, como la energía de la densidad espectral de potencia y el valor RMS. Además, se extrajeron características de complejidad de la señal, como la movilidad, la complejidad, el ritmo, la entropía y la dimensión fractal.

Estas características fueron utilizadas para el entrenamiento de los modelos de clasificación y los modelos de regresión.

Las características de complejidad de la señal ECG se utilizaron para entrenar el modelo de estimación de presión sistólica y el modelo de estimación de presión diastólica, para este propósito se eligió un modelo de regresión de procesos gaussianos (RPG) con kernel exponencial, este modelo fue elegido pues obtuvo el coeficiente de determinación R^2 mas alto y menor desviación cuadrática media $RMSE$, entre todos los modelos disponibles en el *app regression learner* de Matlab, dicho modelo obtuvo un $R^2 = 0,88$ y un $RMSE = 3,58mmHg$ al estimar los valores de la presión arterial diastólica. el mismo tipo de modelo obtuvo entrenado para estimar los valores de presión arterial sistólica obtuvo un $R^2 = 0,83$ y un $RMSE = 8,4mmHg$. la suma de desviación cuadrática media de ambos modelos da como resultado un $RMSE = 11,98mmHg$.

Por lo tanto, el modelo de estimación de presión arterial propuesto cumple con el

5. Conclusiones

estándar establecido por la British Hypertension Society (BHS) y se cataloga como un modelo de estimación de presión arterial de nivel C, pues logra un error acumulado $RMSE < 15mmHg$. Esto demuestra la eficacia de utilizar características de complejidad de la señal ECG para la estimación de la presión arterial, abriendo nuevas posibilidades para el diagnóstico de enfermedades cardiovasculares.

Las características temporales y de frecuencia se utilizaron para entrenar el modelo de clasificación de normalidad de la dinámica cardíaca. Se aplicó un algoritmo para jerarquizar las características en base a su utilidad para la clasificar, lo cual redujo de 7 características a 4 el número de características para el entrenamiento de la clasificación. Estas fueron: desviación estándar, entropía, curtosis y energía (densidad espectral de potencia). El modelo de clasificación elegido fue el bagged trees que presentó una exactitud de 96.6 %, una sensibilidad de 96.82 %, y una especificidad de 96.62 %

La validación exitosa de estos algoritmos mediante conjuntos de datos recopilados con el polifisiógrafo AdInstruments PowerLab 26T respalda la eficacia y confiabilidad de la metodología propuesta.

En conjunto, este proyecto ha proporcionado herramientas valiosas para apoyo al diagnóstico y la clasificación precisa de riesgos cardiovasculares, contribuyendo significativamente al ámbito de la salud cardíaca y abriendo nuevas vías para futuras investigaciones y aplicaciones clínicas.

Referencias Bibliográficas

- [1] L. Zhao, C. Liang, Y. Huang, G. Zhou, Y. Xiao, N. Ji, Y.-T. Zhang, and N. Zhao, "Emerging sensing and modeling technologies for wearable and cuffless blood pressure monitoring," *npj Digital Medicine* 2023 6:1, vol. 6, pp. 1--15, 5 2023. [Online]. Available: <https://www-nature-com.ezproxy.uan.edu.co/articles/s41746-023-00835-6>
- [2] J. I. Gupta and M. J. Shea, "Biología del corazón," 5 2022.
- [3] J. C. Serrano, "Desarrollo de un método de estimación de la presión arterial combinando fotopleletismografía y electrocardiografía," *UPV*, 2019.
- [4] M. EKG, "Derivaciones del electrocardiograma," 6 2022.
- [5] S. F. on ResearchGate, "Ondas, intervalos y segmentos que conforman el electrocardiograma," 12 2010. [Online]. Available: https://www.researchgate.net/figure/Figura-12-Ondas-intervalos-y-segmentos-que-conforman-el-electrocardiograma_fig2_246992000
- [6] J. Pan and W. J. Tompkins, "A real-time qrs detection algorithm," *IEEE Transactions on Biomedical Engineering*, vol. BME-32, no. 3, pp. 230--236, 1985.
- [7] M. L. G. Sr., D. K. Blackwell, M. L. G. Jr., and D. Rajan, *EXECUTIVE OVERVIEW OF THE FOURTH MANUFACTURING REVOLUTION*, 1st ed. McGraw-Hill Education, 2019. [Online]. Available: <https://www.accessengineeringlibrary.com/content/book/9781260135039/chapter/chapter6>
- [8] A. W. Services, "Validación cruzada." [Online]. Available: https://docs.aws.amazon.com/es_es/machine-learning/latest/dg/cross-validation.html
- [9] D. ABC, "Jumping jacks," 4 2020. [Online]. Available: https://www.abc.es/bienestar/fitness/abci-jumping-jacks-202004080958_noticia.html?ref=https%3A%2F%2Fwww.abc.es%2Fbienestar%2Ffitness%2Fabci-jumping-jacks-202004080958_noticia.html
- [10] M. Hammad, S. A. Chelloug, R. Alkanhel, A. J. Prakash, A. Muthanna, I. A. Elgendy, and P. Pławiak, "Automated detection of myocardial infarction and heart conduction disorders based on feature selection and a deep learning model," *Sensors*, vol. 22, p. 6503, 8 2022. [Online]. Available: <https://www.mdpi.com/1424-8220/22/17/6503>
- [11] D. Patiño, J. Medina, R. Silva, A. Guijarro, and J. Rodríguez, "Prediction of arrhythmias and acute myocardial infarctions using machine learning," *Ingenius*, vol. 2023, pp. 79--89, 1 2023.
- [12] R. M. Carey and P. K. Whelton, "Prevention, detection, evaluation, and management of high blood pressure in adults: Synopsis of the 2017 american college of cardiology/american heart association hypertension guideline," *Annals of Internal Medicine*, vol. 168, p. 351, 3 2018.
- [13] E. O'Brien, J. Petrie, W. Littler, M. D. Swiet, P. L. Padfield, D. Altman, M. Bland, A. Coats, N. Atkins *et al.*, "The british hypertension society protocol for the evaluation of blood pressure measuring devices," *Journal of Hypertension*, vol. 11, p. S43--S62, 1993.
- [14] T. Cascino and M. J. Shea, "Electrocardiografía," 6 2021. [Online]. Available: <https://www.msmanuals.com/es-co/professional/trastornos-cardiovasculares/pruebas-y-procedimientos-cardiovasculares/electrocardiograf%C3%ADa>
- [15] OMS, "Enfermedades cardiovasculares," 2017. [Online]. Available: https://www.who.int/es/health-topics/cardiovascular-diseases#tab=tab_1

- [16] F. E. del Corazón, "La hipertensión mata cada año a 7,5 millones de personas en el mundo," 2022. [Online]. Available: <https://fundaciondelcorazon.com/prensa/notas-de-prensa/2567-hipertension-mata-cada-ano-a-75-millones-de-personas-en-el-mundo.html>
- [17] M. Sociedad, L. De, H. Organismo, I. Mendoza, L. E. . M. Estrada, G. . P. García, A. . Chacón, G. . Vera, M. . Contreras-Velásquez, and J. . Bermúdez, "Revista latinoamericana de hipertensión," *Revista Latinoamericana de Hipertensión*, vol. 11, pp. 1--6, 2016. [Online]. Available: <http://www.redalyc.org/articulo.oa?id=170250835001>
- [18] A. de la Sierra, E. Bragulat, and U. de Hipertensión Arterial. Instituto de Investigaciones Biomédicas August Pi i Sunyer (IDIBAPS). Hospital Clínic. Universidad de Barcelona, "Hipertensión arterial y riesgo cardiovascular | medicina integral," pp. 197--201, 3 2001. [Online]. Available: <https://www.elsevier.es/es-revista-medicina-integral-63-articulo-hipertension-arterial-riesgo-cardiovascular-10022761>
- [19] OMS, "Información general sobre la hipertensión en el mundo," 2013. [Online]. Available: https://apps.who.int/iris/bitstream/handle/10665/87679/WHO_DCO_WHD_2013_2_spa.pdf;jsessionid=C271DFC83AD0EE5AB38A9354AA36C708?sequence=1
- [20] -----, "Hipertensión," 8 2021. [Online]. Available: <https://www.who.int/es/news-room/fact-sheets/detail/hypertension>
- [21] CEmprende, "Enfermedades cardiovasculares, un gran desafío para la salud pública en Colombia | cemprende," 9 2022. [Online]. Available: <https://www.innpuccolombia.com/cemprende/noticias/enfermedades-cardiovasculares-un-gran-desafio-para-la-salud-publica-en-colombia>
- [22] M. S. Z. Sánchez, C. P. Z. Sánchez, P. A. C. López, M. S. Sanabria, and S. C. H. Hernández, "Prevalencia de hipertensión arterial en Colombia," *Acta Médica Colombiana*, vol. 44, 2019.
- [23] N. unidas and CEPAL, "La agenda 2030 y los objetivos de desarrollo sostenible: una oportunidad para América Latina y el Caribe," 2018. [Online]. Available: www.cepal.org/es/suscripciones
- [24] DANE, "Defunciones no fetales 2021," 2021. [Online]. Available: <https://www.dane.gov.co/index.php/estadisticas-por-tema/salud/nacimientos-y-defunciones/defunciones-no-fetales/defunciones-no-fetales-2021>
- [25] Y. Huang, W. Huang, W. Mai, X. Cai, D. An, Z. Liu, H. Huang, J. Zeng, Y. Hu, and D. Xu, "White-coat hypertension is a risk factor for cardiovascular diseases and total mortality," *Journal of Hypertension*, vol. 35, p. 677, 2017. [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/31388886/>
- [26] J. A. LOZANO, "Arritmias cardíacas y su tratamiento," *Offarm*, vol. 20, pp. 96--105, 12 2001. [Online]. Available: <https://www.elsevier.es/es-revista-offarm-4-articulo-arritmias-cardiacas-su-tratamiento-13023366>
- [27] M. Simjanoska, M. Gjoreski, M. Gams, and A. M. Bogdanova, "Non-invasive blood pressure estimation from ECG using machine learning techniques," *Sensors 2018, Vol. 18, Page 1160*, vol. 18, p. 1160, 4 2018. [Online]. Available: <https://www.mdpi.com/1424-8220/18/4/1160/html>
- [28] X. Fan, H. Wang, F. Xu, Y. Zhao, and K. L. Tsui, "Homecare-oriented intelligent long-term monitoring of blood pressure using electrocardiogram signals," *IEEE Transactions on Industrial Informatics*, vol. 16, pp. 7150--7158, 11 2020.
- [29] H. H. Hager and B. Burns, *Artery Cannulation*. ncbi, 2023. [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/30778648>
- [30] K. Chavanu, J. Merkel, and A. M. Quan, "Role of ambulatory blood pressure monitoring in the management of hypertension," *American Journal of Health-System Pharmacy*, vol. 65, pp. 209--218, 2 2008. [Online]. Available: <https://dx.doi.org/10.2146/ajhp060663>
- [31] A. J. Viera, K. Lingley, and A. L. Hinderliter, "Tolerability of the oscar 2 ambulatory blood pressure monitor among research participants: A cross-sectional repeated measures study," *BMC Medical Research Methodology*, vol. 11, pp. 1--7, 4 2011. [Online]. Available: <https://bmcmrmedresmethodol.biomedcentral.com/articles/10.1186/1471-2288-11-59>
- [32] D. B. Wax, H. M. Lin, and A. B. Leibowitz, "Invasive and concomitant noninvasive intraoperative blood pressure monitoring observed differences in measurements and associated therapeutic interventions," *Anesthesiology*, vol. 115, pp. 973--978, 11 2011. [Online]. Available: <https://dx.doi.org/10.1097/ALN.0b013e3182330286>
- [33] J. Rodríguez-Velásquez, S. E. Prieto-Bohórquez, F. Mendoza, C. Correa-Herrera, M. Y. Soracipa-Muñoz, F. López, V. Rodríguez-Torrado, L. Méndez-Pino, and L. Pinilla-Bonilla, "Evaluación probabilista de la dinámica cardíaca arritmica con y sin metoprolol," *CES Medicina*, vol. 31, pp. 144--154, 9 2017. [Online]. Available: <https://revistas.ces.edu.co/index.php/medicina/article/view/3691>

- [34] M. B. Shah Nawaz and H. Dawood, "An effective deep learning model for automated detection of myocardial infarction based on ultrashort-term heart rate variability analysis," *Mathematical Problems in Engineering*, vol. 2021, pp. 1--13, 9 2021, recopilacion de metodos de deep learning para deteccion de problemas cardiacos. [Online]. Available: <https://www.hindawi.com/journals/mpe/2021/6455053/>
- [35] R. S. MUÑOZ, "Estrategia para la construcción e interpretación de atractores cardiacos caóticos con estudiantes de pregrado de la facultad de medicina," *Thesis*, 2021.
- [36] T. Newman, "Anatomía y funcionamiento del corazón," 9 2021.
- [37] B. E. Fernández, V. M. Cuevas, M. A. C. Milanés, and B. E. L. Goycochea, *Hipertensión Arterial Guía para pacientes*, 2nd ed. CENAPRECE Secretaría de Salud, 2011. [Online]. Available: <http://www.cenaprece.salud.gob.mx/programas/interior/adulto/descargas/pdf/GuiaPacientesHTA.pdf>
- [38] E. SELLEN-SANCHEN, "Monitorización ambulatoria de presión arterial, acercamiento al verdadero valor de una variable biológica," *Revista Archivo Médico de Camagüey*, vol. 22, pp. 699 -- 702, 9 2018. [Online]. Available: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1025-02552018000600699&nrm=iso
- [39] E. O'Brien, J. Petrie, W. Littler, M. de Swiet, P. L. Padfield, K. O'Malley, M. Jamieson, D. Altman, M. Bland, and N. Atkins, "The british hypertension society protocol for the evaluation of automated and semi-automated blood pressure measuring devices with special reference to ambulatory systems," *Journal of Hypertension*, vol. 8, 1990. [Online]. Available: https://journals.lww.com/jhypertension/fulltext/1990/07000/the_british_hypertension_society_protocol_for_the.4.aspx
- [40] C. U. de Navarra, "Electrocardiograma." [Online]. Available: <https://www.cun.es/enfermedades-tratamientos/pruebas-diagnosticas/electrocardiograma>
- [41] R. S. Khandpur, *Biomedical Recorders*, 3rd ed. McGraw-Hill Education, 2014. [Online]. Available: <https://www.accessengineeringlibrary.com/content/book/9789339205430/chapter/chapter5>
- [42] Y. Wu, "Métodos automáticos para la detección de apnea del sueño a partir del procesado de señales de eeg y ecg," *UPV*, pp. 12--13, 9 2020.
- [43] J. Monge-Álvarez, "Higuchi and katz fractal dimension measures," 3 2015. [Online]. Available: <https://la.mathworks.com/matlabcentral/fileexchange/50290-higuchi-and-katz-fractal-dimension-measures>
- [44] T. Higuchi, "Approach to an irregular time series on the basis of the fractal theory," *Physica D: Nonlinear Phenomena*, vol. 31, pp. 277--283, 6 1988.
- [45] T. L. A. Doyle, E. L. Dugan, B. Humphries, and R. U. Newton, "Discriminating between elderly and young using a fractal dimension analysis of centre of pressure," *Int J Med Sci*, vol. 1, pp. 11--20, 2004. [Online]. Available: <https://www.medsci.org/v01p0011.htm>
- [46] Z.-X. MU, C.-L. HE, and Y.-X. Huang, "Power spectral entropy in the ecg of patients suffered from nocturnal frontal lobe epilepsy," *Journal of pharmaceutical and biomedical sciences*, 2017.
- [47] C. P. Rodríguez, "Heurística entropía de shannon y ganancia de la información," *Universidad de las Américas Puebla*, pp. 35--36, 6 2004. [Online]. Available: http://catarina.udlap.mx/u_dl_a/tales/documentos/mosl/rojas_b_js/capitulo4.pdf
- [48] IBM, "¿qué es machine learning?" septiembre 2023. [Online]. Available: <https://www.ibm.com/mx-es/analytics/machine-learning>
- [49] C. E. Rasmussen and C. K. I. Williams, *Gaussian Processes for Machine Learning*. The MIT Press, 11 2005.
- [50] MathWorks, "Gaussian process regression models." [Online]. Available: <https://la.mathworks.com/help/stats/gaussian-process-regression-models.html>
- [51] E. Morales, "Procesos gaussianos." [Online]. Available: <https://ccc.inaoep.mx/~emorales/Cursos/Aprendizaje2/Acetatos/gaussianprocesses.pdf>
- [52] I. N. da Silva, D. H. Spatti, R. A. Flauzino, L. H. B. Liboni, and S. F. dos Reis Alves, *Artificial Neural Networks: A Practical Course*. Springer, 2016.
- [53] A. E. Johnson, T. J. Pollard, L. Shen, L. wei H. Lehman, M. Feng, M. Ghassemi, B. Moody, P. Szolovits, L. A. Celi, and R. G. Mark, "Mimic-iii, a freely accessible critical care database," *Scientific Data*, vol. 3, p. 160035, 5 2016.
- [54] G. B. Moody and R. G. Mark, "The impact of the mit-bih arrhythmia database." *IEEE engineering in medicine and biology magazine : the quarterly magazine of the Engineering in Medicine y Biology Society*, vol. 20, pp. 45--50, 2001.

- [55] N. Strodthoff, T. Mehari, C. Nagel, P. J. Aston, A. Sundar, C. Graff, J. K. Kanfers, W. Haverkamp, O. Dössel, A. Loewe, M. Bär, and T. Schaeffter, "Ptbx-1+, a comprehensive electrocardiographic feature dataset," *Scientific Data* 2023 10:1, vol. 10, pp. 1--11, 5 2023. [Online]. Available: <https://www.nature.com/articles/s41597-023-02153-8>
- [56] N. Kim, A. Krasner, C. Kosinski, M. Wininger, M. Qadri, Z. Kappus, S. Danish, and W. Craelius, "Trending autoregulatory indices during treatment for traumatic brain injury," *Journal of Clinical Monitoring and Computing*, vol. 30, pp. 821--831, 12 2016.
- [57] P. Wagner, N. Strodthoff, R.-D. Boussejot, D. Kreiseler, F. I. Lunze, W. Samek, and T. Schaeffter, "Ptbx-1, a large publicly available electrocardiography dataset," *Scientific Data*, vol. 7, p. 154, 2020. [Online]. Available: <https://doi.org/10.1038/s41597-020-0495-6>
- [58] MathWorks, "Diseño de filtros fir." [Online]. Available: <https://la.mathworks.com/help/signal/ug/fir-filter-design.html>
- [59] M. Unser, "Sampling-50 years after shannon," *Proceedings of the IEEE*, vol. 88, pp. 569--587, 2000.
- [60] L. Komsta and F. Novomestky, "Moments, cumulants, skewness, kurtosis and related tests," *R package version*, vol. 14, no. 1, 2015.
- [61] V. Singh, S. Tewary, V. Sardana, and H. K. Sardana, "Arrhythmia detection - a machine learning based comparative analysis with mit-bih ecg data," *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*, pp. 1--5, 3 2019.
- [62] IBM, "Resumir: Estadísticos," 8 2023. [Online]. Available: <https://www.ibm.com/docs/es/spss-statistics/saas?topic=summarize-statistics>
- [63] J. G. Barajas, *Electrocardiograma desde una visión digital.*, 1st ed. Ediciones USTA, 2016.
- [64] J. de Pedro Carracedo, "Análisis dimensional conforme a la dinámica y complejidad de las señales biológicas," *UPM*, 10 2020.
- [65] N. Takahashi, A. Kuriyama, H. Kanazawa, Y. Takahashi, and T. Nakayama, "Validity of spectral analysis based on heart rate variability from 1-minute or less ecg recordings," *Pacing and Clinical Electrophysiology*, vol. 40, pp. 1004--1009, 9 2017.
- [66] X. L. Aubert and A. Brauers, "Estimation of vital signs in bed from a single unobtrusive mechanical sensor: Algorithms and real-life evaluation," *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 4744--4747, 8 2008.
- [67] A. Y. Shdefat, M.-I. Joo, S.-H. Choi, and H.-C. Kim, "Utilizing ecg waveform features as new biometric authentication method," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 8, p. 658, 4 2018.
- [68] J. Barco-Ríos, J. E. Duque-Parra, and J. A. Barco-Cano, "El periodo refractario de las células excitables: ¿inconsistencias de un dogma?" *Revista de la Facultad de Medicina*, vol. 68, 4 2020.
- [69] L. D. Sharma and R. K. Sunkaria, "Inferior myocardial infarction detection using stationary wavelet transform and machine learning approach," *Signal, Image and Video Processing*, vol. 12, pp. 199--206, 2 2018.
- [70] B. Fatimah, P. Singh, A. Singhal, D. Pramanick, P. S., and R. B. Pachori, "Efficient detection of myocardial infarction from single lead ecg signal," *Biomedical Signal Processing and Control*, vol. 68, p. 102678, 7 2021.
- [71] P. Melillo, R. Izzo, A. Orrico, P. Scala, M. Attanasio, M. Mirra, N. D. Luca, and L. Pecchia, "Automatic prediction of cardiovascular and cerebrovascular events using heart rate variability analysis," *PLOS ONE*, vol. 10, p. e0118504, 3 2015.

A Anexo 1

A.1 Consentimiento Informado

En mi calidad de participante en el proyecto de investigación titulado "Desarrollo de un Clasificador de Normalidad Cardíaca Basado en las Técnicas de Monitorización Ambulatoria de Electrocardiografía y Presión Arterial a Partir de Señales ECG", conducido por Santiago Erazo, estudiante de la Universidad Antonio Nariño, reconociendo que este proyecto es parte de sus estudios académicos y no tiene una finalidad comercial, otorgo mi consentimiento para participar en el mismo.

Descripción del Proyecto: Este proyecto tiene como objetivo desarrollar un sistema de clasificación de la normalidad de la dinámica cardíaca. Para ello, se utilizarán señales cardíacas ECG mediante la combinación de las técnicas de holter cardíaco y monitorización ambulatoria de presión arterial (MAPA). El propósito principal es mejorar la capacidad de clasificar el riesgo cardiovascular al incorporar información sobre la presión arterial, dada su relevancia en relación con las enfermedades cardíacas y su contribución a una mejor comprensión de la salud cardíaca general. Este proyecto ha sido avalado por el Comité de Trabajos Integrales de Grado (COTIGE) de la Facultad de Ingeniería Mecánica, Electrónica y Biomédica (FIMEB).

Su Participación: Entiendo que mi participación en este proyecto es completamente voluntaria y que no recibiré ninguna recompensa material o económica por ello. Tengo la libertad de no participar o de retirarme en cualquier momento sin necesidad de proporcionar explicaciones, y esto no tendrá ningún impacto en mis cuidados médicos.

Datos Personales: Estoy al tanto de que mis datos personales serán tratados de acuerdo con el Reglamento General de Protección de Datos (RGPD) y se incorporarán en un fichero que cumple con todas las garantías de privacidad.

Consentimiento: Por lo tanto, otorgo mi consentimiento para participar en este proyecto y permitir la toma de señales electrocardiográficas y mediciones de la presión arterial antes

y después de realizar trabajo físico con el objetivo de elevar la presión arterial.

- Nombre

- Cédula

- Correo

- Código estudiantil

Manifiesto que he leído y comprendido la información proporcionada en esta hoja de consentimiento y que he tenido la oportunidad de hacer todas las preguntas necesarias sobre el proyecto. Acepto libremente participar en esta investigación.

B Apéndice 1