



DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OPCIÓN 1.- TESIS

TRABAJO PROFESIONAL

**“MONITORIZACIÓN DE FLUJO SANGUÍNEO PARA IDENTIFICAR
RIESGO CARDIOVASCULAR UTILIZANDO SEÑALES
FOTOPLETISMOGRÁFICAS Y APRENDIZAJE AUTOMÁTICO”**

**QUE PARA OBTENER EL GRADO DE:
DOCTOR EN CIENCIAS
DE LA INGENIERÍA**

PRESENTA:


M.I.E. MARCO ANTONIO ARROYO RAMÍREZ

DIRECTOR DE TESIS:

Dr. JOSÉ DE JESÚS AGUSTÍN FLORES CUAUTLE

CODIRECTOR DE TESIS:

Dr. JOSÉ LUIS SÁNCHEZ CERVANTES



ORIZABA, VERACRUZ, MÉXICO

Febrero 2026



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
Departamento de División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, 05/02/2026
Dependencia: **División de Estudios de
Posgrado e Investigación**
Asunto: **Autorización de Impresión**
OPCION: I

C. MARCO ANTONIO ARROYO RAMÍREZ

Candidato a Grado de Doctor en:

CIENCIAS DE LA INGENIERÍA

P R E S E N T E.-


De acuerdo con el Reglamento de Titulación vigente de los Centros e Institutos Tecnológicos Federales del Tecnológico Nacional de México, de la Secretaría de Educación Pública y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:

"MONITORIZACIÓN DE FLUJO SANGUÍNEO PARA IDENTIFICAR RIESGO CARDIOVASCULAR UTILIZANDO SEÑALES FOTOPLETIsmoGRÁFICAS Y APRENDIZAJE AUTOMÁTICO"

Comunico a Usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

ATENTAMENTE
Excelencia en Educación Tecnológica®
CIENCIA - TÉCNICA - CULTURA®

DR. OSCAR BÁEZ SENTÍES
**JEFE DE LA DIVISIÓN DE ESTUDIOS DE
POSGRADO E INVESTIGACIÓN**



2026
año de
**Margarita
Maza**

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320 Orizaba, Veracruz
Tel. 01 (272) 1105360 info@orizaba.tecnm.mx www.orizaba.tecnm.mx





Instituto Tecnológico de Orizaba
Departamento de División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, **22/enero/2026**
Asunto: **Revisión de trabajo escrito**

C. ÓSCAR BÁEZ SENTÍES
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
P R E S E N T E.-

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.

MARCO ANTONIO ARROYO RAMÍREZ

La cual lleva el título de:

"MONITORIZACIÓN DE FLUJO SANGUÍNEO PARA IDENTIFICAR RIESGO CARDIOVASCULAR UTILIZANDO SEÑALES FOTOPLETISMOGRÁFICAS Y APRENDIZAJE AUTOMÁTICO"

Y concluyen que se acepta.

ATENTAMENTE
Excelencia en Educación Tecnológica®
CIENCIA-TÉCNICA-CULTURA®

PRESIDENTE: DR. JOSÉ DE JESÚS AGUSTÍN FLORES CUAUTLE


FIRMA

SECRETARIO: DR. JOSÉ LUIS SÁNCHEZ CERVANTES


FIRMA

VOCAL: DR. ÓSCAR OSVALDO SANDOVAL GONZÁLEZ


FIRMA


VOCAL: DR. JOSE PASTOR RODRIGUEZ JARQUIN


FIRMA

VOCAL : DR. GUILLERMO CORTÉS ROBLES


FIRMA

VOCAL SUPLENTE: DR. RUBÉN POSADA GÓMEZ


FIRMA



2026
año de
Margarita
Maza



AGRADECIMIENTOS

Al Tecnológico Nacional de México / Instituto Tecnológico de Orizaba, por brindarme la oportunidad de realizar mis estudios de Doctorado en sus instalaciones.

A mis sinodales, Dr. José Luis Sánchez Cervantes, Dr. Guillermo Cortés Robles, Dr. Rubén Posada Gómez, Dr. José Pastor Rodríguez Jarquin, Dr. Óscar Osvaldo Sandoval González y Dr. José de Jesús Agustín Flores Cuautle, por su valiosa guía y conocimientos compartidos para la culminación de este proyecto de investigación.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT), por la beca otorgada para la realización de mis estudios de Doctorado.

A mis padres y familia por su apoyo incondicional a lo largo de mis estudios de Doctorado.

A mis amigos y compañeros, por los momentos compartidos y el apoyo mutuo.

A todos ellos, ¡Muchas gracias!

CONTENIDO

RESUMEN	9
ABSTRACT	10
INTRODUCCIÓN.....	11
JUSTIFICACIÓN.....	13
HIPÓTESIS	13
OBJETIVOS.....	13
OBJETIVO GENERAL.....	13
OBJETIVOS ESPECÍFICOS.....	13
CONTRIBUCIÓN AL CONOCIMIENTO.....	14
CAPITULO 1. ANTECEDENTES	15
1.1 Circulación de la Sangre.....	15
1.2 Presión Sanguínea.	19
1.2.1 Flujo Laminar	25
1.3 Control del flujo Sanguíneo.....	27
1.4 Energía del flujo Sanguíneo.	28
1.5 Turbulencia en la Sangre.	29
1.6 La Arteriosclerosis y el flujo Sanguíneo.	30
1.7 La energía producida por el corazón.	31
1.8 Medición de la presión arterial.	32
1.9 Antecedentes de Inteligencia Artificial	40
CAPÍTULO 2. ESTADO DEL ARTE	42
2.1 Artículos Científicos que utilizan Redes Neuronales Artificiales.....	42
2.2 Artículos Científicos que utilizan Algoritmos de Clasificación.....	58

2.3	Redes Neuronales Artificiales con Algoritmos de Clasificación.	66
CAPÍTULO 3. METODOLOGÍA.....		75
3.1	Etapas de la Metodología de Investigación	75
3.2	Etapa de Análisis	77
3.3	Etapa de Diseño	92
3.4	Etapa de Implementación	95
3.5	Etapa de Pruebas.....	107
CAPÍTULO 4. RESULTADOS Y DISCUSIÓN		136
4.1	Resultados.....	136
4.1.1	Sujeto saludable (S2).....	139
4.1.2	Sujeto Diabético (S4)	143
4.1.3	Sujeto Hipertenso y Diabético (S14).....	146
4.2	Discusión	149
CONCLUSIONES Y TRABAJO FUTURO		150
REFERENCIAS BIBLIOGRÁFICAS		152
PRODUCTOS ACADÉMICOS.....		161
ANEXOS		162

ÍNDICE DE FIGURAS

Figura 1.1 Sistema Circulatorio, adaptada de (Davidovits, 2019).....	17
Figura 1.2 Ciclo Cardíaco, adaptada de (Augusto, 2018).	18
Figura 1.3 Corte histológico de un pedículo vascular, adaptada de (Augusto, 2018).	20
Figura 1.4 Onda de la presión arterial y sus características, adaptada de (Augusto, 2018).	21
Figura 1.5 Componentes de la forma de onda de la presión arterial, adaptada de (Augusto,2018).	22
Figura 1.6 Flujo Laminar, adaptada de (Davidovits, 2019).	24
Figura 1.7 Método Auscultatorio, adaptada de (Augusto, 2018).	35
Figura 1.8 Tonometría aplanatoria, adaptada de (Augusto, 2018).	36
Figura 1.9 Medición del tiempo de tránsito de pulso, adaptada de (Peter et al., 2014).....	39
Figura 3.1 Metodología de la Investigación.	75
Figura 3.2 Método fotopleletismográfico.....	80
Figura 3.3 Tarjeta de adquisición de señales ECG y PPG Max 86150.	81
Figura 3.4 Fases anacrótica y catacrótica de la señal PPG.....	81
Figura 3.5 Características de la señal PPG con sus derivadas.....	82
Figura 3.6 Intervalo de pulso de la señal PPG.....	83
Figura 3.7 Características de la primera derivada de la señal PPG.	85
Figura 3.8 Características de la segunda derivada de la señal PPG.	87
Figura 3.9 Correlación de Enfermedades Cardiovasculares.....	89
Figura 3.10 Detección de ECV's con tecnologías ECG y PPG.	91
Figura 3.11 Fases de proceso del modelo de aprendizaje automático.....	93
Figura 3.12 Fases 5, 6 y 7 del modelo de aprendizaje automático.	94
Figura 3.13 Arquitectura del modelo de Machine Learning para la predicción de hipertensión y arteriosclerosis.	94
Figura 3.14 Diagrama de la metodología para la evaluación de la salud cardiovascular 1/3.	96
Figura 3.15 Diagrama de la metodología para la evaluación de la salud cardiovascular 2/3.	97
Figura 3.16 Diagrama de la metodología para la evaluación de la salud cardiovascular 3/3.	97

Figura 3.17 Modelo de trabajo de aprendizaje automático.	98
Figura 3.18 Fase 1 definir objetivo, Fase 2 recolectar datos.	98
Figura 3.19 Fase 3 procesar datos, Fase 4 crear modelo.	98
Figura 3.20 Fase 5 entrenar el modelo, Fase 6 evaluar el modelo.	99
Figura 3.21 Fase 7 realizar la predicción, Fase 8 controlar los resultados.	99
Figura 3.22 Diagrama de la metodología para la evaluación de la salud cardiovascular 1/3.	100
Figura 3.23 Diagrama de la metodología para la evaluación de la salud cardiovascular 2/3.	101
Figura 3.24 Diagrama de la metodología para la evaluación de la salud cardiovascular 3/3.	101
Figura 3.25 Diagrama de flujo del código para el procesamiento y extracción de características de la señal PPG 1/4.	108
Figura 3.26 Diagrama de flujo del código para el procesamiento y extracción de características de la señal PPG 2/4.	109
Figura 3.27 Gráfica de la señal PPG.	111
Figura 3.28 Diagrama de flujo del código para el procesamiento y extracción de características de la señal PPG 3/4.	112
Figura 3.29 Diagrama de flujo del código para el procesamiento y extracción de características de la señal PPG 4/4.	113
Figura 3.30 Características de la señal PPG procesada, en el dominio del tiempo.	114
Figura 3.31 Características de la señal PPG procesada, en el dominio de la frecuencia....	115
Figura 3.32 Características estadísticas de la señal PPG procesada.	115
Figura 3.33 Características de la primera derivada de la señal PPG procesada, en el dominio del tiempo.	116
Figura 3.34 Características de la segunda derivada de la señal PPG procesada, en el dominio del tiempo.	116
Figura 3.35 4 datos utilizados de cada Dominio.	118
Figura 3.36 Gráficas de la presión arterial con el algoritmo Bagging SVR polinomial....	119
Figura 3.37 6 datos utilizados de cada Dominio.	120
Figura 3.38 Datos contenidos en el Dataset PPG-BP.	121

Figura 3.39 Datos utilizados después de preprocesar el Dataset PPG-BP.	121
Figura 3.40 Correlación de las señales ECG y PPG.....	123
Figura 3.41 Datos para detección de hipertensión normal y baja.....	128
Figura 3.42 Predicciones normal y baja.	129
Figura 3.43 Datos para detección de hipertensión media y alta	129
Figura 3.44 Predicciones media y alta.....	131
Figura 3.45 Datos para detección de arteriosclerosis normal y baja	131
Figura 3.46 Predicciones normal y baja	133
Figura 3.47 Datos para detección de arteriosclerosis media y alta.....	133
Figura 3.48 Predicciones media y alta.....	134
Figura 4.1 participantes para el estudio con pacientes de la Fundación Doctor Hernández Zurita.	136
Figura 4.2 Señal PPG S2	139
Figura 4.3 Señal S2 invertida	140
Figura 4.4 Gráfica de la presión arterial del sujeto S2	141
Figura 4.5 Señal S4 invertida	143
Figura 4.6 Gráfica de la presión arterial del sujeto S4	144
Figura 4.7 Señal S14 invertida	146
Figura 4.8 Gráfica de la presión arterial del sujeto S14	147

ÍNDICE DE TABLAS

Tabla 2.1 Análisis comparativo de los trabajos que utilizan redes neuronales artificiales. 1/2	57
Tabla 2.2 Análisis comparativo de los trabajos que utilizan redes neuronales artificiales. 2/2	58
Tabla 2.3 Análisis comparativo de los trabajos que utilizan algoritmos de clasificación. ...	66
Tabla 2.4 Análisis comparativo de los trabajos que utilizan algoritmos de clasificación en combinación con redes neuronales.	73
Tabla 3.1 Equipos o análisis para Enfermedades Cardiovasculares.....	89
Tabla 3.2 Factores de Riesgo.....	90
Tabla 3.3 Equipos para Medición de Señales ECG.....	90
Tabla 3.4 Equipos para Medición de Señales PPG	91
Tabla 3.5 Biomarcadores de posibles enfermedades cardiovasculares a detectar.....	92
Tabla 3.6 Análisis Comparativo Métodos Clásicos contra Métodos Ensamblados	107
Tabla 3.7 Características PPG	117
Tabla 3.8 Prueba 4 datos.....	118
Tabla 3.9 Prueba 6 datos.....	120
Tabla 3.10 Prueba PPG dataset	122
Tabla 3.11 Prueba 4 datos.....	123
Tabla 3.12 Prueba 6 datos.....	124
Tabla 3.13 Prueba PPG dataset	124
Tabla 3.14 Prueba 4 datos CV	125
Tabla 3.15 Prueba 6 datos CV	126
Tabla 3.16 Prueba PPG dataset CV	127
Tabla 3.17 Prueba 4 datos.....	128
Tabla 3.18 Prueba 4 datos.....	130
Tabla 3.19 Prueba 4 datos.....	132
Tabla 3.20 Prueba 4 datos.....	134
Tabla 4.1 Validación Sujeto S2 (SANO) PA	141
Tabla 4.2 S2 HTA.....	142
Tabla 4.3 S2 AS1.....	143

Tabla 4.4 Validación Sujeto S4 (DIABÉTICO) PA.....	144
Tabla 4.5 S4 HTA1.....	145
Tabla 4.6 S4 AS1.....	145
Tabla 4.7 Validación Sujeto S14 (HIPERTENSO Y DIABÉTICO) PA	147
Tabla 4.8 S14 HTA2.....	148
Tabla 4.9 S14 AS2.....	148
Tabla 4.10 Intervalo de confianza de la presión arterial.....	149

RESUMEN

De acuerdo con la Organización Mundial de la Salud (OMS) a nivel mundial, menos de la mitad de los adultos con hipertensión son diagnosticados y tratados (solo el 42 %), además, uno de cada cinco adultos con hipertensión (21 %) tiene la afección bajo control. En el continente americano, las enfermedades cardiovasculares (ECV) son la principal causa de muerte y la presión arterial alta (hipertensión) es responsable del 50 % de las muertes por ECV. Solo unos pocos países muestran una tasa de control de la hipertensión en la población superior al 50 % (*Día Mundial de la Hipertensión 2024 - OPS/OMS | Organización Panamericana de la Salud, s/f*), (*Cardiovascular Diseases (CVDs), s/f*).

Por lo tanto, el monitoreo continuo de la presión arterial es una herramienta para el seguimiento de la atención domiciliaria, las reacciones del sistema cardiovascular en presencia de algunos fármacos, la detección temprana de posibles enfermedades como la diabetes o la hipertensión arterial y ayudar al médico a programar el tratamiento adecuado. Por esta razón, surge la necesidad de desarrollar una metodología que permita evaluar el estado y características del sistema arterial, y obtener una medición confiable a través de las yemas de los dedos utilizando un método no invasivo, para detectar de manera temprana el desarrollo de una enfermedad cardiovascular.

El buen estado de salud del corazón y del sistema arterial es de vital importancia para el correcto funcionamiento del cuerpo humano, las condiciones anormales del sistema arterial son la causa de numerosas patologías por lo que es necesario un monitoreo constante. Al presentarse condiciones anormales en el sistema arterial, es frecuente que el paciente sea trasladado a un hospital donde se cuenta con el equipo necesario para una evaluación médica, lo que implica un retraso en el tiempo de atención, así mismo se hace necesaria la intervención de un médico especialista. Sin embargo, los tiempos de espera para recibir un tratamiento adecuado, se evitarían con el apoyo de nuevos métodos no invasivos capaces de monitorear el estado de la presión sanguínea en forma constante.

En el primer capítulo se presentan los conceptos relacionados con el funcionamiento del sistema arterial, sus valores óptimos y los diferentes métodos que son utilizados para realizar la medición y monitorización de la presión arterial.

El segundo capítulo presenta un análisis comparativo de los trabajos de investigación que ya existen y que son similares a este tema de investigación.

En el tercer capítulo se presenta la metodología de investigación utilizada para el desarrollo de esta tesis doctoral.

Finalmente en el cuarto capítulo se presentan los resultados obtenidos del desarrollo de este proyecto de investigación y sus respectivas discusiones.

Palabras Clave: Presión arterial, Fotopletismografía, Aprendizaje Automático.

ABSTRACT

According to the World Health Organization (WHO), globally less than half of adults with hypertension are diagnosed and treated Globally, less than half of adults with hypertension are diagnosed and treated (only 42%), and only one in five adults with hypertension (21%) have the condition under control. In the Americas, cardiovascular disease (CVD) is the leading cause of death, and high blood pressure (hypertension) accounts for 50% of CVD deaths. Only a few countries have a hypertension control rate in the population above 50% (*Día Mundial de la Hipertensión 2024 - OPS/OMS | Organización Panamericana de la Salud, s/f*), (*Cardiovascular Diseases (CVDs), s/f*).

Therefore, the continuous monitoring of blood pressure is a tool for monitoring home care, the reactions of the cardiovascular system in the presence of some drugs, early detection of possible diseases such as diabetes or hypertension, and helping the physician program the appropriate treatment. For this reason, the need arises to develop a methodology to evaluate the state and characteristics of the arterial system and obtain a reliable measurement through the fingertips using a non-invasive method to detect early the development of cardiovascular disease.

The excellent health of the heart and the arterial system is of vital importance for the proper functioning of the human body; abnormal conditions of the arterial system are the cause of

numerous pathologies; therefore, constant monitoring is necessary. When abnormal conditions in the arterial system occur, it is common for the patient to be transferred to a hospital where the necessary equipment is available for a medical evaluation, which implies a delay in the time of attention and the intervention of a medical specialist is necessary. However, waiting times to receive adequate treatment could be prevented with the support of new non-invasive methods capable of constantly monitoring the state of blood pressure.

The first chapter presents the concepts related to the functioning of the arterial system, its optimal values, and the different methods used to measure and monitor blood pressure.

The second chapter presents a comparative analysis of existing research works that are similar to this research topic.

The third chapter presents the research methodology used for the development of this doctoral thesis.

Finally, the fourth chapter presents the results obtained from the development of this research project and the respective discussions.

Keywords: Blood pressure, Photoplethysmography, Machine Learning.

INTRODUCCIÓN

El sistema arterial al transportar la sangre que proviene del corazón, por medio de una red compleja de ramificaciones elásticas genera un flujo de sangre que bajo ciertas condiciones se considera un flujo atenuado y constante (Gunther et al., 2006).

La sangre es expulsada a través de las contracciones del corazón, la fuerza aplicada sobre la sangre debida a dichas contracciones produce una onda de presión que recorre los vasos que se encuentran alrededor del corazón. Esta onda de presión recorre el sistema arterial y su flujo está relacionado con las características de las arterias como el grosor de la pared arterial, la elasticidad o la rigidez. La presión sanguínea es un excelente indicador del estado de salud

del sistema cardiovascular debido a su relación con las características de las arterias (Peter et al., 2014).

La presión sistólica y diastólica son los valores extremos de la presión arterial que varían habitualmente entre 40 y 180 veces por minuto. El punto de mayor contracción ventricular se llama presión sistólica y es la presión máxima que ejerce la sangre, por otra parte, la presión mínima durante la relajación ventricular se llama presión diastólica. Una mala distribución de nutrientes y oxígeno indicarían una mala perfusión de la sangre en los vasos más pequeños debido a que el valor de la presión sistólica está por debajo de 90 mmHg. Por el contrario, si la presión sistólica es mayor a 140 mmHg existirían daños en órganos como el hígado, el riñón, el cerebro o el corazón debido a un alto riesgo de rotura de los vasos ya que la circulación de la sangre es muy importante en dichos órganos.

El seguimiento de la atención domiciliaria, los efectos de algunos fármacos en el sistema cardiovascular, la detección temprana de enfermedades como la diabetes o la hipertensión son razones por las cuales el monitoreo continuo de la presión arterial es una herramienta importante que ayuda a los médicos a planificar el tratamiento adecuado. Por esta razón, surge la necesidad de desarrollar una metodología que permita evaluar el estado y características del sistema arterial, y obtener una medición confiable a través de las yemas de los dedos utilizando un método no invasivo, para detectar de manera temprana el desarrollo de una enfermedad cardiovascular.

PLANTEAMIENTO DEL PROBLEMA

El buen estado de salud del sistema arterial es de vital importancia para el transporte del flujo sanguíneo a las diferentes partes del cuerpo humano y su correcto funcionamiento, si el sistema arterial no se encuentra en óptimas condiciones de salud se presentan diversos padecimientos por lo que es necesario un monitoreo constante. Al presentarse anomalías en el sistema arterial, es necesario que el paciente reciba atención médica inmediata, esto implica un retraso en el tiempo de atención y la intervención de un médico especialista. Sin embargo, los tiempos de espera para recibir un tratamiento adecuado, se evitarían con el

apoyo de nuevos métodos no invasivos capaces de monitorear el estado de salud de la presión sanguínea en forma constante, para detectar anomalías en el sistema arterial.

JUSTIFICACIÓN

Contar con información más precisa sobre el estado de salud y características del sistema arterial mediante un método no invasivo, ayudaría a los profesionales de la salud en la detección temprana de padecimientos cardiovasculares o en su defecto ayudaría a agilizar el proceso de recepción de ayuda médica.

HIPÓTESIS

Es posible utilizar la pletismografía en conjunto con técnicas de aprendizaje automático para obtener información más precisa sobre la presión arterial, que permita a los profesionales de la salud inferir cambios en dicha variable fisiológica.

OBJETIVOS

OBJETIVO GENERAL

Obtener información más precisa sobre el estado de salud y características del sistema arterial por medio de técnicas de pletismografía y algoritmos de aprendizaje automático para la detección temprana de padecimientos cardiovasculares.

OBJETIVOS ESPECÍFICOS

- Analizar la literatura sobre las diferentes técnicas de medición de la presión arterial utilizando métodos no invasivos para estar al tanto de las técnicas más actuales.
- Analizar las características de la señal fotopletismográfica (PPG) para obtener información más precisa sobre el sistema arterial, a través de métodos no invasivos.

- Analizar los algoritmos de aprendizaje automático, viables para la solución del problema.
- Diseñar experimentos para la comprobación de la hipótesis, por medio de modelos matemáticos, sistemas electrónicos, ejecución de códigos en algún lenguaje de programación, etc.
- Diseñar las fases de proceso del modelo de aprendizaje automático para implementar la estimación de la presión arterial y la detección de una enfermedad cardiovascular.
- Implementar la metodología para el procesamiento de la señal PPG, la estimación de la presión arterial y la detección de alguna enfermedad cardiovascular.
- Implementar los algoritmos de aprendizaje automático, capaces de realizar el procesamiento de la señal PPG, la estimación de la presión arterial con la mayor precisión posible y realizar la detección de alguna enfermedad cardiovascular.
- Evaluar y validar los resultados obtenidos de los algoritmos de aprendizaje automático con ayuda de expertos en el área de la salud, a través de por lo menos un caso de estudio.

CONTRIBUCIÓN AL CONOCIMIENTO

Una metodología como la propuesta permitiría obtener información más precisa sobre las variaciones de presión y volumen en el sistema arterial a partir de la morfología de la señal fotopletomográfica y así poder realizar una estimación más precisa de la presión arterial, ya que las tecnologías actuales requieren todavía de una mayor precisión de estimación, por lo cual se espera que con este trabajo de investigación se desarrolle una metodología que ayude a los profesionales de la salud a realizar un diagnóstico más preciso del sistema arterial por medio de un método no invasivo y al mismo tiempo mejorar la atención médica.

CAPITULO 1. ANTECEDENTES

En este capítulo se presentan los conceptos relacionados con el funcionamiento del sistema arterial, sus valores óptimos y los diferentes métodos que son utilizados para realizar la medición y monitoreo de la presión arterial.

1.1 Circulación de la Sangre.

El sistema vascular está organizado por arterias, arteriolas, capilares, vénulas y venas que presentan diferentes formas, funciones y superficies, dando paso a la circulación sanguínea (Augusto, 2018).

La sangre se reparte de distinta forma en las diferentes estructuras vasculares debido a que sus superficies son diferentes, del mismo modo el volumen de sangre contenido en dichas estructuras varia. En consecuencia, solo el 20 % de la sangre se reparte en arterias, arteriolas y capilares mientras que el 64 % se reparte en venas, vénulas y senos venosos.

El estudio de los fluidos en movimiento tiene una relación directa con la biología y la medicina. Uno de los investigadores interesados en este campo fue un médico francés llamado L. M. Poiseuille (1799-1869), cuyo interés en el flujo de la sangre a través del cuerpo humano motivó su estudio sobre los fluidos en movimiento (Davidovits, 2019).

Usualmente la circulación de la sangre a través del cuerpo humano es comparada con una red de tuberías, tomando a las venas, arterias y capilares como los tubos por los que fluye la sangre y al corazón como si fuera una bomba. La comparación de la circulación de la sangre con una red de tuberías no es completamente correcta debido que la sangre tiene células que cambian el flujo sanguíneo, en particular cuando las paredes de las arterias se reducen, estas características son las que la hacen diferente de un simple fluido. Por otra parte, las venas y las arterias son conductos elásticos y las fuerzas aplicadas por el fluido sobre dichos conductos cambian su forma. Sin embargo, se utilizan los métodos empleados en el análisis de fluidos simples que viajan a través de tubos rígidos para hacer un análisis del sistema circulatorio con cierta precisión. Normalmente se ha planteado que la sangre humana es un

fluido newtoniano, debido a que su viscosidad no depende del trabajo que realizan este tipo de fluidos (Moreno et al., 2013).

Un fluido es newtoniano si su capacidad para oponerse a un flujo es alterada únicamente por las variaciones de temperatura o presión y que toma la forma del medio que lo contiene (*Fluido Newtoniano | Oilfield Glossary*, n.d.).

La viscosidad de un fluido newtoniano se describe como la relación entre la fuerza aplicada por la pared de las arterias sobre la superficie del fluido que se opone al flujo y la velocidad aplicada al fluido para moverlo, siempre y cuando no haya cambios en la temperatura y presión de dicho fluido. Sin embargo, la sangre contiene células que flotan en un ambiente líquido conocido como plasma y para que se pudiera considerar como un fluido newtoniano se tendría que disolver. La sangre es bombeada por el corazón a través del sistema circulatorio transportando oxígeno y nutrientes entre otras sustancias esenciales para las células, pero también se encarga de la eliminación de desechos de dichas células, de esta forma la sangre entra y sale del corazón a través de las arterias y las venas.

Cabe mencionar que una arteria es un vaso sanguíneo que se encarga de distribuir la sangre oxigenada desde el corazón hacia los capilares del cuerpo, tiene paredes que son muy gruesas y elásticas de esta manera recuperan rápidamente su forma original al ser deformadas y están formadas por tres capas, interna, media y externa. Son capaces de mantener la presión arterial en su luz, que es el orificio por donde viaja la sangre, entre más lejos se encuentran las arterias del corazón, su pared va perdiendo grosor por disminución del número de fibras elásticas.

Por otra parte, una vena es un vaso sanguíneo cuya función es regresar la sangre desoxigenada desde los capilares hacia el corazón para ser oxigenada nuevamente en el pulmón. Para facilitar el regreso de la sangre venosa contra la fuerza de gravedad, dentro de las venas hay un mecanismo valvular que empuja el flujo hacia arriba, dificultando el flujo en sentido contrario, en las extremidades inferiores hay dos sistemas venosos, el superficial y el profundo, unidos por las venas conocidas como perforantes o comunicantes. Las venas del sistema superficial tienen paredes más finas y distensibles, por otra parte, las venas del sistema profundo reciben el 90% de la sangre venosa de los miembros inferiores y tienen paredes más gruesas con menor capacidad de distensión.

La sangre de todo el sistema circulatorio sin tomar en cuenta la de los pulmones entra a una cámara del corazón conocida como aurícula derecha para después empujarla hacia otra cámara conocida como ventrículo derecho que a su vez empuja la sangre hacia los pulmones por medio de la arteria pulmonar. Cuando la sangre llega a los pulmones libera dióxido de carbono y absorbe oxígeno para después viajar hacia la aurícula izquierda por medio de la vena pulmonar. La sangre es empujada por la aurícula izquierda hacia el ventrículo izquierdo que a su vez empuja la sangre rica en oxígeno por medio de la arteria aorta hacia las arterias que transportan la sangre por todo el sistema circulatorio menos los pulmones. De esta manera el lado derecho del corazón bombea la sangre a través de los pulmones y el lado izquierdo la bombea al resto del cuerpo, tal como se muestra en la Figura 1-1.




Figura 1.1 Sistema Circulatorio, adaptada de (Davidovits, 2019).

La arteria aorta lleva la sangre oxigenada que proviene del ventrículo izquierdo por todo el sistema circulatorio hasta llegar a las arterias más pequeñas llamadas arteriolas.

Las arteriolas ayudan a regular el flujo sanguíneo en ciertas partes del cuerpo, pero también se dividen en capilares tan angostos que apenas si tienen el tamaño suficiente para dejar pasar una célula sanguínea.

El intercambio de gases, nutrientes y desechos entre la sangre y tejido se realiza por difusión por medio de las paredes de los capilares, dichos capilares son tan abundantes que prácticamente todas las células del cuerpo están cerca de un capilar.

Por otra parte, los capilares se unen con venas pequeñas llamadas vénulas que a su vez se unen con venas más grandes que transportan la sangre desoxigenada de regreso a la aurícula derecha.

Un ciclo cardiaco está formado por un periodo de contracción (sístole) seguido de un periodo de relajación (diástole), la duración del ciclo cardiaco se calcula como el recíproco de la frecuencia cardiaca (Augusto, 2018).

Por ejemplo, si la frecuencia cardiaca es de 72 latidos por minuto, esto quiere decir que hay 72 latidos cada 60 segundos, por lo tanto cada segundo hay 1.2 latidos, esto significa que cada latido dura 0.83 segundos.

Cuando el ventrículo izquierdo se encuentra relajado se inicia el periodo sistólico con una contracción que no presenta variación de volumen, sin embargo, la presión dentro del ventrículo se encuentra por debajo de la presión de la aorta por lo que la válvula de dicha arteria permanece cerrada.

Cuando la presión del ventrículo se encuentra al mismo nivel que la presión de la aorta la válvula se abre y se inicia el periodo de eyección, al terminar dicho periodo el volumen de sangre del ventrículo llega a su valor mínimo conocido como volumen telesistólico, luego entonces la válvula de la aorta se cierra e inicia el periodo de relajación sin cambios de volumen. Finalmente, al bajar la presión de la aurícula, la presión del ventrículo desciende debido a su periodo de relajación e inicia el periodo de llenado en el ventrículo debido a la apertura de la válvula mitral, tal como se muestra en la Figura 1-2.




Figura 1.2 Ciclo Cardíaco, adaptada de (Augusto, 2018).

1.2 Presión Sanguínea.

Debido a que el promedio del flujo sanguíneo es igual en todo el sistema vascular, la relación del volumen de sangre a través de las arterias es mayor que en las venas y entonces las presiones que se presentan en las arterias grandes son de 80 a 120 mmHg y en las vénulas de 5 a 10 mmHg.

Existen diferencias de volumen, forma y funciones en las distintas partes del sistema vascular. La distensibilidad vascular es la causa de dichas diferencias la cual se describe como el aumento de volumen por cada mmHg en la presión, tal como se muestra en la Ecuación 1-1.

$$\text{Distensibilidad vascular} = \frac{\text{Aumento del volumen}}{(\text{Aumento de presión})(\text{Volumen original})}$$

Ecuación 1-1. Distensibilidad Vascular (Augusto, 2018).

Las venas se dilatan hasta ocho veces más que las arterias porque las arterias tienen paredes más gruesas. Por lo tanto, el cambio de volumen en la circulación venosa debido a un aumento de la presión es menor que el aumento de presión en la circulación arterial.

Como la circulación venosa tiene variaciones de presión menores y sus volúmenes son mayores en comparación con la circulación arterial, entonces los cambios de volumen de la red venosa debido a las contracciones cardíacas son insignificantes en comparación con las de la red arterial.

Las paredes de los vasos sanguíneos están formadas por tres capas conocidas como tunicas, la capa interna formada por el endotelio, la membrana basal y el subendotelio es conocida como túnica íntima.

La túnica media está formada por capas circulares de fibras musculares separadas por elastina, fibras reticulares y proteoglucanos, y la capa externa formada por el tejido conectivo que contiene colágeno repartido longitudinalmente, es conocida como túnica adventicia.

Entre las venas y las arterias la diferencia más importante es que las venas transportan la sangre desoxigenada y las arterias transportan la sangre oxigenada, además, del espesor y la capacidad de contraerse de la túnica media. Dicha túnica es más gruesa en las arterias mientras que en las venas la túnica más importante es la adventicia ya que les ofrece mayor elasticidad.

En la túnica media el grado de contracción cambia el tamaño del vaso y se ajusta de manera organizada, por lo tanto, ajusta la resistencia y el flujo sanguíneo en esa zona.

La túnica media es una capa muy gruesa en las arteriolas, esto hace que la estructura del sistema vascular sea resistente debido a las condiciones de contracción de las arteriolas. Por esta razón las arteriolas son conocidas comúnmente como los vasos fuertes del organismo.

El nivel de contracción de la túnica media es regulado en forma organizada, por lo tanto, el flujo sanguíneo se incrementa o disminuye a través del organismo dependiendo de las necesidades de los diferentes tejidos, tal como se ve en la Figura 1-3.

Debido a que las arteriolas son las estructuras fuertes del sistema vascular, forman una pared con la que chocan las ondas mecánicas de la presión arterial provocando variaciones que son propias de la onda de presión.




Figura 1.3 Corte histológico de un pedículo vascular, adaptada de (Augusto, 2018).

La contracción de los ventrículos es provocada por impulsos eléctricos que son aplicados a los lados izquierdo y derecho del corazón al mismo tiempo.

Inicialmente las aurículas transportan la sangre a los ventrículos, después los ventrículos transportan la sangre fuera del corazón. El bombeo del corazón hace que la sangre viaje a través de las arterias en forma de chorros o pulsos.

La presión sanguínea se define como la fuerza aplicada por unidad de área que la sangre aplica sobre las paredes de las arterias en un momento determinado.

Como se mencionó anteriormente el valor máximo de la presión arterial presente en un pulso cardiaco es conocido como presión sistólica y el valor mínimo de la presión arterial es conocido como presión diastólica.

En condiciones normales la presión sistólica es de 120 mmHg mientras que la diastólica es de 80 mmHg y se expresa como 120/80. Por lo tanto, la presión arterial media es de 100 mmHg.

Es importante tomar en cuenta que estos valores varían en todo el sistema cardiovascular, en el ventrículo izquierdo los valores de la presión son entre 5 mmHg y 150 mmHg, hay que tomar en cuenta que en condiciones normales la presión diastólica en las arterias más grandes no baja de 60 mmHg. En la Figura 1-4 se muestra una gráfica de la forma de onda de la presión arterial.




Figura 1.4 Onda de la presión arterial y sus características, adaptada de (Augusto, 2018).


La presión sanguínea es de naturaleza pulsátil y se genera con la contracción del ventrículo izquierdo. La onda de presión comienza después de que se presenta la onda R del electrocardiograma que es generada por la disminución del potencial de las fibras musculares del ventrículo izquierdo.

La disminución del potencial de las fibras musculares, la contracción del ventrículo, la activación de la válvula aórtica y la eyección de la presión sistólica se presentan entre la onda R y la onda de la presión arterial.

La onda de presión tiene una parte rápida de 10 m/seg y una lenta de 0.5 m/seg, por lo tanto, no se propaga inmediatamente a todo el sistema vascular, si no que tiene un retraso que depende de la distancia completa desde el punto medido hasta el ventrículo izquierdo.

Todas las partes de la presión sanguínea forman el segmento arteriolar y constituyen la forma de onda de la presión arterial. En consecuencia, para cada sección del sistema arterial la forma de onda de la presión es diferente y no solo cambia su amplitud sino también su morfología.

En la Figura 1-5 se observan dichas partes de la presión arterial que son: Frente sistólico (1), presión sistólica máxima (2), caída sistólica (3), muesca dicrótica (4), pendiente diastólica (5), presión diastólica final (6) y la onda R del electrocardiograma (R), donde se observa una forma de onda normal a nivel cardiaco.



Frente sistólico (1), presión sistólica máxima (2), caída sistólica (3), muesca dicrótica (4), pendiente diastólica (5), presión diastólica final (6) y la onda R del electrocardiograma (R).

Figura 1.5 Componentes de la forma de onda de la presión arterial, adaptada de (Augusto,2018).

El frente sistólico (1) indica el ascenso súbito de la presión arterial; La presión sistólica máxima (2) es el nivel máximo de volumen de sangre eyectada, antes de que la válvula aortica se abra, dicha eyección de sangre tiende a mantener la presión sistólica cuando la válvula aortica se abre; Caída sistólica (3) indica que el volumen de sangre empieza a decrecer, debido a la apertura de la válvula aortica; Muesca dicrótica (4) indica el cierre de la válvula aortica al final del ciclo sistólico, causando un aumento momentáneo en el volumen de la presión arterial; Pendiente diastólica (5) indica la presión que ejerce la sangre cuando el corazón se relaja para volver a llenarse de sangre; Presión diastólica final (6) indica el nivel mínimo de volumen sanguíneo que se detecta antes de que el corazón se vuelva a llenar de sangre.

Un incremento en la presión es el resultado de una gran compresión generada antes de que la válvula aórtica se abra, al mismo tiempo que la expulsión de la sangre se encarga de mantener la presión. Por otra parte, la muesca dicrótica presente en la presión aórtica es producida cuando la válvula aortica se cierra.

Conforme la sangre viaja por el sistema cardiovascular la energía generada por el bombeo del corazón, se dispersa por dos razones, las pérdidas de energía por la expansión y contracción de las arterias y por la fricción viscosa del flujo sanguíneo.

Un flujo sin fricción es una condición ideal, sin embargo, en un fluido real las moléculas se atraen unas a otras, por lo tanto, el movimiento de las moléculas del fluido ejerce una fuerza conocida como rozamiento viscoso (Davidovits, 2019).

El rozamiento viscoso tiene una relación similar a la velocidad del flujo y la viscosidad del fluido presente. La velocidad de un fluido que se mueve a través de una tubería varía debido a la fricción viscosa. Esta velocidad es mayor en el interior y disminuye en las paredes de la tubería donde el fluido permanece estático, a este movimiento del fluido se le conoce como laminar porque su movimiento tiene un orden perfecto, es suave y se presenta en forma de capas, de modo que se mueva en láminas paralelas que no se mezclan, tal como se muestra en la Figura 1-6 (Torres, 2012). En la Ecuación 1-3 de la velocidad crítica del flujo sanguíneo, de la sección 1.5, se muestra que el número de Reinold $\mathfrak{R}$ es el que determina si el flujo sanguíneo será laminar o turbulento.




Figura 1.6 Flujo Laminar, adaptada de (Davidovits, 2019).

Las oscilaciones de la presión debidas a las pérdidas de energía desaparecen conforme la sangre se aleja del corazón y desciende la presión media.

La presión arterial es de 30 mmHg cuando la sangre llega a los capilares, por otra parte, en las venas la presión disminuye más y se hace cero antes de regresar al corazón.

En esta etapa final el flujo sanguíneo en las venas es impulsado por la contracción de los músculos que empujan la sangre al corazón. Las válvulas unidireccionales de las venas se encargan de que el flujo sanguíneo se realice en una sola dirección.

Las principales arterias del cuerpo tienen un tamaño relativamente grande, por ejemplo, el radio de la aorta es de más o menos 1 cm, por esta razón la caída de la presión arterial es pequeña. Hay que tomar en cuenta que conforme la aorta se ramifica, el diámetro de las arterias se hace más pequeño, esto provoca una mayor oposición al flujo.

Aunque el flujo sanguíneo en las arterias más pequeñas también disminuye, la caída de presión es considerable en dichas arterias. Sin embargo, la presión media a la entrada de las arteriolas es más o menos de 90 mm Hg.

Esto solamente es una caída del 10 % de la presión media en el corazón. El flujo sanguíneo en las arteriolas implica una caída de presión más grande alrededor de 60 mm Hg, en consecuencia, la presión en los capilares es de 30 mmHg.

Ya que la caída de presión es pequeña en las arterias principales, cuando el cuerpo se encuentra en posición horizontal la presión arterial media es más o menos constante en todo el cuerpo.

Si una persona se encuentra de pie, la presión arterial no es igual en todas las partes del cuerpo. Además, hay que tomar en cuenta el peso de la sangre al calcular la presión en las diferentes partes del cuerpo.

El sistema vascular cuenta con varios mecanismos de control del flujo sanguíneo, que ayudan a compensar los cambios de la presión arterial que se juntan con los cambios debidos a la posición del cuerpo. Sin embargo, el sistema presenta un retraso al compensar dichos cambios.

De este modo una persona se siente mareada cuando salta de una posición boca abajo, esto por una súbita disminución de la presión arterial y bajo flujo sanguíneo en el cerebro.

Estos principios hidrostáticos funcionan igual en las venas, y su efecto es peor que en las arterias. Sin embargo, la presión sanguínea es menor en las venas que en las arterias.

Cuando una persona está en reposo, la presión sanguínea no empuja la sangre de los pies al corazón. Por esta razón cuando una persona está sentada o de pie, la sangre se estanca en las venas de las piernas lo que aumenta la presión en los capilares y provoca una hinchazón temporal en las piernas.

1.2.1 Flujo Laminar

El flujo laminar es el flujo que fluye con suavidad y en orden dentro de un conducto, como es el caso de tuberías o canales. Dicho flujo se mueve en láminas paralelas sin mezclarse, de modo que las partículas del fluido siguen una trayectoria que comúnmente se conoce como línea de corriente.

En el flujo laminar, la velocidad, la presión y otras propiedades del flujo permanecen constantes en cada punto del fluido. El flujo laminar sobre una superficie horizontal consiste de capas delgadas o láminas paralelas entre sí, cuando el fluido entra en contacto con la

superficie horizontal se vuelve estacionario, pero las demás capas se deslizan unas sobre otras.

Cuando el flujo laminar se produce dentro de una tubería recta se considera como el movimiento relativo de cilindros concéntricos de fluido, el cilindro exterior en la pared de la tubería y los demás cilindros se mueven a velocidades crecientes conforme se acercan al centro de la tubería. El flujo laminar es común únicamente en los casos donde el canal del flujo es relativamente pequeño, la viscosidad es alta y el flujo se mueve lentamente.

Para poder predecir si un flujo es laminar se utiliza un parámetro, el cual, depende de la viscosidad del fluido, este parámetro es conocido como número de Reynolds, el cual relaciona las fuerzas de inercia y las fuerzas viscosas para poder estimar la condición del flujo y predecir si es laminar o no.

La expresión matemática para estimar el número de Reynolds en el caso del flujo de un fluido dentro de una tubería se muestra en la Ecuación 1-2.

$$R_e = \frac{\rho v D}{\mu}$$

Ecuación 1-2 Cálculo del número de Reynolds.

Donde R_e es el número de Reynolds, ρ es la densidad del fluido, v es la velocidad del fluido, D es el diámetro de la tubería y μ es la viscosidad dinámica del fluido. Cabe mencionar que el número de Reynolds es un parámetro adimensional compuesto por las características del fluido que se esté estudiando.

En consecuencia un flujo es laminar cuando se tienen flujos lentos, las fuerzas viscosas son dominantes y se mantienen las partículas del fluido en línea recta. Como referencia se tiene que para un número de Reynolds menor a 2000 se tendrá un flujo laminar, para valores del número de Reynolds que van entre 2000 y 3500 el fluido presenta turbulencia dando lugar a

una transición de flujo laminar a flujo turbulento que generalmente se presenta en la mayoría de los flujos con los que se trabaja en ingeniería.

1.3 Control del flujo Sanguíneo.

El bombeo del corazón está regulado por hormonas que son proteínas producidas por tejidos y órganos de distintas partes del cuerpo, estas hormonas se separan en el flujo sanguíneo y llevan señales a todas las partes del cuerpo.

Cuando la función del corazón es alterada se producen hormonas debido a estímulos del cuerpo como la falta de oxígeno, variaciones en la temperatura y diferentes tipos de estrés emocional.

El flujo sanguíneo es controlado por las arteriolas en ciertas partes del cuerpo, dichas arterias tienen un diámetro de 0.1 mm, sus paredes están formadas por fibras musculares lisas que se contraen por medio de impulsos nerviosos y hormonas.

Cuando las arteriolas se contraen, se reduce o se desvía el flujo sanguíneo en ciertas partes del cuerpo. Debido a que el tamaño de las arteriolas es pequeño un método eficaz para el control del flujo sanguíneo es la constricción. La ecuación de Poiseuille expresa que si la caída de presión es constante el radio de las arteriolas disminuye un 20 % reduciendo el flujo sanguíneo más del doble, tal como se muestra en la Ecuación 1-3.

$$Q = \frac{\pi R^4 (P_1 - P_2)}{8\eta L} \text{ cm}^3 / \text{s}$$

Ecuación 1-3. Ley de Poiseuille para el control del flujo sanguíneo (Davidovits, 2019).

Donde Q es la velocidad del flujo laminar a través de un tubo cilíndrico de radio R y longitud L , $(P_1 - P_2)$ es la diferencia entre las presiones del fluido en los dos extremos del cilindro y η es el coeficiente de viscosidad medido en unidades de s/cm^2 .

1.4 Energía del flujo Sanguíneo.

Cuando una persona se encuentra en reposo la velocidad del flujo sanguíneo es de 5 litros/min, esto significa que la velocidad promedio de la sangre en la aorta es de 26.5 cm/seg, pero hay que tomar en cuenta que la sangre en la aorta se mueve en forma de chorros y no de manera constante.

La velocidad de la sangre es más o menos tres veces mayor que su promedio, por lo tanto, su energía cinética por centímetro cúbico se calcula con la Ecuación 1-4.

$$KE = \frac{1}{2} \rho v^2 = \frac{1}{2} (1.05)(79.5)^2 = 3330 \text{ erg/cm}^3$$

Ecuación 1-4. Energía Cinética de la sangre (Davidovits, 2019).

Donde encontramos que la energía cinética de 3330 erg/cm³ es similar a una presión de 2.50 mmHg, esta es una presión baja en comparación con la presión de la aorta que es de 100 mmHg. Por lo tanto, la densidad de energía por unidad de volumen y la presión se miden como 1 erg/cm³ = 1 dina/cm².

En las arterias más pequeñas la energía cinética es todavía menor porque conforme las arterias se dividen el área total que ocupan aumenta y en consecuencia la velocidad del flujo sanguíneo disminuye, por ejemplo, la velocidad de la sangre en los capilares es de solo 0.33 mm/seg cuando el flujo total es de 5 litros/min.

La energía cinética en la sangre es importante conforme la velocidad del flujo sanguíneo se incrementa, por ejemplo, en la sangre la energía cinética es de 83.300 erg/cm³ que es igual a una presión de 62.5 mmHg, esto se presenta durante la actividad física cuando el flujo sanguíneo aumenta a 25 litros/min.

En comparación con la presión sanguínea medida en reposo esta energía es considerable. Por otra parte, el aumento de la velocidad del flujo sanguíneo durante la actividad física no representa un problema en las arterias sanas, pero si la actividad física es intensa la presión arterial aumenta para igualar la caída de presión.

1.5 Turbulencia en la Sangre.

Si la velocidad de un fluido aumenta más allá de un punto crítico, el flujo laminar se interrumpe, entonces dicho flujo se vuelve turbulento con remolinos y torbellinos. En un tubo cilíndrico el flujo de la sangre se vuelve turbulento por encima de la velocidad crítica. Por otra parte, el flujo sanguíneo es laminar en la mayor parte del sistema circulatorio, solamente en la aorta el flujo se presenta turbulento en algunas ocasiones. Por lo tanto, la velocidad crítica cuando se presenta la turbulencia en la aorta, que es de 2 cm de diámetro y tomando en cuenta un número de Reynold, se calcula a partir de la Ecuación 1-5.

$$V_c = \frac{\Re \eta}{\rho D} = \frac{(2000)(0.04)}{(1.05)(2)} = 38 \text{ cm/seg}$$

Ecuación 1-5. Velocidad crítica del flujo sanguíneo (Davidovits, 2019).

Donde V_c es la velocidad crítica del flujo, D es el diámetro del cilindro, ρ es la densidad del fluido, η es la viscosidad y el símbolo $\Re$ es el número de Reynold.

La velocidad del flujo en la aorta se encuentra por debajo de dicho valor crítico cuando el cuerpo se encuentra en reposo, pero conforme aumenta la actividad física, el flujo en la aorta es mayor a la velocidad crítica y se vuelve turbulento.

El flujo sanguíneo es laminar en las diferentes partes del cuerpo a menos que las arterias estén apretadas de manera anormal. Por lo tanto, el flujo laminar es silencioso a diferencia del flujo turbulento que produce ruidos por las vibraciones de los diferentes tejidos cercanos, esto indica irregularidades en el sistema circulatorio.

Estos ruidos son conocidos como soplos, se detectan con un estetoscopio y ayudan a diagnosticar los trastornos circulatorios.

1.6 La Arteriosclerosis y el flujo Sanguíneo.

La arteriosclerosis es una enfermedad cardiovascular común en Estados Unidos, se calcula que 200 000 personas mueren cada año por esta enfermedad, en la que la pared de la arteria aumenta su tamaño y su diámetro se reduce al cubrirse por unos depósitos conocidos como placa, dicha enfermedad daña de manera grave la función del sistema circulatorio.

Un 50% de estrechamiento o estenosis en las arterias se considera moderada, entre el 60% y 70% se considera grave y un estrechamiento superior al 80% se considera crítico. Los problemas causados por la estenosis se determinan con la ecuación de Bernoulli.

El flujo sanguíneo aumenta en las arterias que tienen su diámetro reducido, por ejemplo, si el radio de la arteria se reduce en una razón de 3 veces, su área transversal se reduce en una razón de 9 veces y por lo tanto la velocidad del flujo sanguíneo aumenta 9 veces.

Cuando se presenta un estrechamiento la energía cinética incrementa una razón de 92 veces, el incremento de dicha energía depende de la presión sanguínea, esto quiere decir que para tener mayor velocidad del flujo sanguíneo la energía potencial generada por la presión se transforma en energía cinética, por lo tanto, la presión sanguínea en una región reducida disminuye, por ejemplo, si la aorta no presenta obstrucción la velocidad del flujo es de 50 cm/seg en una región reducida, debido a que el área disminuye en una razón de 9 veces la velocidad aumenta a 450 cm/seg.

Por lo tanto, la presión decrementa unos 80 mmHg. Por otra parte debido a la baja presión en el interior de la arteria la presión externa cierra dicha arteria y bloquea el flujo sanguíneo. Cuando se presenta esta obstrucción en la arteria coronaria que suministra sangre al corazón este deja de funcionar.

Como se comentaba anteriormente cuando la estenosis está arriba del 80 % se considera crítica porque el flujo sanguíneo se vuelve turbulento y disipa una energía mayor que la del flujo laminar. En consecuencia, la caída de presión es mayor que la calculada con la ecuación de Bernoulli. Cabe mencionar que cuando el flujo se vuelve turbulento el sistema circulatorio se daña debido a que partes del flujo chocan contra la pared arterial y no son paralelas como en el flujo laminar.

La sangre que choca contra la pared arterial desprende parte de la placa acumulada, después dicha placa obstruye una parte más angosta de la arteria. Si la obstrucción se presenta en una arteria cervical el flujo sanguíneo que se dirige al cerebro es interrumpido dando lugar a un accidente cerebrovascular.

La arteria tiene cierta elasticidad, por lo tanto, presenta propiedades de resorte, similar a un muelle la arteria tiene una frecuencial natural con la que presenta movimiento vibratorio.

La frecuencia natural de una arteria sana es de 1 a 2 kHz. Sin embargo, los depósitos de placa aumentan la masa de la pared de las arterias y disminuyen su elasticidad, por esta razón la frecuencia natural de la arteria decrementa bastante por lo regular unos cientos de Hertz.

El flujo sanguíneo de naturaleza pulsante tiene un rango de frecuencias de unos 450 Hertz. La pared de la arteria cubierta de placa presenta una reducción en su frecuencia natural, al entrar en movimiento vibratorio resonante se desprenden los depósitos de placa o provocan más daños en la pared arterial.

1.7 La energía producida por el corazón.

La energía de la sangre es suministrada por el bombeo del corazón, esta energía se encarga de impulsar la sangre por el sistema circulatorio y se calcula con la Ecuación 1-6.

$$P_H = Q \left(\frac{cm^3}{seg} \right) E \left(\frac{erg}{cm^2} \right) = QE \text{ erg / seg}$$

Ecuación 1-6. Energía Generada por el Corazón (Davidovits, 2019).

Donde P_H es la potencia producida por el corazón, que se calcula con el producto del caudal Q y la energía E por unidad de volumen de sangre.

Cuando el cuerpo humano se encuentra en reposo el flujo sanguíneo es de 5 litros/min u 83.4 cm³/seg y entonces la energía cinética de la sangre que circula por medio de la aorta es de 3.33×10^3 erg/cm³.

Por otra parte, la energía que corresponde a la presión sistólica de 120 mmHg es de $160 \times 10^3 \text{ erg/cm}^3$.

De este modo, la energía total que corresponde a la suma de la energía cinética y la energía de la presión del fluido es de $1.63 \times 10^5 \text{ erg/cm}^3$, en consecuencia, la energía P producida por el ventrículo izquierdo del corazón se calcula con la Ecuación 1-7.

$$P = (83.4)(1.63)(10^5) = (1.35)(10^7) \text{ erg/seg} = 1.35 \text{ W}$$

Ecuación 1-7. Energía producida por el ventrículo izquierdo (Davidovits, 2019).

El flujo a través del ventrículo derecho que bombea la sangre hacia los pulmones es el mismo flujo que el del ventrículo izquierdo. Por lo tanto, en esta región la presión sanguínea es solo una sexta parte de la presión en la aorta.

De este modo, la potencia del ventrículo derecho es de 0.25 W cuando se encuentra en reposo y de 4.5 W durante la actividad física intensa.

En consecuencia, la potencia total del corazón es más o menos de 1.9 W y 14.6 W, que está en función de la intensidad de la actividad física, aunque en la realidad la presión arterial sistólica aumenta con el aumento del flujo sanguíneo.

1.8 Medición de la presión arterial.

Las presiones sanguíneas que rebasan los límites superiores, así como las que rebasan los límites inferiores sugieren trastornos del organismo que necesitan atención médica, debido a esto la presión arterial es un indicador importante de la salud de una persona.

Las constricciones que provocan la presión arterial alta en el sistema circulatorio, indican que el corazón está haciendo un sobre esfuerzo y se presenta un riesgo por el exceso de carga. La forma directa en que se mide la presión arterial es metiendo un tubo de vidrio de manera vertical en una arteria para observar a que altura llega la sangre.

Esta fue la forma en que el reverendo Stephen Hales midió la presión arterial por primera vez en 1733, conectando un tubo largo de vidrio en forma vertical en el interior de la arteria de un caballo.

Se han desarrollado diferentes métodos de medición de la presión arterial, estos métodos utilizan las leyes físicas de la circulación sanguínea, para establecer la presión arterial en el sistema vascular (Augusto, 2018).

Hay dos tipos de sistemas de medición, la medición directa o invasiva en la que se introduce un catéter en un vaso sanguíneo, este catéter tiene un transductor de presión que convierte las variaciones de presión sanguínea en señales eléctricas que se amplifican y acondicionan.

Estos métodos representan un riesgo alto para los pacientes, pero tienen la ventaja de que son los métodos más exactos para la medición de la presión realizada con un catéter de medición.

El otro sistema de medición es la indirecta o no invasiva donde son utilizados los principios de la física circulatoria para tener estimaciones o aproximaciones de la presión arterial sin la necesidad de un método quirúrgico.

Los sistemas no invasivos tienen un bajo costo, riesgos bajos para el paciente y son de mucha utilidad para el diagnóstico. Hay diferentes métodos no invasivos, gran parte de ellos permiten tener estimaciones de las presiones sistólica y diastólica, incluso algunos métodos permiten tener una medición instantánea de la presión arterial.

Hay otra clasificación importante de estos sistemas de medición que es con respecto a los resultados obtenidos. Estos sistemas de medición se conocen como continuos o instantáneos y son capaces de estimar la presión arterial en un instante de tiempo determinado.

Hay autores que usan el término continuo para clasificar a los instrumentos que realizan múltiples mediciones en largos periodos de tiempo sin la supervisión de un operador.

Cuando se habla de los sistemas de medición no invasivos y continuos se trata de los métodos que no necesitan penetrar en la piel y miden la presión arterial en largos periodos de tiempo. Para los especialistas de la salud es importante contar con un método que mida de manera precisa la presión arterial sistólica, diastólica y media.

A continuación, se muestran los métodos más actuales para la medición no invasiva y continua de la presión arterial, cada uno de estos métodos tiene ventajas y desventajas, desafortunadamente ninguno de ellos es confiable, preciso y no son cómodos para el paciente (Peter et al., 2014).

Los métodos no invasivos más utilizados para la medición de la presión arterial son el auscultatorio y el oscilométrico, estos métodos usan un brazalete neumático que se coloca alrededor del brazo el cual se infla a una presión mayor a la sistólica para después desinflarse lentamente.

El método auscultatorio se basa en los sonidos de Korotkoff que se escuchan con un estetoscopio colocado sobre la arteria por debajo del brazalete neumático, dichos sonidos se presentan cuando la presión del brazalete es igual a la presión sistólica y desaparecen cuando la presión restante es igual a la presión diastólica.

A medida que la presión desciende la arteria se expande a su tamaño normal, el flujo sanguíneo se vuelve laminar y el sonido desaparece, sin embargo, como la arteria está todavía constreñida el flujo es turbulento y va acompañado de un sonido particular. La presión que se presenta cuando el sonido comienza a desvanecerse se toma como la presión diastólica.

Aunque este método no es tan preciso como los métodos invasivos, es sencillo y en la mayoría de los casos es el adecuado, pero depende de la experiencia del operador. Además, este método no se utiliza para un control a largo plazo porque es necesaria la supervisión de un médico.

El método oscilométrico se basa en la medición de las oscilaciones de la presión arterial que aparecen cuando la presión en el brazalete es igual a la presión sistólica, dichas oscilaciones tienen un valor máximo en la presión media y desaparecen en la presión diastólica.

Como se mencionó anteriormente la medición de la presión arterial se realiza con un brazalete colocado en el brazo a nivel braquial, aproximadamente a la altura del corazón, tal como se muestra en la Figura 1-7.




Figura 1.7 Método Auscultatorio, adaptada de (Augusto, 2018).

Normalmente al realizar mediciones clínicas se toma en cuenta la variación de la presión arterial a lo largo de todo el cuerpo.

El método de la tonometría realiza el monitoreo continuo de la forma de onda de la presión sanguínea y se basa en la aplicación de una fuerza controlada que forma un ángulo de 90 grados entre la pared de la arteria superficial y el hueso. Este método no necesita de un brazalete neumático, pero si de un dispositivo que genere una fuerza de empuje.

La fuerza aplicada es pequeña para no aplastar completamente la arteria ya que existe un riesgo de isquemia al no poder realizar la medición de la presión sanguínea en ese punto. El contacto del tonómetro sobre la arteria se mantiene durante todo el ciclo cardíaco, debido a que la fuerza aplicada cambia y sigue la onda de presión.

La posición correcta del tonómetro sobre la parte central de la arteria es muy importante debido a que la diferencia con la posición incorrecta del tonómetro es de unos milímetros. El método de la tonometría es sensible al movimiento, por lo que se necesita una posición precisa y estable del sensor.

La condición ideal para la medición de la presión arterial con el método de la tonometría es en la posición de descanso. La exactitud de este método está en función de varios factores que son controlados con respecto al tiempo, por esta razón dicha exactitud disminuye de manera rápida sin supervisión. Además, el tonómetro no es un dispositivo cómodo para el paciente durante sus actividades cotidianas.

Actualmente, algunos dispositivos en el mercado que se basan en el método de la tonometría son el T-Line1 de la empresa Tensys Medical de Estados Unidos y el BPro2 del Center of Hearts de Canadá. Sin embargo, este método mostrado en la Figura 1-8 no se utiliza comúnmente para medir la presión arterial.




Figura 1.8 Tonometría aplanatoria, adaptada de (Augusto, 2018).

El primer método no invasivo para el control de la presión arterial y que fue nombrado como pinza volumétrica fue desarrollado y patentado por el médico Checo Jan Peñáz en 1969. Este método parcialmente oclusivo, utiliza un pequeño brazalete neumático con un sensor de fotopleetismografía adaptado, dicho brazalete se coloca en el dedo para mantener constante el flujo sanguíneo durante cada latido del corazón, además incluye una unidad de control de presión colocada en la muñeca.

La fotopleetismografía no accede de manera directa a los valores de la presión sanguínea, pero mide los cambios de volumen sanguíneo en la arteria. Desafortunadamente, estos cambios de volumen no se transforman en valores de presión debido a la no linealidad de los componentes elásticos de la pared arterial.

Por otra parte, la fotopleetismografía mide la onda de pulso, esto representa cambios en el volumen de sangre por debajo del brazalete, por lo tanto, la presión también varía en el brazalete debido a esos cambios de volumen en la sangre. Si este volumen de sangre debajo del brazalete es constante, entonces el valor de la presión sanguínea se estima como el valor de la presión en el brazalete.

Luego entonces, la presión que cambia de manera constante en el brazalete se aplica de manera directa al dedo, esta presión corresponde a la presión intraarterial y es una medida instantánea y continua de la presión sanguínea.

El Finapres de la empresa Medical Systems de Ámsterdam, fue el primer dispositivo en el mercado con base en la metodología de la pinza volumétrica, desarrollado a principios de 1980.

La presión del brazalete del dispositivo Finapres fue comparada con la presión intraarterial en muchos estudios y las formas de onda obtenidas fueron similares a las ondas de presión intraarterial en la mayoría de los sujetos.

Actualmente, el sistema Finapres ya no está disponible, pero existen otros dispositivos basados en esta metodología como el Portapres³ y el Finometer de la empresa Finapres Medical Systems de Holanda, el sistema Task Force Monitor⁴ de la empresa CNSystems Medizintechnik, de Alemania y el ccNexfin⁵ de la empresa Edwards Lifesciences de California, Estados Unidos.

Una forma de monitorear la presión arterial sin utilizar un brazalete neumático es medir la velocidad de propagación de las ondas de pulso o PWV en todo el árbol vascular. De hecho, la velocidad de las ondas de presión del pulso que se propagan en todo el árbol vascular está en función del valor de la presión arterial.

La medición indirecta de la presión arterial se realiza a través de la medición continua de la velocidad de las ondas de pulso. El lugar ideal para medir esta velocidad se encuentra en la aorta, debido a que la relación entre la PWV y la presión arterial es mejor en las arterias elásticas centrales del cuerpo humano.

Sin embargo, esta medición es difícil de realizar de forma no invasiva, es más fácil medir el inicio de la onda de pulso desde las primeras arterias que comienzan en la aorta y son más accesibles, las carótidas comunes y las arterias femorales comunes.

La velocidad de la onda de pulso o PWV es la velocidad de los pulsos de presión que se generan en la eyección del ventrículo izquierdo después de la apertura de la válvula aórtica.

Actualmente, los especialistas de la salud consideran importante estimar la velocidad de estos pulsos en la aorta, debido a que la velocidad de propagación de los pulsos de presión aórticos está en función de la elasticidad y la forma geométrica de la pared arterial.

De hecho, la medición de la PWV es el método principal para investigar la rigidez arterial, pero también mide la presión sanguínea de manera precisa a través la medición continua de la velocidad de la onda de pulso.

La medición de la PWV en la aorta es difícil porque es necesario detectar el tiempo de inicio del pulso de presión tanto en la parte de ascenso de la aorta como en la bifurcación ilíaca y aparte medir con precisión la distancia de desplazamiento de los pulsos.

Por otra parte, la aorta no es de fácil acceso ya sea por medios ópticos ni mecánicos. Una opción es medir el inicio de un pulso de presión en dos sitios arteriales que estén cerca de la aorta.

Actualmente hay dispositivos automáticos en el mercado como el Complior6 de la empresa Alam Medical, el SphygmoCor7 de la empresa AtCor Medical de Australia y el PulsePen8 de la empresa DiaTecne de Italia.

El Complior6 mide el tiempo de tránsito del pulso o PTT como el tiempo de retraso entre la onda del pulso carotídeo y la onda del pulso femoral. El SphygmoCor7 estima la medición del PTT a partir de dos valores de tiempo diferentes.

El primer valor es el tiempo de retraso medido entre el pico de la onda R del electrocardiograma y el punto de inicio de la onda de pulso carotídeo, y el segundo valor es el tiempo de retraso medido entre el pico de la onda R del electrocardiograma y el punto de inicio de la onda de pulso femoral.

Cada método hace recomendaciones diferentes e inconsistentes sobre cómo obtener esta distancia, que se mide manualmente. Estos dispositivos requieren la presencia de un operador experto para localizar manualmente las arterias carótidas y femorales. Por esta razón, esta medición depende del operador y es propensa a errores, la Ecuación 1-8 muestra cómo se calcula la PWV.

$$PWV = \frac{L}{time\ delay} = \sqrt{\frac{h E_0 e^{\alpha P}}{\rho d}}$$

Ecuación 1-8. Cálculo de la velocidad de onda de pulso (Augusto, 2018)

Donde E_0 es el módulo de Young de la arteria para presión arterial nula, α es el número de Euler, P es la presión, h es el espesor de la pared arterial, d es el diámetro de la arteria y ρ es la viscosidad de la sangre.

El método PTT o tiempo de tránsito del pulso se basa en la estimación de la velocidad de la onda de pulso a partir del tiempo de recorrido entre dos lugares conocidos. Dado que existe una relación entre la velocidad de onda de pulso o PWV y la presión sanguínea, también existe la misma relación entre el tiempo de recorrido y la presión sanguínea.

De hecho, el PTT se deriva del tiempo de retraso entre la onda R del electrocardiograma y el inicio de la onda de pulso en el dedo que se mide a partir del fotopletismograma. La onda R se genera al inicio de la presión sistólica, cuando la sangre que es expulsada por el corazón hacia la aorta crea la onda de presión del pulso que luego recorre las cercanías.

Por lo tanto, la onda R es una buena referencia para el inicio del ciclo de la presión arterial, debido a que es fácil de detectar, tal como se muestra en la Figura 1-9.




Figura 1.9 Medición del tiempo de tránsito de pulso, adaptada de (Peter et al., 2014).

1.9 Antecedentes de Inteligencia Artificial

En esta sección se da una breve definición sobre la inteligencia artificial, así como, una breve explicación de los algoritmos tentativos que serán utilizados para el desarrollo de este proyecto de tesis doctoral.

La inteligencia artificial es una rama de la informática que se ocupa principalmente de la automatización del comportamiento inteligente, este comportamiento se considera de todos los dominios, el humano, el mundo animal y la vegetación. Una definición compacta de inteligencia es, que la inteligencia es igual a percibir, analizar y reaccionar.

Los materiales básicos de la inteligencia artificial comprenden estructuras de datos, técnicas de representación del conocimiento, algoritmos para aplicar el conocimiento y el lenguaje, y las técnicas de programación para aplicar todo lo anterior.

En parte el objetivo de la inteligencia artificial es encontrar la respuesta a la pregunta de cómo se genera la inteligencia a través de las herramientas que proporciona la inteligencia artificial, debido a que la inteligencia artificial ofrece el medio, así como el banco de pruebas para las teorías de la inteligencia que son expresadas en forma de programas informáticos y son probadas y verificadas ejecutando estos programas en computadoras (Chowdhary, 2020).

Para el desarrollo de este proyecto de tesis doctoral, se analizaron los algoritmos de inteligencia artificial más adecuados para la medición y monitoreo de la presión arterial, de acuerdo con la literatura revisada se recomienda el uso de algoritmos de Deep Learning como las redes neuronales convolucionales (CNN) ya que se utilizan para la predicción de arritmias y para tareas de procesamiento de señales, tal es el caso de este tema de investigación ya que se requiere realizar la adquisición de señales PPG de buena calidad que permitan obtener nueva información sobre sus características morfológicas. Por otra parte, la literatura también recomienda el uso de algoritmos de Machine Learning como K – Nearest Neighbors, Support Vector Machine, Linear Regression y Random Forest ya que estos algoritmos presentan el mejor desempeño en la predicción de la estimación de la presión arterial de manera más precisa.

Las redes neuronales convolucionales (CNN) son un algoritmo de Deep Learning, que está diseñado para trabajar con imágenes, es uno de los algoritmos que ha contribuido en el

desarrollo del campo de visión por computadora. Las tareas comunes de este tipo de redes son, la detección de objetos, clasificación de escenas y clasificación de imágenes en general.

El algoritmo K – Nearest Neighbors es un algoritmo de aprendizaje estadístico, también conocido como algoritmo basado en memoria, se utiliza para agrupar objetos enfocándose en la similitud de sus atributos.

El algoritmo Support Vector Machine es un algoritmo de aprendizaje automático muy potente y versátil, capaz de realizar clasificación lineal o no lineal, regresión e incluso detección de valores atípicos. Las máquinas de vectores de soporte son adecuadas para la clasificación de conjuntos de datos complejos de tamaño pequeño o mediano.

El algoritmo Linear Regression es un algoritmo de modelado estadístico que se emplea para describir una variable de respuesta continua como una función de una o varias variables predictoras, ayuda a predecir el comportamiento de sistemas complejos o a analizar datos experimentales, financieros y biológicos.

Por último, el algoritmo Random Forest es un algoritmo de aprendizaje automático supervisado, es uno de los algoritmos más utilizados debido a su precisión, simplicidad y flexibilidad, se utiliza para tareas de clasificación y regresión, debido a su naturaleza no lineal, es muy adaptable a una variedad de datos y situaciones.

CAPÍTULO 2. ESTADO DEL ARTE

En este capítulo se presenta un análisis de los artículos científicos relacionados con el monitoreo de la presión arterial por medio de fotoplethysmografía. Dicho análisis permitió obtener un conocimiento más amplio sobre las tecnologías y metodologías utilizadas para la medición y monitoreo de la presión arterial por medio de métodos no invasivos utilizando algoritmos de inteligencia artificial.

2.1 Artículos Científicos que utilizan Redes Neuronales Artificiales.

En esta sección se presenta un análisis de los trabajos de investigación que utilizan redes neuronales artificiales incluyendo las redes neuronales profundas que pertenecen a la subárea de Deep Learning dentro del área de Machine Learning, para la medición y monitoreo de la presión arterial por medio de métodos no invasivos utilizando fotoplethysmografía.

Bersano y Sanson (2018) estimaron la presión arterial a partir de las señales fotoplethysmográficas (PPG) sin procesar por medio de clasificación multiclase. Para este estudio utilizaron 52 sujetos entre hombres y mujeres con rangos de edades entre 25 y 60 años, las señales PPG las obtuvieron con un pulsioxímetro con un tiempo de medición de 60 segundos. Cada señal PPG la segmentaron en pulsos utilizando un algoritmo de umbralización con lo que obtuvieron un conjunto de 8135 características de pulso. Los algoritmos que utilizaron fueron fully connected network, convolutional neural network y convolutional-recurrent neural network. Reportaron que el algoritmo convolutional-recurrent neural network obtuvo el mejor error absoluto y desviación estándar para la presión sistólica de 0.36 ± 0.99 mmHg con una precisión de 83.36 % y para la presión diastólica de 0.12 ± 0.45 mmHg con una precisión de 91.23 % esto debido a que añadieron características demográficas de los sujetos. Concluyeron que el algoritmo convolutional-recurrent neural network obtuvo menos variación de error con una ligera pérdida de precisión.

Priyanka et al. (2018) realizaron un estudio donde consideraron los periodos temporales variados de las formas de onda del fotoplethysmograma (PPG) como características para la estimación de la presión arterial utilizaron un enfoque de red neuronal artificial. Reportaron

que utilizaron un tensiómetro de mano con sensores PPG de tipo reflectancia para detectar las señales de la arteria de la muñeca, también utilizaron los datos recolectados de 40 sujetos entre hombres y mujeres de acuerdo con las normas de la FDA (Food and Drug Administration), con un rango de edades entre 23 y 35 años. Señalaron que el algoritmo Levenberg-Marquardt backpropagation y el software Matlab los utilizaron para entrenar la red neuronal la cual consiste de una capa con cuatro entradas que corresponden a los cuatro parámetros que extrajeron de la señal PPG, dos capas ocultas con quince neuronas cada una y una capa con dos salidas para estimar la presión arterial, también utilizaron el método de validación cruzada 10 veces para incrementar la precisión de la red neuronal. Reportaron que el algoritmo de red neuronal obtuvo un error promedio y desviación estándar de 0.17 ± 3.9 mmHg para la presión sistólica y de 0.3 ± 1.8 mmHg para la presión diastólica, debido a que utilizaron los datos demográficos de los sujetos lograron disminuir el error en la medición. Concluyeron que los resultados del enfoque de redes neuronales artificiales para la estimación de la presión arterial son muy alentadores ya que alcanzaron una precisión de 0.99.

L Wang et al. (2018) desarrollaron un método para estimar la presión arterial continua sin brazalete neumático utilizando solamente la señal fotopletimográfica (PPG). El método que proponen utiliza un método llamado multitaper para la extracción de características y una red neuronal artificial con una arquitectura perceptrón multicapa que consta de 22 neuronas de entrada que corresponden a las 22 características extraídas de la señal PPG y 2 neuronas de salida para la estimación de la presión arterial. Reportaron que utilizaron los datos de 72 sujetos registrados en la base de datos MIMIC, el 70 % de los datos los utilizaron para entrenamiento, 15 % para validación y 15 % para prueba, también utilizaron el algoritmo Levenberg-Marquart para el entrenamiento de la red neuronal. Reportaron que los resultados obtenidos mostraron un error promedio absoluto y desviación estándar de 4.02 ± 2.79 mmHg para la presión sistólica y de 2.27 ± 1.82 mmHg para la presión diastólica.

Baek et al. (2019) propusieron un nuevo método para predecir la presión arterial utilizando únicamente señales sin procesar y sin extracción de características de la velocidad de onda de pulso (PWV) manualmente. Encontraron que es más complicado realizar la extracción de características manualmente por medio de PWV y que requiere de una calibración periódica

debido a que la correlación entre PWV y la presión arterial difiere de un sujeto a otro. Para resolver este problema propusieron una red totalmente convolucional la cual consiste de un codificador de tiempo, un codificador de frecuencia y tres predictores para tiempo, frecuencia y matrices de características combinadas. Reportaron que utilizaron la base de datos MIMIC con un registro de 1912 señales ECG y PPG de 942 sujetos, de los datos de las señales registradas utilizaron 1340 para entrenamiento, 193 para validación y 379 para prueba. Reportaron que obtuvieron un error promedio absoluto de 9.30 mmHg para la presión sistólica y un error promedio absoluto de 5.12 mmHg para la presión diastólica con el método propuesto, sin calibración. Señalaron que el método que propusieron se aplica fácilmente a una aplicación sobre un dispositivo debido a que es posible entrenar y predecir la presión arterial utilizando un corto tiempo de duración de 8 segundos y es posible combinar varias señales de entrada como ECG y/o PPG.

Manamperi et al. (2019) propusieron un método para extraer una combinación de características a partir de la señal PPG para estimar los valores de la presión arterial. Encontraron que existen métodos que utilizan principalmente una categoría de características u otra, pero no utilizan características a partir de múltiples categorías. Reportaron que utilizaron la base de datos MIMIC II con datos registrados de 50 sujetos con un tiempo de medición de 3 minutos, extrajeron un total de 53 características de la señal PPG a partir de 3 categorías como características generales, características relacionadas con la segunda derivada de la señal y características relacionadas con la anchura de la señal. Reportaron que utilizaron en este estudio una red neuronal artificial de 6 capas para predecir la presión arterial, el 20 % de los datos recolectados los utilizaron para prueba y 20 % para validación. Reportaron que la red neuronal artificial obtuvo un error promedio absoluto de 3.2 mmHg para la presión sistólica y un error promedio absoluto de 1.9 mmHg para la presión diastólica.

Shimazaki et al. (2019) desarrollaron un método para estimar la presión arterial sistólica a partir de fotopletimografía (PPG) y generar automáticamente las características de la onda de pulso. El modelo que propusieron en este estudio utiliza una red neuronal convolucional para la extracción automática de características, dicha red neuronal consiste de una capa de entrada, una capa convolucional, una capa de agrupación, una capa totalmente conectada y una capa de regresión totalmente conectada, utilizaron un prototipo de un sensor PPG fijado

en el dedo índice izquierdo para la adquisición de las señales, con un tiempo de medición de 5 minutos, para el preprocesamiento de las señales utilizaron aproximadamente 50000 datos de onda de pulso. Reportaron que el modelo que propusieron obtuvo un coeficiente de correlación de 0.71 y una desviación estándar de 11.40 mmHg, con una muestra de 78 sujetos entre hombres y mujeres con rangos de edades entre 20 y 70 años.

Slapnicar et al. (2019) desarrollaron sistemas robustos para la estimación de la presión arterial no intrusivos que ofrecen al usuario actualizaciones periódicas de la presión arterial casi en tiempo real a partir de fotopletimografía (PPG). Reportaron que utilizaron la base de datos MIMIC III con registros de 510 sujetos con edades por arriba de los 16 años, con un tiempo de medición de 10 minutos. Reportaron que el modelo que propusieron es una red neuronal convolucional llamada ResNet de espectro-temporal la cual obtuvo un error promedio absoluto de 9.43 mmHg para la presión sistólica y un error promedio absoluto de 6.88 mmHg para la presión diastólica, utilizando un proceso de personalización. Concluyeron que los resultados sugieren que la estimación de la presión arterial con un solo sensor PPG es adecuado para mediciones de una sola vez mientras que su aplicabilidad al monitoreo continuo es limitada.

Tanveer et al. (2019) propusieron un modelo de red neuronal artificial con memoria a corto plazo con base en forma de onda que extrae las características necesarias automáticamente utilizando las formas de onda electrocardiográfica (ECG) y fotopletimográfica (PPG) para la estimación de la presión arterial. Encontraron que las señales PPG y ECG son afectadas por varias enfermedades, fármacos y otros factores externos, esto hace que la extracción de características sea bastante difícil. Para este estudio utilizaron la base de datos MIMIC I con datos recolectados de ECG y PPG, utilizaron los registros de 39 pacientes con rangos de edades entre 20 y 100 años. Propusieron un modelo el cual consiste de dos niveles jerárquicos, el nivel inferior utiliza redes neuronales artificiales para aprender las características de las formas de onda ECG y PPG concatenadas y el nivel superior de memoria a corto plazo aprende las relaciones temporales entre las características extraídas en el nivel inferior. El 70 % de los datos de los pacientes los utilizaron para entrenamiento, el 10 % para validación y el 20 % para prueba, también utilizaron dos conjuntos de datos uno con 10 segmentos de formas de onda extraídos con una ventana de tiempo de 16 segundos

equivalente a 2000 muestras y el otro conjunto con 32 segmentos con una ventana de tiempo de 40 segundos equivalente a 5000 muestras. Reportaron que el modelo propuesto obtuvo un error promedio absoluto de 1.10 mmHg para la presión sistólica y un error promedio absoluto de 0.58 mmHg para la presión diastólica, utilizando el conjunto de datos de 10 segmentos, e incrementando la capacidad de predicción con el conjunto de datos de 32 segmentos. Señalaron que el proceso de detección de picos ECG y PPG lo mejoraron con el uso de redes neuronales.

Hajj et al. (2020) propusieron nuevos métodos para la estimación de la presión arterial no invasiva sin brazalete neumático a partir de las señales fotopletismográficas (PPG). Reportaron que las señales PPG fueron adquiridas a partir de 500 registros de 1 paciente obtenidos de la base de datos MIMIC III, todas las señales PPG las agruparon en conjuntos de 3 segundos con 21000 segmentos y de 7 segundos con 9000 segmentos, para este estudio utilizaron 7 características para la estimación de la presión arterial, para validar el desempeño de los modelos el 60 % de los datos los utilizaron para entrenamiento, 20 % para validación y 20 % para prueba. Los modelos que proponen utilizan dos redes neuronales recurrentes no lineales llamadas redes de memoria a corto plazo (LSTM) y redes de unidades recurrentes de compuerta (GRU), ambos modelos son efectivos y eficientes en el procesamiento de datos de series de tiempo. Reportaron que los modelos LSTM y GRU superaron a los modelos de regresión lineal múltiple y las redes neuronales no recurrentes obteniendo un error promedio absoluto de 3.23 mmHg para la presión sistólica y de 1.59 mmHg para la presión diastólica con el modelo LSTM y un error promedio absoluto de 3.25 mmHg para la presión sistólica y de 1.43 mmHg para la presión diastólica con el modelo GRU. Concluyeron que los resultados mejoran incrementando el tamaño de la base de datos y optimizando el conjunto de características de entrada para incluir información que describa la rigidez arterial, edad, genero, altura y otros factores que influyen en la presión arterial.

Hsu et al. (2020) desarrollaron un modelo de red neuronal profunda capaz de extraer 32 características exclusivamente de señales fotopletismográficas (PPG) para la estimación de la presión arterial. Reportaron que utilizaron los datos de 9000 sujetos, es decir 2.17 millones de registros de la base de datos MIMIC II, de los datos obtenidos utilizaron el 70 % para entrenamiento, 20 % para prueba y 10 % para validación. El modelo que propusieron utiliza

una red neuronal profunda de predicción la cual consiste de 5 capas completamente conectadas, cada capa contiene más de 2000 unidades de perceptrones completamente conectadas que son responsables de predecir la presión arterial en cada ciclo cardíaco a partir de 32 parámetros fisiológicos extraídos. Reportaron que la red neuronal profunda mostró un error promedio absoluto de 3.21 mmHg para la presión sistólica y un error promedio absoluto de 2.23 mmHg para la presión diastólica.

Han et al. (2020) probaron un nuevo método de aprendizaje profundo el cual determina de manera precisa la presión arterial sin una calibración inicial a partir de las señales fotopletimográficas (PPG) sin procesar. Para este estudio utilizaron la base de datos Figshare PPG-BP la cual consiste de 219 sujetos adultos y utilizaron 900 segmentos de formas de onda de la señal PPG, el 90 % de los datos los utilizaron para entrenamiento y el 10 % para prueba. El método que propusieron utiliza una red neuronal convolucional la cual consiste de 5 capas convolucionales, una capa maxpooling y 3 capas totalmente conectadas, con este modelo obtuvieron la clase de hipertensión predicha y la estimación de la presión arterial. Reportaron que la red neuronal convolucional obtuvo una precisión de 91.67 % para tensión normal, un valor Recall de 92.31 % para prehipertensión y una precisión de 66.67 % para hipertensión. Señalaron que el método que propusieron también alcanzó puntajes F1 de 84.62 %, 95.65 % y 90 % en la clasificación de la presión arterial, donde F1 es una medida de la precisión de las pruebas. Concluyeron que los resultados comparativos mostraron que el método que propusieron superó a la mayoría de los trabajos relacionados en puntajes F1.

Li et al. (2020) desarrollaron un modelo de aprendizaje profundo para realizar la estimación de la presión arterial en tiempo real utilizando las características extraídas a partir de las señales, electrocardiográfica (ECG) y fotopletimográfica (PPG). Encontraron que las señales ECG y PPG son utilizadas para recuperar información importante para la estimación de la presión arterial. El algoritmo que propusieron está inspirado en un modelo de aprendizaje profundo que contiene una red de memoria a corto plazo bidireccional con la cual utilizaron 7 características de la señal PPG. Reportaron que utilizaron la base de datos MIMIC II la cual contiene más de 25000 instancias de señales ECG y PPG sin procesar, utilizaron 6852 registros de ciclos de señal, de los cuales el 80 % los utilizaron para entrenamiento y 20 % para prueba, dichos registros los obtuvieron a partir de 50 sujetos

seleccionados aleatoriamente. Reportaron que la red de memoria a corto plazo bidireccional obtuvo un error promedio de 4.63 mmHg para la presión sistólica y un error promedio de 3.15 mmHg para la presión diastólica. Señalaron que el modelo que propusieron presenta una fuerte ventaja sobre los métodos tradicionales de aprendizaje automático debido a que modelan la función de mapeo, además los modelos de aprendizaje profundo son entrenados con la menor intervención humana comparados con los métodos tradicionales de aprendizaje automático. Concluyeron que el modelo que propusieron superó a los métodos existentes y es capaz de alcanzar una estimación precisa para ser aplicado en la práctica clínica de manera efectiva.

Panwar et al. (2020) propusieron un marco de aprendizaje profundo para la estimación simultánea de la frecuencia cardíaca y la presión arterial utilizando un simple canal de datos de señal fotopletimográfica (PPG). Encontraron que se han realizado varios estudios relacionados con la frecuencia cardíaca y la presión arterial que utilizan algoritmos de aprendizaje con base en ingeniería de características para eliminar o atenuar los artefactos de movimiento, sin embargo, han utilizado la referencia de movimiento del sensor externo y una serie de características para la estimación satisfactoria del parámetro fisiológico en presencia de artefactos de movimiento que impiden la evaluación precisa de esas metodologías para diferentes condiciones y usuarios. Reportaron que utilizaron las bases de datos MIMIC II y PPG-DaLiA, utilizaron los datos recolectados de 1557 sujetos, utilizaron 250 muestras de señal PPG con un tiempo de medición de 8 minutos. Reportaron que el modelo que propusieron llamado PP-Net implica una red neuronal convolucional combinada con una red de memoria a corto plazo (LSTM). Reportaron que el modelo que propusieron obtuvo un error promedio absoluto de 3.97 mmHg para la presión sistólica y un error promedio absoluto de 2.30 mmHg para la presión diastólica y 2.32 latidos por minuto para la frecuencia cardíaca. Señalaron que este estudio es un paso hacia el desarrollo de una solución para estimar múltiples parámetros fisiológicos simultáneamente de forma discreta. Concluyeron que el modelo que propusieron es ligero, poco complejo, que proporciona muchas soluciones de manera discreta para la monitorización de la salud dentro y fuera de un entorno clínico.

Park et al. (2020) investigaron la viabilidad de la estimación de la presión arterial utilizando la fotopletimografía (PPG) de lóbulo de la oreja durante la reanimación cardiopulmonar

(RCP). Encontraron que el método estándar para la detección de la circulación sanguínea durante la RCP es por medio de un capnograma como una herramienta de soporte para decidir sobre el retorno de la circulación espontánea, sin embargo, este método solo está disponible con intubación y tiene baja precisión en la detección del retorno de circulación espontánea. Señalaron que la PPG de lóbulo de oreja tiene la ventaja de reflejar el flujo de sangre al cerebro en tiempo real. Reportaron que utilizaron 2 sujetos con modelo de paro cardíaco, utilizaron un total 255 conjuntos de datos de los cuales 135 los utilizaron para entrenamiento y 80 para prueba, las señales PPG las adquirieron por medio de un sensor comercial. Reportaron que el método que propusieron fue una red de memoria a corto plazo (LSTM) con la que obtuvieron un error cuadrático medio de 2.24 mmHg para la presión sistólica y un error cuadrático medio de 1.90 mmHg para la presión diastólica. Concluyeron que es posible estimar la presión arterial incluso durante la reanimación cardiopulmonar.

Song et al. (2020) presentaron una técnica para estimar la presión arterial con base en aprendizaje profundo para relojes de pulsera inteligentes sin brazaletes neumáticos utilizando las señales, fotopletimográfica (PPG) y electrocardiográfica (ECG). Encontraron que, aunque los estudios más recientes sobre la estimación de la presión arterial utilizan dispositivos tipo reloj de pulsera, dichos dispositivos están inspirados en la técnica de regresión polinomial, que es vulnerable a los datos no lineales tales como la presión arterial. El modelo que propusieron en este estudio utiliza una red neuronal profunda para la estimación de la presión arterial. Reportaron que las señales ECG y PPG las recolectaron por medio de sensores comerciales con un tiempo de medición de 20 segundos y utilizaron 11 características de dichas señales, utilizaron los datos recolectados de 110 sujetos de los cuales utilizaron los datos de 66 sujetos para entrenamiento y los datos de los 44 sujetos restantes los utilizaron para validación. Reportaron que la red neuronal profunda mostró un error promedio absoluto de 4.8 mmHg para la presión sistólica y un error promedio absoluto de 4.8 mmHg para la presión diastólica utilizando los datos demográficos de los sujetos. Concluyeron que cuando las señales PPG y ECG son afectadas por factores externos no se garantiza el desempeño estable del algoritmo que propusieron.

Senturk et al. (2020) establecieron un sistema de medición de la presión arterial continua sin brazaletes neumáticos por medio del uso de un nuevo método para la extracción de

características de las señales, electrocardiográfica (ECG) y fotopletimográfica (PPG). Encontraron que la presión arterial no se mide de manera continua con el método de brazalete neumático debido a que este método no determina la dinámica subyacente de la presión arterial y es ineficaz de captar los síntomas. Reportaron que en este estudio utilizaron la base de datos MIMIC II la cual contiene registros de formas de onda de señales ECG y PPG de 2378 pacientes con rangos de edades entre 13 y 101 años, de cada forma de onda utilizaron 20 características, de la cuales el 60 % las utilizaron para entrenamiento, 15 % para validación y 25 % para prueba, en total utilizaron 4500 latidos cardiacos. Reportaron que utilizaron redes neuronales no lineales autorregresivas con entradas exógenas y redes neuronales de memoria a corto plazo (LSTM), dichas redes LSTM obtuvieron el mejor desempeño con un error promedio de 2.62 mmHg para la presión sistólica y un error promedio de 1.21 mmHg para la presión diastólica. Señalaron que, aunque no se ha desarrollado un estándar para dispositivos de medición de la presión arterial que no obstruyan las arterias, este trabajo es una referencia para estudios estándar. Concluyeron que un dispositivo portátil con el modelo que propusieron es utilizado para la medición de la presión arterial llevándolo en la ropa y accesorios como pulseras, relojes, auriculares y collares.

Tjahjadi et al. (2020) propusieron un método para la clasificación de la presión arterial con base en la fotopletimografía (PPG). Encontraron que los métodos de aprendizaje profundo no tienen buena precisión en tareas de clasificación y su etapa entrenamiento es demasiado larga. Reportaron que utilizaron los datos de 121 sujetos con un rango de edades entre 21 y 86 años, recolectaron 870 registros de datos a partir de la base de datos Figshare PPG-BP, con un tiempo de medición de 15 minutos, la señal PPG la dividieron en segmentos de 2100 muestras cada segmento con una duración de 2.1 segundos. Propusieron utilizar el algoritmo k nearest neighbors, este método es uno de los algoritmos más sencillos y se utiliza principalmente para tareas de clasificación. Reportaron que el método que propusieron obtuvo una precisión de 86.7% en comparación con otros métodos de clasificación, por lo tanto, dicho método es adecuado para aplicarse a datos no lineales como las señales PPG. Concluyeron que el algoritmo K nearest neighbors no requiere de una señal PPG de alta calidad ni de la extracción de sus características morfológicas, por lo tanto, este método es aplicado fácilmente en muchas situaciones.

D. Wang et al. (2020) diseñaron una nueva estructura de red neuronal artificial para realizar la fusión y efectiva utilización de información múltiple para extraer las características holísticas del dominio del tiempo y la frecuencia que mejoran la medición de la presión arterial sin brazalete neumático con base en fotopletismografía (PPG). Encontraron que muchos nuevos enfoques se probaron para lograr la detección de la presión arterial sin brazalete neumático, sin embargo, la precisión de dichos enfoques existentes todavía necesita ser mejorada. Reportaron que utilizaron la base de datos pública UCI-ML-BP la cual consta de registros de señales PPG de 12000 pacientes, utilizaron vectores de características de 200 datos con un tiempo de medición de 24 segundos. Reportaron que diseñaron una red neuronal artificial de fusión de múltiple información la cual consiste de una red neuronal convolucional y 3 redes de memoria a corto plazo (LSTM) con combinaciones de clasificadores múltiples para procesamiento de diferentes datos de entrada. Señalaron que la red neuronal modela bien la relación entre la señal PPG y la presión arterial logrando una precisión promedio del 91.33%, además, verificaron que la fusión de múltiple información de una red meticulosamente diseñada mejoró la precisión de la detección de la presión arterial. Concluyeron que el principal objetivo de este trabajo es ver si el entrenamiento del modelo que propusieron es adecuado para recolectar ondas de pulso por los autores mismos por medio de las cámaras de los teléfonos móviles u otros sensores PPG.

Athaya et al. (2021) Propusieron una arquitectura de aprendizaje profundo llamada U-net que utiliza la señal fotopletismográfica (PPG) de la yema del dedo como entrada para estimar la forma de onda de la presión arterial de manera continua y no invasiva. Señalaron que este método es entrenado utilizando un pequeño conjunto de datos ya que es simple y computacionalmente muy eficiente. Reportaron que utilizaron en este estudio los datos de 45 sujetos de la base de datos MIMIC y los datos de 55 sujetos de la base de datos MIMIC III, utilizaron 350 muestras de señales. El modelo que propusieron utiliza una red U que utiliza un modelo de red neuronal totalmente conectada para segmentación semántica, esta arquitectura consiste de 3 vías, de contracción, de cuello de botella y expansiva, el 70 % de los datos los utilizaron para entrenamiento, 15 % para validación y 15 % para prueba. Reportaron que el modelo U-net obtuvo un error promedio absoluto de 3.68 mmHg para la presión sistólica y un error promedio absoluto de 1.97 mmHg para la presión diastólica. Señalaron que este modelo es utilizado para medir las formas de onda de la presión arterial

continua no invasiva utilizando teléfonos inteligentes o dispositivos portátiles. Concluyeron que este estudio proporciona una posible solución en los métodos de medición de la presión arterial continua, no invasiva, sin brazaletes neumáticos y ayudar a mantenerla bajo control.

En este trabajo El-Hajj et al. (2021) evaluaron rigurosamente la capacidad de los modelos de redes neuronales recurrentes en la predicción de la presión arterial no invasiva sin brazaletes neumáticos a partir de la primera y segunda derivadas de la señal fotopletomográfica (PPG). Encontraron que, aunque algunos estudios han mostrado un desempeño notable utilizando el enfoque PPG existe todavía incertidumbre en la precisión de dicho enfoque lo cual es evidente dada la amplia variación en los resultados reportados. El modelo que propusieron utiliza dos modelos de redes neuronales recurrentes, una red de memoria a corto plazo (LSTM) y una unidad recurrente de compuerta (GRU), utilizaron 52 características de la señal PPG a partir de los registros de 942 pacientes que obtuvieron de la base de datos MIMIC II, la señal PPG la dividieron en segmentos de 10 segundos, el 70 % de los datos los utilizaron para entrenamiento, 15 % para validación y 15 % para prueba. Reportaron que el mejor desempeño lo obtuvieron con las redes LSTM con un error promedio absoluto de 4.51 mmHg para la presión sistólica y un error promedio absoluto de 2.60 mmHg para la presión diastólica. Señalaron que estos resultados confirmaron que consiguieron una precisión de estimación razonable utilizando un conjunto de datos pequeño o un número limitado de pacientes. Concluyeron que las precisiones obtenidas prueban la viabilidad de estimar la presión arterial sin brazaletes neumáticos utilizando solo un sensor PPG.

Harfiya et al. (2021) desarrollaron un autocodificador con base en redes de memoria a corto plazo (LSTM) para traducir la señal de la presión arterial a partir de la señal fotopletomográfica (PPG) sin procesar junto con sus derivaciones y extraer los valores de la presión arterial a partir de dicha señal. Encontraron que los métodos de estimación de la presión arterial con base en la señal PPG son susceptibles al ruido y únicamente proporcionan los valores discretos de la presión arterial. Reportaron que utilizaron la base de datos MIMIC II con registros de datos recolectados de 5289 sujetos, utilizaron 25000 segmentos de la señal PPG. En este estudio utilizaron redes LSTM con base en un autocodificador que es una clase de red neuronal artificial para aprender las características de la señal PPG, el 70 % de los datos los utilizaron para entrenamiento, el 10 % para validación y el 20 % restante para

prueba. Reportaron que el modelo que propusieron obtuvo un error promedio absoluto de 4.05 mmHg para la presión sistólica y un error promedio absoluto de 2.41 mmHg para la presión diastólica. Señalaron que debido a su versatilidad y su carácter no invasivo la PPG se ha convertido en una tecnología ampliamente preferida para obtener información sobre el sistema cardiovascular y respiratorio. Concluyeron que el modelo que propusieron omite el complejo e impráctico enfoque de ingeniería de características el cual algunas veces no es utilizado debido a varias situaciones durante la adquisición que afectarían la calidad de las señales PPG.

Li et al. (2021) desarrollaron un mecanismo de estimación de la presión arterial continua sin la necesidad de la ingeniería de características. Encontraron que la extracción de características automática a partir de la señal fotopletomográfica (PPG) se está convirtiendo en una necesidad ya que el ruido es difícil de manejar incluso con una compleja ingeniería de características. Reportaron que utilizaron la base de datos MIMIC II de la cual utilizaron registros de señales PPG de 5000 sujetos, utilizaron 50000 segmentos de las señales PPG, extrajeron 59 características de cada señal, el 80 % de los datos los utilizaron para entrenamiento, el 10 % de los datos de entrenamiento los utilizaron para validación y el 20 % restante para prueba. Reportaron que utilizaron una red neuronal convolucional (CNN) para extraer las características necesarias y una red de memoria a corto plazo bidireccional (BiLSTM) para realizar la estimación de la presión arterial por medio del aprendizaje de las relaciones temporales entre las características extraídas. Reportaron que el modelo que propusieron alcanzó un error promedio absoluto de 7.84 mmHg para la presión sistólica y un error promedio absoluto de 4.41 mmHg para la presión diastólica. Señalaron que la transición del procesamiento de señales con base en características a la de sin características implicará cambios en los modelos en el área del procesamiento de señales biomédicas. Concluyeron que debido a la simplicidad y suficiencia del modelo que propusieron tiene aplicación a los dispositivos de internet de las cosas.

Qiu et al. (2021) se centraron en la extracción del valor de la característica con base en la información gráfica del fotopletomograma (PPG) y el electrocardiograma (ECG) y adoptaron una estructura de extracción de características diseñada cuidadosamente la cual es más adecuada para una mejor predicción de la presión arterial con grandes bases de datos de

sujetos. Encontraron que trabajos previos han probado que la presión arterial se predice efectivamente por medio de las señales ECG y PPG combinadas las cuales son fácil de obtener a partir de dispositivos vestibles o instrumentos. Reportaron que utilizaron la base de datos MIMIC II con registros de formas de onda que obtuvieron de 1216 sujetos, cada señal con 1000 puntos de información, un tiempo de medición de 8 segundos y 32 parámetros de entrada, el 70 % de los datos los utilizaron para entrenamiento y el 30 % restante para prueba. Reportaron que utilizaron una red neuronal convolucional adaptiva secuencial para la extracción de características y una capa de red neuronal residual para clasificación de objetivos. Reportaron que el modelo que propusieron obtuvo un error promedio absoluto de 3.70 mmHg para la presión sistólica y un error promedio absoluto de 2.81 mmHg para la presión diastólica. Señalaron que para aplicaciones prácticas la velocidad de respuesta de salida es más rápida y en pacientes con señales de entrada inestables la estructura del modelo con base en información gráfica es más confiable. Concluyeron que la medición de la presión arterial sin brazalete neumático detecta de manera continua los valores dinámicos de la presión arterial y que los métodos de aprendizaje profundo con base en la extracción de información gráfica más estables y adaptables para bases de datos con un gran número de sujetos.

Rong et al. (2021) propusieron un nuevo modelo de aprendizaje profundo con base en la fusión de características multi tipo para la predicción de la presión arterial a partir de fotoplethismografía (PPG). Encontraron que trabajos previos utilizaron diferentes tipos de señales biológicas para predecir la presión arterial, sin embargo, la adquisición de múltiples señales requiere más trabajo. Reportaron que utilizaron la base de datos UC Irvine la cual contiene 11546 datos originales divididos en segmentos de 680 puntos. Reportaron que utilizaron dos redes neuronales convolucionales para entrenar las características morfológicas y del espectro de frecuencia de la señal PPG, una red de memoria a corto plazo bidireccional para entrenar las características temporales de dicha señal y el método de fusión de múltiples características para mejorar el desempeño del algoritmo de Deep learning, el 60 % de los datos los utilizaron para entrenamiento, 20 % para prueba y 20 % para validación. Reportaron que el modelo de fusión obtuvo un error promedio absoluto de 5.59 mmHg para la presión sistólica y un error promedio absoluto de 3.36 mmHg para la presión diastólica. Señalaron que este modelo es general y no tiene una calibración personalizada, por lo tanto,

es necesario recolectar constantemente datos personales de la presión arterial y del PPG para afinarlo. Concluyeron que este es un método muy prometedor para lograr una medición de la presión arterial continua sin brazalete neumático a través de la señal PPG.

Sun et al. (2021) propusieron utilizar la señal fotopletimográfica (PPG) y su primera y segunda derivadas para predecir el nivel de la presión arterial utilizando un método de aprendizaje profundo. Encontraron que existe una necesidad urgente de desarrollo de dispositivos de medición de la presión arterial portátiles, fáciles de operar, de medición continua y de bajo costo. Reportaron que utilizaron la base de datos MIMIC con registros de datos recolectados de 582 sujetos, utilizaron la transformada Hilbert-Huang para resolver el problema no estacionario, de no linealidad y eliminar los artefactos de movimiento de la señal, también utilizaron redes neuronales convolucionales como AlexNet, ResNet y GoogleNet para estimar normotensión, prehipertensión e hipertensión. Reportaron que la red AlexNet obtuvo el mejor desempeño con una precisión del 98.90 %. Señalaron que AlexNet con solamente 8 capas se desempeñó mejor que las otras redes con más capas. Concluyeron que por medio de la comparación del desempeño de los experimentos de clasificación en diferentes modelos de redes neuronales convolucionales probaron que las derivadas de la señal PPG llevan importante información sobre la presión arterial lo cual significa que la señal PPG y sus derivadas son utilizadas para reemplazar la combinación de las señales ECG y PPG para la predicción de la presión arterial.

Schrumpf et al. (2021) analizaron el error de predicción de la presión arterial con base en la fotopletimografía (PPG) con respecto a la distribución de datos subyacente. Encontraron que los métodos de medición auscultatorio y oscilométrico con base en brazalete neumático son los más utilizados en ambientes clínicos y domésticos, sin embargo, no son adecuados para mediciones a largo plazo debido a la incomodidad de los sujetos e irritaciones potenciales de la piel incluso requieren de una calibración regular. Reportaron que utilizaron la base de datos MIMIC III con 4000 registros de formas de onda, los datos de 3750 sujetos los utilizaron para entrenamiento y los datos de 625 sujetos los utilizaron para validación y prueba. En este estudio utilizaron 4 diferentes arquitecturas de redes neuronales que son AlexNet, ResNet, una red de espectro-temporal y una red de memoria a corto plazo bidireccional (BiLSTM). Reportaron que la red ResNet obtuvo el mejor desempeño con un

error promedio absoluto de 12.7 mmHg para la presión sistólica y un error promedio absoluto de 10.8 mmHg para la presión diastólica. Señalaron que con el método que propusieron es posible prescindir totalmente de la región de interés lo que posiblemente conduzca a una señal más limpia. Concluyeron que las diferencias de edad, el estado de salud y medicaciones tienen una gran influencia en la distribución de la presión arterial en un conjunto de datos.

En la Tabla 2.1 se presenta un análisis comparativo de los trabajos relacionados con la medición y monitoreo de la presión arterial por medio de fotoplethysmografía, así como las tecnologías y redes neuronales artificiales incluyendo las redes neuronales profundas que pertenecen a la subárea de Deep Learning dentro del área de Machine Learning y que fueron implementadas. Como parte de las tecnologías que utilizaron se encuentra el uso de pulso oxímetros, sensores PPG, utilizaron el software Matlab para el procesamiento de los datos, también utilizaron la base de datos MIMIC que es de acceso público y la base de datos Figshare PPG BP. Los mejores resultados los obtuvieron con redes neuronales profundas.

Tabla 2.1 Análisis comparativo de los trabajos que utilizan redes neuronales artificiales. 1/2

Artículo	Contribución	Tecnologías	Resultados
Bersano y Sanson (2018)	Clasificación y obtención de características PPG.	Pulso Oxímetro Xpod, ANN, FCNN, CNN, C-RNN	El algoritmo C-RNN tuvo precisión del 91.23 %.
Priyanka et al. (2018)	Extracción de características PPG con redes neuronales.	ANN, Matlab	ANN tuvo precisión de 0.99, los datos demográficos disminuyeron el error de medición.
L Wang et al. (2018)	Extracción de características PPG con método multitaper y red neuronal para estimación de presión arterial continua.	Sensor PPG, ANN, MIMIC	La red neuronal resultó eficaz en detección de hipertensión.
Baek et al. (2019)	Extracción de características PPG para estimar presión arterial con red neuronal convolucional	CNN, MIMIC	Este método es recomendado para uso clínico, no requiere calibración y tiene aplicación en un dispositivo embebido.
Manamperi y Chitraranjan (2019)	Extracción de características PPG y estimación de presión arterial con redes neuronales	ANN, MIMIC-II	Las ANN superaron a otros métodos y la combinación de características PPG mejoró la estimación de presión arterial.
Shimazaki et al. (2019)	Extracción de características PPG para estimar presión arterial con una red neuronal convolucional	Sensor PPG, CNN	La CNN extrajo características PPG de manera efectiva y automática.
Slapnicar et al. (2019)	Estimación de presión arterial en tiempo real, no invasiva con red neuronal convolucional (ResNet) de espectro temporal.	Sensor PPG, ResNet, MIMIC-III	Este modelo mejoró con la personalización de datos, sin embargo, su aplicación al monitoreo continuo de presión arterial es limitado.
Tanveer y Hasan (2019)	Estimación de presión arterial con modelo de redes neuronales que aprende características ECG y PPG.	ANN, MIMIC-I	Las ANN extrajeron de manera automática características PPG y ECG sin utilizar ingeniería de características.
Eom et al. (2020)	Estimación de presión arterial a través de ECG, PPG y BCG con red neuronal convolucional.	BIOPACECG100C, PSL-iPPG2C, CNN, BiGRU, Mecanismo de atención	Múltiples señales mejorarían la precisión de predicción de presión arterial en lugar de analizar una sola señal.
El Hajj y Kyriacou (2020)	Estimación de presión arterial a través de PPG con redes neuronales recurrentes no lineales.	LSTM, GRU, MIMIC-III	Estos modelos superaron a los modelos lineales y a las redes neuronales no recurrentes.
Hsu et al. (2020)	Estimación de presión arterial a través de características PPG con una red neuronal profunda.	DNN, MIMIC-II	La DNN tuvo una precisión notablemente alta en comparación con otros métodos.
Han et al. (2020)	Estimación de presión arterial e hipertensión a través de PPG con red neuronal convolucional.	CNN, Figshare PPG-BP	Este modelo tuvo una precisión de 91.67 % para normotension, 92.31 % para prehipertensión y 66.67 % para hipertensión.
Li et al. (2020)	Estimación de presión arterial a través de características ECG y PPG con algoritmo de aprendizaje profundo	BiLSTM, MIMIC-II	Este algoritmo tiene aplicación en la práctica clínica de manera eficaz y ser entrenado con la menor intervención humana.
Panwar et al. (2020)	Estimación de presión arterial y frecuencia cardíaca con una CNN (PP-Net) combinada con una red LSTM.	CNN, LSTM, MIMIC-II, PPG-DaLIA	Este algoritmo estima múltiples parámetros fisiológicos de manera simultánea dentro y fuera de un entorno clínico.
Park et al. (2020)	Estimación de presión arterial en el lóbulo de la oreja durante RCP a través de PPG con red LSTM.	LSTM, Sensor PPG	Este algoritmo logró estimar la presión arterial incluso durante RCP.

Tabla 2.2 Análisis comparativo de los trabajos que utilizan redes neuronales artificiales. 2/2

Artículo	Contribución	Tecnologías	Resultados
Song et al. (2020)	Estimación de presión arterial a través de un smartwatch utilizando ECG y PPG con DNN.	DNN, Sensores comerciales	Este algoritmo obtuvo un buen desempeño incluyendo datos demográficos.
Senturk et al. (2020)	Medición de presión arterial continua, a través de características ECG y PPG con redes neuronales no lineales y redes LSTM	ANN no lineales, LSTM, MIMIC-II	Este modelo es utilizado en un dispositivo portátil para medición de presión arterial continua.
Tjahjadi et al. (2020)	Estimación de presión arterial a partir de PPG con redes BiLSTM que son ampliamente utilizadas para resolver problemas de clasificación.	BiLSTM, Figshare PPG-BP	BiLSTM tuvo una precisión de 96.36 % en normotension, 94.64 % en prehipertensión y 96.64 % en hipertensión, no requiere de extracción de características morfológicas.
D. Wang et al. (2020)	Extracción de características del dominio del tiempo y la frecuencia a partir de PPG con ANN de fusión de múltiple información.	CNN, LSTM, UCI-ML-BP	Dicha red neuronal tuvo una precisión de 91.33 % en la estimación de presión arterial.
Athaya y Choi (2021)	Estimación de presión arterial de la yema del dedo a través de PPG con aprendizaje profundo.	U-net, MIMIC-III	Este modelo es capaz de medir la forma de onda de la presión arterial continua, no invasiva utilizando dispositivos portátiles.
El Hajj y Kyriacou (2021)	Estimación de presión arterial tomando en cuenta la dependencia del tiempo en las características PPG con RNN.	LSTM, GRU, MIMIC-II	Las redes GRU tuvieron el mejor desempeño y extrajeron varias características del dominio del tiempo de la morfología PPG.
El-Hajj y Kyriacou (2021)	Estimación de presión arterial a partir de la primera y segunda derivadas del PPG con RNN.	LSTM, GRU, MIMIC-II, Sensor PPG	Las redes LSTM tuvieron la mejor precisión de estimación con un conjunto de datos pequeño o un número limitado de sujetos.
Harfiya et al. (2021)	Extracción de valores de presión arterial con redes LSTM que aprenden características PPG.	LSTM, MIMIC-II	Dichas redes LSTM no requieren del complejo e impráctico enfoque de ingeniería de características.
Li et al. (2021)	Estimación de presión arterial continua, sin ingeniería de características a partir del PPG con algoritmos de ML.	CNN, BiLSTM, MIMIC-II	Este modelo es aplicado a dispositivos de internet de las cosas.
Qiu et al. (2021)	Estimación de presión arterial a partir de la extracción de características PPG y ECG con algoritmos de aprendizaje profundo	CNN, MIMIC-II	Este modelo detecta de manera continua los valores dinámicos de la presión arterial.
Rong y Li (2021)	Estimación de presión arterial a partir del PPG con algoritmos de Deep learning y el método de fusión de múltiples características.	CNN, BiLSTM, UC Irvine	Este modelo es general y requiere recolección constante de datos personales para obtener una buena precisión de estimación de presión arterial.
Sun et al. (2021)	Clasificación de presión arterial utilizando la primera y segunda derivadas del PPG con CNN.	AlexNet, ResNet, GoogleNet, MIMIC	AlexNet tuvo una precisión de 98.90 % en la clasificación de presión arterial.
Schrumpf et al. (2021)	Evaluación del error de predicción de presión arterial a través del PPG con algoritmos de Deep learning.	AlexNet, ResNet, BiLSTM, MIMIC-III	ResNet tuvo el mejor desempeño obteniendo el menor error de predicción de presión arterial.

2.2 Artículos Científicos que utilizan Algoritmos de Clasificación.

En esta sección se presenta un análisis de los trabajos de investigación que utilizan algoritmos de clasificación, para la medición y monitoreo de la presión arterial por medio de métodos no invasivos utilizando fotopletimografía.

Khalid et al. (2018) compararon tres algoritmos de aprendizaje automático para estimar la presión arterial utilizando las señales fotopletimográficas (PPG). Además, evaluaron la precisión de la estimación de las categorías normotensiva, hipertensiva e hipotensiva. Para este estudio utilizaron los datos recolectados de 32 sujetos con ayuda de un monitor de signos vitales con un rango de muestreo de 100 Hz y un tiempo de medición de 5 segundos, con lo que obtuvieron 8133 segmentos de datos. Las características de la señal PPG que utilizaron fueron el área de pulso, el tiempo de subida del pulso y el ancho del pulso de 25 %. Los algoritmos que utilizaron fueron multiple linear regression, support vector machine y regression tree, dichos algoritmos los evaluaron por medio de validación cruzada aplicada 10 veces. Reportaron que el algoritmo regression tree obtuvo el mejor desempeño con un promedio y desviación estándar de 109.1 ± 12.8 mmHg para la presión sistólica y de 59.8 ± 7.2 mmHg para la presión diastólica.

Slapnicar et al. (2018) se centraron en el análisis del fotopletimograma (PPG). Propusieron un sistema formado por un módulo de preprocesamiento de la señal y un módulo de aprendizaje automático que se encargó de extraer 13 características relevantes de la señal por medio del algoritmo RReliefF (Regression Relief Feature) y finalmente entrenaron varios algoritmos de regresión con los cuales construyeron los modelos de predicción. Reportaron que utilizaron 41 sujetos registrados en la base de datos MIMIC y la base de datos recolectada por el Instituto Jozef Stefan con un tiempo de medición de 3 minutos. Además, utilizaron validación cruzada quíntuple y validación LOSO (Leave One Subject Out) que significa dejar un sujeto afuera para evaluar el desempeño de los algoritmos de regresión. Reportaron que el algoritmo regression trees mostró el mejor desempeño con la base de datos MIMIC utilizando validación LOSO, con lo que obtuvieron el mejor error promedio absoluto y desviación estándar de 4.47 ± 5.85 mmHg para la presión sistólica y de 2.02 ± 2.94 mmHg para la presión diastólica, debido a que aplicaron el 80 % de personalización de los datos. Señalaron que todos los hiperparámetros los optimizaron por medio de optimización bayesiana con ayuda del software Matlab.

Chen et al. (2019) construyeron modelos para estimar la presión arterial continua, utilizando algoritmos de aprendizaje automático y las características de la forma de onda fotopletimográfica (PPG) con base en el tiempo de tránsito del pulso (PTT). Para este

estudio utilizaron la base de datos MIMIC-III que incluye registros de señales ECG y PPG con un registro de 22317 formas de onda y 22247 registros numéricos de pacientes, utilizaron un total de 772 conjuntos de datos de formas de onda, extrajeron 14 características incluyendo PTT, frecuencia cardíaca y características de la forma de onda de pulso. Señalaron que para el preprocesamiento de los datos el 80 % fueron seleccionados aleatoriamente para entrenamiento y el 20 % restante fueron utilizados para prueba. Reportaron que utilizaron support vector regression para construir los modelos para estimar la presión arterial y los compararon con modelos de multivariate linear regression, la optimización de parámetros la realizaron con algoritmos genéticos. Reportaron que utilizaron el error promedio cuadrático y validación cruzada aplicada 5 veces para medir la precisión del modelo, obtuvieron un error promedio absoluto de 3.27 mmHg para la presión sistólica y un error promedio absoluto de 1.16 mmHg para la presión diastólica.

Jung et al. (2019) desarrollaron un sistema para la estimación de la presión sanguínea sin brazalete neumático con base en aprendizaje semi supervisado. En este estudio propusieron el uso del método del tiempo de tránsito del pulso (PTT) para estimar la presión sanguínea sin brazalete neumático, midiendo la diferencia de tiempo entre el pico R del electrocardiograma (ECG) y el pico P del fotoplethismograma (PPG). Reportaron que utilizaron un FPGA para procesar las señales analógicas obtenidas de 9 sujetos de alrededor de 20 años y aplicaron un filtro pasa bajas Sallen-key para mejorar la precisión de la medición, la cual realizaron 5 veces con un tiempo de 25 segundos para cada sujeto. Reportaron haber obtenido cuatro parámetros con valores de 135.2 mmHg para la presión sistólica, 71.63 mmHg para la presión diastólica, 60.89 mmHg para la presión del pulso, que es la diferencia entre la presión sistólica y diastólica y un valor de 74.91 mmHg para la presión arterial promedio, esto con ayuda de regresión lineal. Con los cuatro parámetros extraídos determinaron el estado de salud del usuario utilizando el método de aprendizaje por mapas.

Yi et al. (2019) analizaron un método de medición de alta precisión de la presión arterial continua con base en fotoplethismografía (PPG) y algoritmos de aprendizaje automático. En este trabajo utilizaron la base de datos MIMIC de la cual obtuvieron los datos de 20 pacientes diferentes con diferentes rangos de edades para asegurar la diversidad, utilizaron 5300

señales periódicas para prueba y entrenamiento de cinco algoritmos de aprendizaje automático con los cuales obtuvieron la medición de la presión arterial, dichos algoritmos fueron, linear regression, Lasso regression, elastic network regression, k nearest neighbors y classification and regression trees, además utilizaron 9 características de la señal PPG. Señalaron que el 80 % de los datos fueron utilizados para entrenamiento y el 20 % restante para prueba del modelo. Reportaron que el algoritmo k nearest neighbors obtuvo el mejor desempeño obteniendo un error promedio absoluto de 2.09 mmHg para la presión sistólica y un error promedio absoluto de 1.66 mmHg para la presión diastólica.

Chowdhury et al. (2020) propusieron un sistema de medición de la presión arterial sin brazalete neumático, continua y no invasiva utilizando la señal fotopletimográfica (PPG) y características demográficas utilizando algoritmos de aprendizaje profundo. Reportaron que utilizaron 657 muestras de señales PPG recolectadas de 219 sujetos, utilizaron 107 características de la señal PPG. En este estudio utilizaron 5 diferentes algoritmos de aprendizaje profundo que son linear regression, regression trees, support vector regression, Gaussian process regression y ensemble trees para la estimación de la presión arterial. Reportaron que el algoritmo Gaussian process regression obtuvo el mejor desempeño con un error promedio absoluto de 3.02 mmHg para la presión sistólica y un error promedio absoluto de 1.74 mmHg para la presión diastólica.

Jorge et al. (2020) desarrollaron un nuevo enfoque híbrido que emplea un método validado clínicamente llamado oBPM para preprocesar las señales fotopletimográficas (PPG) y extraer características fisiológicas para la estimación de la presión arterial. Reportaron que la base de datos que utilizaron incluyó 40 sujetos adultos sometidos a cirugía, las formas de onda de la señal PPG sin procesar fueron registradas por medio de un sensor comercial con un tiempo de medición entre 9 y 19 minutos, las señales PPG las segmentaron con un tiempo de 20 segundos con 83 características, el 70 % de los datos los utilizaron para entrenamiento y el 30 % para prueba. Reportaron que en este estudio utilizaron diferentes enfoques como linear regression, Lasso regularized linear regression, random forest regression, Gaussian process regression y support vector regression, para extraer las características más relevantes de la señal PPG. Reportaron que el algoritmo Gaussian process regression obtuvo un error promedio de 0.13 mmHg con características para entrenamiento y un error promedio de -1.98

mmHg con características para prueba, utilizando validación cruzada y los datos demográficos de los sujetos en ambos casos.

Sannino et al. (2020) analizaron un amplio conjunto de algoritmos de aprendizaje automático con base en diferentes mecanismos de aprendizaje para estimar la presión arterial a través de la señal fotoplethysmográfica (PPG) y compararon sus resultados en cuanto a la eficacia de la clasificación obtenida. Encontraron que no hay trabajos previos que hagan una revisión exhaustiva de los métodos de aprendizaje automático para la clasificación no invasiva y evaluación de los niveles de la hipertensión. Reportaron que utilizaron la base de datos MIMIC II que contiene un registro de formas de onda de la señal PPG, los datos fisiológicos los recolectaron por medio de sensores conectados a un monitor de señales vitales, utilizaron los registros de 12000 pacientes, utilizaron 625 muestras de la señal PPG y las dividieron en segmentos de 5 segundos. Algunos de los algoritmos que investigaron en este estudio fueron redes bayesianas, support vector machines, k nearest neighbors, adaboost, decision tree y random forest entre otros. Reportaron que dichos algoritmos obtuvieron precisiones de 65.94%, 67.20%, 97.92% y 100%. Señalaron que todos los algoritmos investigados tuvieron la capacidad de discriminación más alta entre los eventos normotensos y los hipertensos. Concluyeron que el algoritmo Random Forest tuvo el mejor desempeño en cuanto a precisión, sensibilidad y puntaje F en comparación con otros algoritmos.

Tjahjadi et al. (2020) propusieron un método para la clasificación de la presión arterial con base en la fotoplethysmografía (PPG). Encontraron que los métodos de aprendizaje profundo no tienen buena precisión en tareas de clasificación y su etapa entrenamiento es demasiado larga. Reportaron que utilizaron los datos de 121 sujetos con un rango de edades entre 21 y 86 años, recolectaron 870 registros de datos a partir de la base de datos Figshare PPG-BP, con un tiempo de medición de 15 minutos, la señal PPG la dividieron en segmentos de 2100 muestras cada segmento con una duración de 2.1 segundos. Propusieron utilizar el algoritmo k nearest neighbors, este método es uno de los algoritmos más sencillos y se utiliza principalmente para tareas de clasificación. Reportaron que el método que propusieron obtuvo una precisión de 86.7% en comparación con otros métodos de clasificación, por lo tanto, dicho método es adecuado para aplicarse a datos no lineales como las señales PPG. Concluyeron que el algoritmo K nearest neighbors no requiere de una señal PPG de alta

calidad ni de la extracción de sus características morfológicas, por lo tanto, este método es aplicado fácilmente en muchas situaciones.

Thambiraj et al. (2020) presentaron un método que extrae características informativas como el número de Womersley a partir de las señales, electrocardiográfica (ECG) y fotopletomográfica (PPG) para el monitoreo de la presión arterial continua. Encontraron que una nueva investigación en aprendizaje automático es la creación de características las cuales reflejan varios fenómenos fisiológicos como el número de Womersley que es una característica que refleja las propiedades del flujo de la sangre y por lo tanto influye en la presión arterial. Reportaron que utilizaron la base de datos MIMIC II con un total de 3801 datos y 1000 muestras de formas de onda con 43 características, el 80% de los datos los utilizaron para entrenamiento y 20 % para prueba. Los algoritmos que utilizaron para la extracción de características fueron linear regression, support vector regression, adaboost regression, random forest regression y algoritmos genéticos. Reportaron que el mejor desempeño lo obtuvieron con la combinación de Random Forest y un algoritmo genético con los que obtuvieron un error promedio de 9.54 mmHg para la presión sistólica y un error promedio de 5.48 mmHg para la presión diastólica. Concluyeron que este estudio exploró el efecto de la alteración hemodinámica sobre la presión arterial junto con las características de la señal de pulso que mejoraron la robustez del modelo y llevó a una estimación confiable de la presión arterial.

Fati et al. (2021) construyeron un modelo automatizado de aprendizaje automático utilizando una herramienta de optimización de tuberías inspirada en árboles, a partir de las señales fotopletomográficas (PPG) para la estimación de la presión arterial. Señalaron que por medio del empleo de esta herramienta de optimización se automatizan los pasos de extracción de características y seleccionar el clasificador de aprendizaje automático adecuado. Reportaron que utilizaron la base de datos PhysioNet la cual contiene registros de 1000 sujetos, utilizaron en total 64115 muestras de formas de onda, el 60 % de los datos los utilizaron para entrenamiento y 40 % para validación. Reportaron que utilizaron para este estudio los algoritmos, random forest y k nearest neighbors para automatizar la extracción de características de la señal PPG. Reportaron que el modelo que propusieron obtuvo un error promedio absoluto de 6.52 mmHg para la presión sistólica y un error promedio absoluto de

4.19 mmHg para la presión diastólica. Concluyeron que con el desarrollo de modelos de aprendizaje automático se hace una evaluación en tiempo real y se proporciona una atención oportuna y precisa con base en la salud del sujeto.

Lin et al. (2021) investigaron más afondo el problema de la estimación de la presión arterial continua sin brazalete neumático a partir de la señal fotopletismográfica (PPG) y el impacto que tienen las diferentes características de la señal PPG sobre los resultados. Encontraron que los enfoques con base solo en las características de la señal PPG sin el tiempo de llegada del pulso (PAT) tienen un pobre desempeño en términos de la precisión de los valores estimados de la presión arterial. Reportaron que utilizaron los registros de 109 pacientes a partir de las bases de datos MIMIC II y MIMIC III que contienen registros de formas de onda de la señal PPG de la que utilizaron 65 características, también utilizaron 729 mil valores de la presión arterial, utilizaron validación cruzada para evaluar la efectividad de las características seleccionadas, el 75 % de los datos los utilizaron para entrenamiento y el 25 % restante para prueba. Reportaron que utilizaron el algoritmo multiple linear regression para la estimación de la presión arterial, por otra parte, para poder incrementar la utilidad del algoritmo desarrollaron un método de selección de características para escoger el subconjunto de características de la señal PPG más representativo, esto para reducir el error de estimación. Reportaron que los resultados obtenidos mostraron un error promedio absoluto de 4.59 mmHg para la presión sistólica y un error promedio absoluto de 2.47 mmHg para la presión diastólica. Señalaron que el método que propusieron es prometedor para su aplicación práctica y proporcionan una forma conveniente de estimar la presión arterial continua sin brazalete neumático con una precisión comparable. Concluyeron que el método que propusieron facilitará potencialmente el desarrollo de dispositivos portátiles capaces de monitorear la presión arterial de manera continua fuera de los entornos clínicos.

En la Tabla 2.3 se presenta un análisis comparativo de los trabajos relacionados con la medición y monitoreo de la presión arterial por medio de fotopletismografía, así como las tecnologías y algoritmos de clasificación dentro del área de Machine Learning, que fueron implementados, dentro de los algoritmos que utilizaron se encuentran: Support Vector Machine, Random Forest, Decision Tree, Multiple Linear Regression, Regression Tree, Algoritmos Genéticos, Support Vector Regression, Regresión Lineal, K nearest neighbors,

Gaussian Process Regression y Random Forest Regression. Como parte de las tecnologías que utilizaron se encuentra el uso de un monitor de signos vitales, utilizaron el software Matlab para el procesamiento de los datos, también se muestra el uso de las bases de datos MIMIC, MIMIC-II, MIMIC-III que son bases de datos de acceso público, sensores de pulso, dispositivos programables como FPGA's, sensores PPG, también utilizaron la base de datos Figshare PPG BP. En cuanto a los resultados reportados se muestra que en la mayoría de los artículos los algoritmos que tuvieron mejor desempeño fueron: Regression Tree, K nearest neighbors, Gaussian Process Regression y Random Forest.

Tabla 2.3 Análisis comparativo de los trabajos que utilizan algoritmos de clasificación.

Artículo	Contribución	Tecnologías	Resultados
Khalid et al. (2018)	Estimación de presión arterial normotensiva, hipertensiva e hipotensiva.	Multiple linear regression, Support Vector Machine, Regression Tree, Monitor de signos vitales.	Regression Tree tuvo mejor desempeño en presión normotensiva, no incluyeron datos demográficos.
Slapnicar et al. (2018)	Extracción de características PPG con módulo de preprocesamiento y módulo ML.	Regression Tree, RReliefF, Matlab, MIMIC	Regression Tree tuvo mejor desempeño de 80 % de personalización de los datos.
Chen et al. (2019)	Extracción de características PPG y estimación de presión arterial con algoritmos de ML.	Sensores de pulso, Support Vector Regression, Algoritmo Genético, MIMIC-III	Este método mejoró la precisión de predicción de presión arterial continua, no invasiva.
Jung et al. (2019)	Estimación de presión arterial a través de PPG con método de aprendizaje semi supervisado.	FPGA, Método PTT, Regresión lineal, Método de aprendizaje por mapas	Con este método y los datos demográficos obtuvieron una precisión más alta en la estimación de presión arterial.
Yi et al. (2019)	Medición de presión arterial continua a través de PPG con algoritmos de ML	Linear regression, K nearest neighbors, Regression Tree, MIMIC	K nearest neighbors superó a los métodos tradicionales de medición de presión arterial.
Chowdhury et al. (2020)	Medición de presión arterial a través de PPG con algoritmos de Deep learning.	Regression Tree, Support vector regression, Gaussian process regression	Gaussian process regression tuvo mejor desempeño debido a características PPG seleccionadas con datos demográficos.
Jorge et al. (2020)	Estimación de presión arterial a partir de características PPG con algoritmos de ML.	Random forest regression, Gaussian process regression, SVR, Sensor PPG	Gaussian process regression extrajo características relevantes del PPG para estimación de presión arterial.
Sannino et al. (2020)	Estimación de presión arterial y clasificación de niveles de hipertensión a través de PPG con algoritmos de ML.	SVM, K nearest neighbors, Decision tree, Random forest, MIMIC-II, Monitor de señales vitales	Random Forest tuvo el mejor desempeño en precisión y sensibilidad en comparación con otros algoritmos.
Tjahjadi y Ramli (2020)	Estimación de presión arterial con el algoritmo K nearest neighbors ya que se utiliza principalmente en tareas de clasificación.	K nearest neighbors, Figshare PPG-BP	K nearest neighbors tuvo una precisión de 86.7 % superando a otros métodos de clasificación y es adecuado para datos no lineales como las señales PPG.
Thambiraj et al. (2020)	Extracción de características fisiológicas ECG y PPG para estimar la presión arterial continua con algoritmos de ML.	No. de Womersley, SVR, RFR, Algoritmos genéticos, MIMIC-II	Random forest y algoritmos genéticos demostraron los efectos de características fisiológicas sobre la presión arterial obteniendo una estimación de manera confiable.
Fati et al. (2021)	Optimización de extracción de características PPG con un modelo automatizado de ML.	Random Forest, K nearest neighbors, PhysioNet	Este modelo pudo evaluar en tiempo real la presión arterial de manera oportuna y precisa.
Lin et al. (2021)	Estimación de presión arterial continua, sin brazalete neumático con el algoritmo multiple linear regression.	MLR, MIMIC-II, MIMIC-III	Este método facilitará potencialmente el desarrollo de dispositivos portátiles para monitorear la presión arterial continua fuera de entornos clínicos.

2.3 Redes Neuronales Artificiales con Algoritmos de Clasificación.

En esta sección se presenta un análisis de los algoritmos de clasificación en combinación con redes neuronales artificiales para la estimación de la presión arterial por medio de métodos no invasivos utilizando fotopletimografía.

Attarpour et al. (2019) propusieron el registro simultáneo de la señal fotopletimográfica (PPG) a partir de la yema del dedo y la muñeca para el monitoreo continuo de la presión arterial. Encontraron que actualmente la técnica oscilométrica con base en el brazalete neumático es la más comúnmente utilizada para monitorear la presión arterial, sin embargo, esta técnica es discontinua e inconveniente para mediciones repetidas. El modelo que propusieron utiliza redes neuronales artificiales y un algoritmo genético para evaluar las 38 características extraídas de la señal PPG, para estimar la presión arterial de manera precisa. Señalaron que utilizaron el algoritmo Levenberg-Marquart para entrenar la red neuronal, también utilizaron un sistema diseñado con dos sensores infrarrojos uno posicionado en la muñeca y el otro en el dedo índice para la adquisición de la señal PPG, para este estudio utilizaron 111 sujetos entre hombres y mujeres con edades de alrededor de 30 años, para un tiempo de medición de 2 minutos, de las 111 muestras utilizaron 1 para datos de prueba, 88 para entrenamiento y 22 para validación. Reportaron que el algoritmo genético obtuvo el error promedio absoluto más bajo de 4.94 mmHg para la presión sistólica y un error promedio absoluto de 4.03 mmHg para la presión diastólica.

Eom et al. (2020) desarrollaron un modelo de aprendizaje profundo para la estimación de la presión sanguínea sin la extracción de características y utilizaron las señales, electrocardiográfica (ECG), fotopletimográfica (PPG) y balistocardiográfica (BCG). Encontraron que la presión sanguínea es estimada utilizando únicamente señales en bruto con el mínimo de preprocesamiento y que el tiempo de tránsito del pulso (PPT) es monitoreado a largo plazo a partir de la señal ECG y PPG debido a que dichas señales son medidas de manera no invasiva y no requiere de la experiencia de un médico o un brazalete neumático. Reportaron que utilizaron 15 sujetos entre hombres y mujeres de alrededor de 20 años, hicieron la adquisición de las señales ECG por medio de un módulo BIOPAC ECG100C y la señal PPG la midieron en el dedo índice de cada sujeto con un módulo PSL-iPPG2C, con un tiempo de medición de 30 minutos y utilizaron 128 características de las señales. El método que propusieron consta de una red neuronal convolucional para extraer los patrones clave de la señal de entrada de manera automática, también utilizaron un método llamado unidad recurrente de compuerta bidireccional para utilizar la información de características futuras y pasadas, por último, utilizaron el mecanismo de atención cuyo objetivo es que el modelo propuesto aprenda centrándose en una región de interés. Señalaron

que el tamaño de la muestra fue alrededor de 26 millones de formas de onda con segmentos de 5 segundos y que el 70 % de los datos los utilizaron para entrenamiento, 10 % para validación y 20 % para prueba. Reportaron que obtuvieron un error promedio absoluto de 4.06 mmHg para la presión sistólica y un error promedio absoluto de 3.33 mmHg para la presión diastólica.

Kilickaya et al. (2020) implementaron algoritmos de aprendizaje automático utilizando señales fotopletomográficas (PPG) y algunas características personales como el índice de masa corporal, edad, altura y peso, con el objetivo de estimar la presión arterial sin el uso de un brazalete neumático. Reportaron que utilizaron la base de datos de la universidad Guilin la cual contiene 657 segmentos de formas de onda adquiridos de 219 sujetos con un rango de edades entre 21 y 86 años, con un tiempo de medición de 3 minutos por sujeto, cada uno de los segmentos con un tiempo de duración de 2.1 segundos y utilizaron 5 características de la señal PPG. Los algoritmos de aprendizaje automático que utilizaron fueron linear regression, support vector regression y artificial neural networks. Reportaron que utilizaron validación cruzada para evaluar cada uno de los modelos de aprendizaje automático, el mejor desempeño lo obtuvieron con support vector regression obteniendo un error promedio absoluto de 13.57 mmHg para la presión sistólica y un error promedio absoluto de 8.30 mmHg para la presión diastólica. Concluyeron que, es necesario reducir el error promedio absoluto a 5 mmHg para que pueda utilizarse en aplicaciones médicas.

Sadrawi et al. (2020) investigaron la habilidad de un autocodificador convolucional profundo para estimar la presión arterial continua, utilizando solamente la señal fotopletomográfica (PPG). Reportaron que utilizaron un conjunto de datos de 18 pacientes que adquirieron por medio de un monitor de signos vitales MP60, en total utilizaron 36516 secuencias de datos con un tiempo de medición de 5 segundos, el 85 % de los datos los utilizaron para entrenamiento y 15 % para prueba. Señalaron que evaluaron dos modelos de autocodificadores convolucionales profundos, el primero lo generaron con base en un modelo de red neuronal convolucional llamado LeNet-5, el segundo modelo fue un autocodificador convolucional profundo inspirado en una arquitectura llamada U-Net, para la generalización de los datos utilizaron el método de validación cruzada, por último utilizaron un algoritmo genético llamado autocodificador convolucional profundo genético con el que ensamblaron

los modelos de los autocodificadores LeNet y U-Net. Reportaron que el autocodificador U-Net mostró resultados superiores en la estimación de la presión arterial sistólica, por su parte el autocodificador LeNet les dio un resultado ligeramente mejor para la estimación de la presión arterial diastólica, sin embargo, el autocodificador convolucional profundo genético superó a los dos anteriores obteniendo un error promedio absoluto de 2.54 mmHg para la presión sistólica y un error promedio absoluto de 1.48 mmHg para la presión diastólica.

Aguirre et al. (2021) desarrollaron un método sin brazalete neumático para estimar la morfología del promedio del pulso de la presión arterial a partir de la señal fotopletomográfica (PPG). Encontraron que desafortunadamente el enfoque de tiempo de tránsito del pulso (PTT) no se aplica directamente a la morfología de la señal PPG. Reportaron que utilizaron la base de datos MIMIC III con registros de 1131 sujetos con un rango de edades entre 18 y 89 años. En este estudio utilizaron una arquitectura de aprendizaje profundo que consistió de una red neuronal recurrente codificadora-decodificadora con un mecanismo de atención. Reportaron que el modelo que propusieron obtuvo un error promedio absoluto de 14.39 mmHg para la presión sistólica y de 6.57 mmHg para la presión diastólica sin calibración, por otra parte, obtuvieron un error promedio absoluto de 12.08 mmHg para la presión sistólica y de 5.56 mmHg para la presión diastólica con calibración. Señalaron que las condiciones preexistentes de los sujetos como diabetes, enfermedad renal crónica, tabaquismo y dislipidemia también son consideradas.

Munir et al. (2021) discuten un método para estimar la presión arterial utilizando solamente la señal fotopletomográfica (PPG). Encontraron que los métodos de tiempo de tránsito de pulso (PTT) y la PPG son técnicas comúnmente utilizadas, sin embargo, para medir el PTT se necesitan de dos parámetros el electrocardiograma (ECG) y el (PPG). Reportaron que utilizaron la base de datos MIMIC con registros de datos de 72 pacientes con un tiempo de medición entre 20 y 40 horas, utilizaron 58795 intervalos de señales PPG, el 70 % de los datos los utilizaron para entrenamiento, 15 % para validación y el 15 % restante para prueba. Reportaron que utilizaron en este estudio un modelo llamado multitaper para la extracción de características de la señal PPG y una red neuronal artificial para la aproximación de la presión arterial, dicha red neuronal utilizó 22 parámetros de entrada. Reportaron que el modelo que propusieron obtuvo un error promedio absoluto de 4.02 mmHg para la presión

sistólica y un error promedio absoluto de 2.27 mmHg para la presión diastólica. Concluyeron que el modelo que propusieron tiene grandes implicaciones como parte de un enfoque de datos masivos sobre todo a medida que el sensor PPG integrado se vuelve cada vez más popular.

Mejía-Mejía et al. (2021) evaluaron la capacidad de las características extraídas a partir de la fotopletomografía (PPG) con base en la variabilidad de la frecuencia del pulso para clasificar los eventos hipertensivos, normotensos e hipotensivos y estimar la presión arterial promedio en pacientes críticos. Reportaron que utilizaron la base de datos MIMIC II con un conjunto de datos de 500 registros, utilizaron características del dominio del tiempo, del dominio de la frecuencia y no lineales, utilizaron 4937 segmentos de la señal PPG con un tiempo de medición de 5 segundos, utilizaron validación cruzada para identificar la mejor combinación de características. Reportaron que utilizaron regresive support vector machines y redes neuronales de ajuste de funciones para la estimación de la presión arterial. Reportaron que el modelo que propusieron obtuvo un error promedio absoluto de 4.74 mmHg para la presión sistólica y un error promedio absoluto de 1.78 mmHg para la presión diastólica. Señalaron que la variabilidad de la frecuencia del pulso es una herramienta que evalúa los cambios en la presión arterial utilizando solamente señales PPG.

Maqsood et al. (2021) realizaron un análisis completo de técnicas de extracción de características para la estimación de la presión arterial utilizando señales fotopletomográficas (PPG). Encontraron que la PPG es una técnica no invasiva, sencilla y de bajo costo que es utilizada para medir el volumen de la sangre y otros parámetros significativos relacionados con enfermedades cardiovasculares. Reportaron que utilizaron dos bases de datos en este estudio la primera fue MIMIC II la cual contiene registros de señales ECG y PPG, las señales las dividieron en segmentos de 30 segundos y la segunda base de datos fue PPG-BP la cual contiene registros recolectados de 219 pacientes con un rango de edades entre 21 y 86 años. Señalaron que las técnicas de extracción de características las dividieron en tres subgrupos para analizar la importancia de cada grupo, el grupo A incluyó las características con base en el dominio del tiempo, el grupo B presentó la extracción de características estadísticas y el grupo C presentó las características con base en el dominio de la frecuencia, dicho análisis empleó algoritmos de aprendizaje automático

como linear regression, random forest, Adaboost, support vector machines, memoria a corto plazo (LSTM), Bidirectional LSTM (BiLSTM) y unidades recurrentes de compuerta (GRU). Reportaron que el algoritmo GRU obtuvo el mejor desempeño con un error promedio absoluto de 3.68 mmHg para la presión sistólica y el algoritmo BiLSTM obtuvo el mejor desempeño con un error promedio absoluto de 4.18 mmHg para la presión diastólica, utilizando la base de datos PPG-BP con 21 características de la señal PPG incluyendo los datos demográficos de los sujetos. Concluyeron que los algoritmos de Deep learning con características en el dominio del tiempo obtuvieron el mejor rendimiento con menor error en la estimación de la presión arterial.

Pandey et al. (2021) diseñaron un sistema de adquisición de señales fotopletimográficas (PPG) para medir la presión arterial continua de larga duración y en tiempo real. Encontraron que, aunque varios métodos demuestran que la señal PPG es suficiente para la medición de la presión arterial, la implementación de esos métodos de circuitos y sistemas requiere de muchos cambios especialmente con el sistema de adquisición de señales PPG. Reportaron que utilizaron el algoritmo principal component análisis (PCA) para la extracción de 14 características a partir de las señales PPG que obtuvieron de 96 sujetos con un rango de edades entre 21 y 48 años y una arquitectura de redes neuronales para la estimación de la presión arterial, dicha arquitectura consistió de una capa de entrada con 5 nodos, dos capas ocultas con 32 nodos cada una y 2 nodos de salida para la presión sistólica y diastólica, el 90 % de los datos los utilizaron para entrenamiento y el 10 % restante para prueba. Reportaron que el modelo que propusieron obtuvo un error promedio cuadrático de 2.00 mmHg para la presión sistólica y un error promedio cuadrático de 1.87 mmHg para la presión diastólica.

Yang et al. (2021) analizaron varias características con base en la morfología de la señal fotopletimográfica (PPG) a partir de bioseñales quirúrgicas para determinar los marcadores válidos de la presión arterial, construyeron y evaluaron modelos de la estimación de la presión arterial, además, utilizaron estas características con el tiempo de llegada del pulso (PAT). Encontraron que hay una relación entre la presión arterial y el PAT, sin embargo, el PAT como único predictor con una calibración simple no mostró un buen rendimiento en la estimación de la presión sistólica. Reportaron que utilizaron la base de datos VitalDB la cual contiene registros de formas de onda ECG y PPG de 1376 pacientes con rangos de edades

entre 8 y 92 años, utilizaron 42 características de la señal PPG. Reportaron que utilizaron linear regression, random forest, artificial neural networks y recurrent neural networks, los cuales obtuvieron un error promedio cuadrático de 6.92 mmHg para la presión sistólica y un error promedio cuadrático de 3.99 mmHg para la presión diastólica. Señalaron que este estudio utilizó un gran conjunto de datos heterogéneos para validar el potencial de las características morfológicas del PPG como predictores de la presión arterial. Concluyeron que varias características morfológicas de la señal PPG superaron al PAT como predictor de la presión arterial, el modelado de los componentes de baja y alta frecuencia de la presión arterial mejora el rendimiento de la estimación y que los modelos de regresión no lineal con base en redes neuronales artificiales y recurrentes mejora el rendimiento de la estimación en comparación con la regresión lineal.

Yin et al. (2021) presentaron un método de medición de la presión arterial continua sin brazalete neumático inspirado en múltiples tipos de fusión de información. Encontraron que la presión arterial de una persona no solamente está relacionada con el tiempo de tránsito del pulso (PTT) y con los parámetros de la forma de onda del pulso (PWP's), sino que también es afectada por los parámetros de características personales (PCP's) como la altura, peso, edad y género. Reportaron que utilizaron un sistema de adquisición de datos de diseño propio, recolectaron los datos de 186 sujetos con un rango de edades entre 18 y 72 años, con un tiempo de medición de 10 segundos y 14 parámetros de entrada. Reportaron que utilizaron backpropagation neural network como herramienta de modelado la cual se encargó de extraer las características de las señales PPG y ECG y después aplicaron el método de fusión de información de múltiples tipos para la estimación de la presión arterial de manera precisa. Reportaron que el modelo que propusieron obtuvo un error cuadrático promedio de 1.5 mmHg para la presión sistólica y un error cuadrático promedio de 0.9 mmHg para la presión diastólica. Señalaron que las restricciones del objeto medido son consideradas totalmente para obtener un modelo más preciso y estable. Concluyeron que incluyendo las características personales de los sujetos durante el modelado mejoran significativamente el modelo de predicción de la presión arterial.

En la Tabla 2.4 se presenta un análisis comparativo de los trabajos relacionados con la medición y monitoreo de la presión arterial por medio de fotoplethysmografía, así como las tecnologías y algoritmos de clasificación combinados con redes neuronales.

Tabla 2.4 Análisis comparativo de los trabajos que utilizan algoritmos de clasificación en combinación con redes neuronales.

Artículo	Contribución	Tecnologías	Resultados
Attarpour et al. (2019)	Estimación de presión arterial en dedo y muñeca a través de PPG con redes neuronales y algoritmo genético.	Sensores infrarrojos, ANN, Algoritmo Genético	Este método sustituye al método oscilométrico, no requiere calibración, monitorea presión arterial de manera continua sin brazaletes neumáticos.
Kilickaya et al. (2020)	Estimación de presión arterial sin brazaletes neumáticos con algoritmos de ML	Líneaar regression, Support vector regression, ANN	support vector regression tuvo el mejor desempeño con características demográficas, pero necesita más pruebas para usarse en aplicaciones médicas.
Sadrawi et al. (2020)	Estimación de presión arterial continua, a través de PPG con 2 CNN y un algoritmo genético	LeNet, U-Net, Algoritmo genético, Monitor de signos vitales	Este algoritmo genético superó con éxito a los otros dos y estimó la presión arterial continua, utilizando solo PPG.
Aguirre et al. (2021)	Estimación de presión arterial a partir de la morfología PPG con aprendizaje profundo.	RNN, Mecanismo de atención, MIMIC-III	Este modelo permite utilizar la información simultánea del PPG sin procesar y los datos demográficos.
Munir et al. (2021)	extracción de características PPG con el método multitaper y una ANN para estimar la presión arterial.	Método multitaper, ANN, MIMIC, Sensor PPG	Este modelo es prometedor para la estimación de presión arterial por su capacidad de recolección de datos masivos.
Mejía-Mejía et al. (2021)	Clasificación de presión arterial a partir de las características PPG con algoritmos de ML.	Regressive support vector machines, ANN, MIMIC-II	Este método es una herramienta útil para el monitoreo continuo, no invasivo de ECV debido a la presencia de eventos hipertensos.
Maqsood et al. (2021)	extracción de características PPG para estimar la presión arterial con algoritmos de ML.	Random forest, SVM, BiLSTM, GRU, MIMIC-II, PPG-BP	Los algoritmos GRU y BiLSTM obtuvieron el menor error en la estimación de presión arterial.
Pandey et al. (2021)	Extracción de características PPG y medición de presión arterial continua en tiempo real con algoritmos de ML.	PCA, ANN	Este modelo mostró un rendimiento satisfactorio en la medición de presión arterial continua en tiempo real.
Yang et al. (2021)	Estimación de presión arterial a partir de características morfológicas PPG con algoritmos de ML.	Linear regression, Random forest, ANN, RNN, VitalDB	Dichos algoritmos evaluaron el potencial de las características morfológicas PPG en la predicción de presión arterial.
Yin et al. (2021)	Medición precisa de presión arterial a través del PPG con red neuronal y el método de fusión de múltiple información.	ANN, Método de fusión de múltiple información	Este modelo obtuvo un buen desempeño e incluyendo los datos demográficos se mejoraría la predicción de presión arterial.
Tesis Doctoral	Utilizar información más precisa de la señal PPG para entrenar algoritmos de aprendizaje automático y poder obtener una estimación más precisa de la presión arterial no invasiva a través de las yemas de los dedos, con el objetivo de determinar el riesgo de hipertensión y su correlación con arteriosclerosis.	Tarjeta de adquisición de señales cardiacas Max 86150 certificada por la FDA, Bases de datos propia y de acceso público, Algoritmos de aprendizaje automático.	Nuestro modelo obtuvo una precisión del 95 % en la predicción de la presión arterial. Por otra parte se obtuvo un 99.57 % en la precisión de la predicción del riesgo de hipertensión y su correlación con arteriosclerosis, utilizando únicamente algoritmos de regresión clásicos y de tipo ensamble. Sin embargo se requieren más pruebas con una base de datos más amplia.

En la Tabla 2.4 se muestra que las tecnologías que utilizaron fueron: sensores infrarrojos, monitores de signos vitales, también utilizaron la base de datos MIMIC que es una base de datos de acceso público, sensores PPG y la base de datos Vital DB. En cuanto a los resultados reportados se muestra que de acuerdo con los artículos analizados en esta sección, los algoritmos que tuvieron mejor desempeño fueron: Redes neuronales profundas, algoritmos genéticos y Random Forest.

Con este análisis se pudo obtener un conocimiento más amplio sobre las tecnologías y metodologías utilizadas en la medición y monitoreo de la presión arterial por medio de fotoplethysmografía (PPG). Se pudo observar que es importante realizar el preprocesamiento de las señales PPG para obtener señales de buena calidad que permitan obtener las características necesarias de la forma de onda de la señal para estimar la presión arterial con alta precisión con ayuda de algoritmos de inteligencia artificial. Sin embargo, también se observó que es realizada la estimación de la presión arterial con señales PPG sin procesar y se obtiene una estimación con buena precisión, además, al incluir las características personales de los sujetos de prueba como edad, género, peso, estatura, etc., para entrenar los algoritmos de inteligencia artificial, es posible incrementar la precisión de estimación de los algoritmos. En cuanto al desempeño de los algoritmos de inteligencia artificial los trabajos de investigación analizados reportaron que los algoritmos de Deep Learning específicamente redes neuronales convolucionales (CNN) son los más utilizados para tareas de procesamiento de señales y que los algoritmos de clasificación como Random Forest, Decision Tree, Regression Tree, K nearest neighbors, Gaussian Process Regression y Support Vector Machine tienen el mejor desempeño en la predicción de la estimación de la presión arterial, esta información será de gran apoyo para el desarrollo de esta Tesis Doctoral.

CAPÍTULO 3. METODOLOGÍA

En este capítulo se describen las etapas de la metodología de investigación utilizada para el desarrollo de esta tesis doctoral. Dicha metodología tiene su base en el método científico inductivo-deductivo, y está formada por 4 etapas: 1) análisis, 2) diseño, 3) desarrollo y 4) pruebas. Las 4 etapas mencionadas conducen al objetivo de obtener nueva información sobre el estado de salud y características del sistema arterial por medio de técnicas de pletismografía mediante un método no invasivo en la porción distal de las extremidades superiores.

3.1 Etapas de la Metodología de Investigación

En esta sección se presentan las etapas de la metodología de investigación utilizada para el desarrollo de esta tesis doctoral. En la Figura 3.1 se describen las etapas de la metodología de investigación incluyendo las actividades realizadas en cada etapa.




Figura 3.1 Metodología de la Investigación.

Análisis. En esta etapa inicialmente se realizó la búsqueda de la literatura donde se describe con detalle cómo funciona el sistema circulatorio y cómo se comporta el flujo sanguíneo del cuerpo humano a través de las arterias, esto para poder entender cómo se genera una señal pletismográfica. Por otra parte, se revisó la literatura sobre las diferentes técnicas de medición de la presión arterial por medio de métodos no invasivos como la fotopletismografía (PPG). De acuerdo con la literatura la técnica PPG es uno de los métodos más utilizados para medir la presión arterial de manera no invasiva, la cual consiste en hacer incidir un haz de luz sobre las arterias del área donde se desea realizar la medición de la presión arterial dicha medición se realiza en diferentes partes del cuerpo humano como la muñeca, el lóbulo de la oreja, los dedos de los pies y los dedos de las manos. En esta tesis doctoral se optó por obtener la señal PPG a partir de las yemas de los dedos de las manos. También se analizaron los algoritmos de aprendizaje automático más adecuados para la medición y monitoreo de la presión arterial, de acuerdo con la literatura revisada se recomienda el uso de algoritmos de Deep Learning como las redes neuronales convolucionales (CNN) ya que se utilizan para la predicción de arritmias y para tareas de procesamiento de señales, tal es el caso de este tema de investigación ya que se requiere realizar la adquisición de señales PPG de buena calidad que permitan obtener información más precisa sobre sus características morfológicas. Por otra parte, la literatura también recomienda el uso de algoritmos de Machine Learning como K – Nearest Neighbors, Support Vector Machine, Lineal Regression y Random Forest ya que estos algoritmos presentan el mejor desempeño en la predicción de la estimación de la presión arterial de manera más precisa.

Diseño. Para esta etapa se compró una tarjeta de adquisición de señales biomédicas certificada por la FDA (Food and Drug Administration) de Estados Unidos, como apoyo para el diseño de experimentos, que tiene el objetivo de obtener señales cardíacas a partir de las yemas de los dedos, dicha tarjeta lleva integrado un módulo sensor para adquisición de señales PPG y un par de electrodos secos de inox para adquisición de señales ECG, dichas señales son adquiridas de manera simultánea o por separado. Por otra parte, se diseñó el modelo de aprendizaje automático, dicho modelo contiene las fases de proceso para la implementación del algoritmo o los algoritmos que darán solución, al problema planteado en esta Tesis Doctoral.

Implementación. En esta etapa se implementó la metodología para el procesamiento de la señal PPG, la estimación de la presión arterial y la detección de alguna enfermedad cardiovascular. Por otra parte, también se implementará el modelo de trabajo de aprendizaje automático donde se define el algoritmo o los algoritmos que serán utilizados para el procesamiento de la señal fotopletimográfica, la estimación de la presión arterial y la detección de alguna enfermedad cardiovascular.

Pruebas. En esta etapa se evaluarán y validarán los resultados obtenidos sobre el desempeño de los algoritmos de aprendizaje automático con ayuda de expertos en el área de la salud, a través de por lo menos un caso de estudio.

3.2 Etapa de Análisis

Tal como se mencionó en el capítulo 1 sección 1.1 usualmente la circulación de la sangre a través del cuerpo humano es comparada con una red de tuberías, tomando a las venas, arterias y capilares como los tubos por los que fluye la sangre y al corazón como si fuera una bomba. La comparación de la circulación de la sangre con una red de tuberías no es completamente correcta debido a que la sangre tiene células que cambian el flujo sanguíneo, en particular cuando las paredes de las arterias se reducen, estas características son las que la hacen diferente de un simple fluido. Por otra parte, las venas y las arterias son conductos elásticos y las fuerzas aplicadas por el fluido sobre dichos conductos cambian su forma. Sin embargo, se utilizan los métodos empleados en el análisis de fluidos simples que viajan a través de tubos rígidos para hacer un análisis del sistema circulatorio con cierta precisión. La duración del ciclo cardíaco está formada por un periodo de relajación llamado diástole seguido de un periodo de contracción llamado sístole. Cuando el ventrículo izquierdo se encuentra relajado se inicia el periodo sistólico con una contracción que no presenta variación de volumen, sin embargo, la presión dentro del ventrículo se encuentra por debajo de la presión de la aorta por lo que la válvula de dicha arteria permanece cerrada. Cuando la presión del ventrículo se encuentra al mismo nivel que la presión de la aorta la válvula se abre y se inicia el periodo de eyección, al terminar dicho periodo el volumen de sangre del ventrículo llega a su valor mínimo conocido como volumen telesistólico, luego entonces la válvula de la aorta se cierra

e inicia el periodo de relajación sin cambios de volumen. Finalmente, al bajar la presión de la aurícula, la presión del ventrículo desciende debido a su periodo de relajación e inicia el periodo de llenado en el ventrículo debido a la apertura de la válvula mitral.

De acuerdo con la sección 1.2 la contracción de los ventrículos es provocada por impulsos eléctricos que son aplicados a los lados izquierdo y derecho del corazón al mismo tiempo. El bombeo del corazón hace que la sangre viaje a través de las arterias en forma de chorros o pulsos.

La presión sanguínea se define como la fuerza aplicada por unidad de área que la sangre aplica sobre las paredes de las arterias en un momento determinado. Como se mencionó anteriormente el valor máximo de la presión arterial presente en un pulso cardiaco es conocido como presión sistólica y el valor mínimo de la presión arterial es conocido como presión diastólica. En condiciones normales la presión sistólica es de 120 mmHg mientras que la diastólica es de 80 mmHg y se expresa como 120/80. Por lo tanto, la presión arterial media es de 100 mmHg.

En la sección 1.8 se menciona que las presiones sanguíneas que rebasan los límites superiores, así como las que rebasan los límites inferiores sugieren trastornos del organismo que necesitan atención médica, debido a esto la presión arterial es un indicador importante de la salud de una persona. Las constricciones que provocan la presión arterial alta en el sistema circulatorio, indican que el corazón está haciendo un sobre esfuerzo y se presenta un riesgo por el exceso de carga.

Se han realizado diferentes métodos de medición de la presión arterial, estos métodos utilizan las leyes físicas de la circulación sanguínea, para establecer la presión arterial en el sistema vascular. Hay dos tipos de sistemas de medición, la medición directa o invasiva en la que se introduce un catéter en un vaso sanguíneo, este catéter tiene un transductor de presión que convierte las variaciones de presión sanguínea en señales eléctricas que se amplifican y acondicionan.

Estos métodos representan un riesgo alto para los pacientes, pero tienen la ventaja de que son los métodos más exactos para la medición de la presión realizada con un catéter de medición.

El otro sistema de medición es la indirecta o no invasiva donde son utilizados los principios de la física circulatoria para tener estimaciones o aproximaciones de la presión arterial sin la necesidad de un método quirúrgico. Los sistemas no invasivos tienen un bajo costo, riesgos bajos para el paciente, miden la presión arterial en largos periodos de tiempo, para los especialistas de la salud es importante contar con un método que mida de manera precisa la presión arterial sistólica, diastólica y media. Hay diferentes métodos no invasivos gran parte de ellos permiten tener estimaciones de las presiones sistólica y diastólica, incluso algunos métodos permiten tener una medición instantánea de la presión arterial.

Los métodos no invasivos más utilizados para la medición de la presión arterial son el auscultatorio y el oscilométrico, estos métodos usan un brazalete neumático que se coloca alrededor del brazo el cual se infla a una presión mayor a la sistólica para después desinflarse lentamente.

El método auscultatorio se basa en los sonidos de Korotkoff que se escuchan con un estetoscopio colocado sobre la arteria por debajo del brazalete neumático, dichos sonidos se presentan cuando la presión del brazalete es igual a la presión sistólica y desaparecen cuando la presión restante es igual a la presión diastólica.

A medida que la presión desciende la arteria se expande a su tamaño normal, el flujo sanguíneo se vuelve laminar y el sonido desaparece, sin embargo, como la arteria está todavía constreñida el flujo es turbulento y va acompañado de un sonido particular. La presión que se presenta cuando el sonido comienza a desvanecerse se toma como la presión diastólica.

Aunque este método no es tan preciso como los métodos invasivos, es sencillo y en la mayoría de los casos es el adecuado, pero depende de la experiencia del operador. Además, este método no se utiliza para un control a largo plazo porque es necesaria la supervisión de un médico.

El método oscilométrico se basa en la medición de las oscilaciones de la presión arterial que aparecen cuando la presión en el brazalete es igual a la presión sistólica, dichas oscilaciones tienen un valor máximo en la presión media y desaparecen en la presión diastólica.

Como se mencionó anteriormente la técnica PPG es otro de los métodos más utilizados para medir la presión arterial de manera no invasiva, la cual consiste en medir las variaciones de

presión y volumen de la circulación sanguínea por medio de hacer incidir un haz de luz sobre las arterias del área donde se desea realizar la medición de la presión arterial, dicha medición se realiza en diferentes partes del cuerpo humano como la muñeca, el lóbulo de la oreja, los dedos de los pies y los dedos de las manos, en esta tesis doctoral se optó por realizar dicha medición en los dedos de las manos, tal como se muestra en la Figura 3.2.




Figura 3.2 Método fotopleletismográfico.

Tal como se vio en la sección 1.2 el ciclo de una señal fotopleletismográfica está compuesta por un pico sistólico, un pico diastólico, una muesca dicrótica y la amplitud de la señal, donde el pico sistólico se forma cuando el corazón bombea sangre, el pico diastólico se forma cuando el corazón se llena de sangre, la muesca dicrótica está dada por una caída momentánea de la presión sanguínea y la amplitud de la señal está dada por la respiración.

La forma en que serán obtenidas las señales fotopleletismográficas será por medio de una tarjeta de adquisición de señales cardiacas Max 86150 de la empresa Analog Devices (*MAX86150 Datasheet and Product Info | Analog Devices, s/f*), tal como se muestra en la Figura 3.3, que tiene la capacidad de adquirir señales electrocardiográficas (ECG) por medio de electrodos secos y adquirir señales fotopleletismográficas (PPG) por medio de un módulo sensor óptico que cuenta con dos tipos de Leds uno rojo y otro infrarrojo, dichas señales son adquiridas de manera simultánea o por separado y además está certificada por la FDA de Estados Unidos.




Figura 3.3 Tarjeta de adquisición de señales ECG y PPG Max 86150.

Por otra parte se realizó el análisis de las características de la señal PPG. Las señales PPG contienen información valiosa que ayuda no sólo a detectar enfermedades, sino también a diagnosticarlas. De acuerdo con la literatura las características de la señal PPG extraídas de las yemas de los dedos son las más utilizadas y validadas en comparación con otras partes del cuerpo humano. El pulso PPG suele dividirse en dos fases, la fase **anacrótica** que es el borde ascendente del pulso y la fase **catacrótica** que es el borde descendente del pulso. La primera fase se encarga de la sístole, y la segunda fase se encarga de la diástole y de los reflejos de las ondas procedentes de la periferia. En la fase catacrótica suele observarse una muesca dicrótica, que se observa en sujetos con arterias sanas, tal como se muestra en la Figura 3.4, donde la letra O representa el inicio de la señal PPG, la letra S representa el pico sistólico, la letra N representa la muesca dicrótica y la letra D representa el pico diastólico.




Figura 3.4 Fases anacrótica y catacrótica de la señal PPG.

En la literatura se han descrito varios puntos de referencia extraídos de la forma de onda PPG, sin embargo, hay incoherencias a la hora de denominar o etiquetar estos puntos. La figura 3.5 muestra una denominación y etiquetado sistemáticos y claros de los principales puntos de referencia en la forma de onda PPG y sus derivadas VPG y APG. Obsérvese que los puntos de referencia se denominan características, las combinaciones de ellas se utilizarían para generar características más sofisticadas, como intervalos de tiempo, potencia, y entropía, en dicha figura se muestra que las letras con los subíndices +1 hacen referencia a la primera derivada de la señal y las letras con los subíndices +2 hacen referencia a la segunda derivada de la señal.




Figura 3.5 Características de la señal PPG con sus derivadas.

En la Figura 3.6 se muestra la **amplitud sistólica** (x), que es un indicador de los cambios pulsátiles en el volumen sanguíneo causados por el flujo sanguíneo arterial alrededor del lugar de medición. También se ha sugerido que la amplitud sistólica es una medida potencialmente más adecuada que el tiempo de llegada del pulso para estimar la presión arterial continua.




Figura 3.6 Intervalo de pulso de la señal PPG.

La **anchura del pulso** en la onda PPG se muestra también en la figura 3-6 y se define como la anchura del pulso a la mitad de la altura del pico sistólico. Se ha sugerido que la anchura del pulso se correlaciona mejor con la resistencia vascular sistémica que con la amplitud sistólica.

El **área del pulso** se mide como el área total bajo la curva PPG. De acuerdo con la literatura el área del pulso es dividida en dos subáreas en la muesca dicrótica A1 y A2, tal como se muestra en la Figura 3-6.

La distancia entre dos picos sistólicos consecutivos se denomina **intervalo pico-pico**. El intervalo R-R de la señal de ECG se correlaciona estrechamente con el intervalo pico-pico de la señal APG que hace referencia a la segunda derivada de la señal PPG, ya que ambos representan un ciclo cardiaco completo. El intervalo pico-pico en las señales PPG se ha utilizado para detectar la frecuencia cardiaca y la variabilidad de la frecuencia cardiaca.

El **intervalo de pulso** es la distancia entre el principio y el final de la forma de onda PPG, tal como se muestra en la Figura 3-6. La literatura sugiere que la relación entre el intervalo del pulso y su amplitud sistólica proporciona una comprensión de las propiedades del sistema cardiovascular de una persona.

El **índice de aumento** de la presión es la medida de la contribución de la reflexión de la onda a la presión arterial sistólica. Se obtiene midiendo la onda reflejada desde la periferia hacia el centro. La reducción de la distensibilidad de las arterias elásticas provoca un retorno más precoz de la onda reflejada, que llega en sístole y no en diástole, lo que causa un aumento

desproporcionado de la presión sistólica y un aumento de la presión del pulso, lo que implica un aumento de la poscarga ventricular izquierda, una disminución de la presión arterial diastólica y un deterioro de la perfusión coronaria. El índice de aumento se define en la Ecuación 3-1.

$$IA = \frac{y}{x}$$

Ecuación 3-1. Índice de aumento de la presión arterial.

Donde IA es el índice de aumento, y es la altura del pico sistólico tardío y x es el pico sistólico temprano del pulso.

El componente sistólico de la forma de onda procede principalmente de una onda de presión que se desplaza hacia delante y se transmite a lo largo de un trayecto directo desde el ventrículo izquierdo hasta el dedo. El componente diastólico procede principalmente de las ondas de presión transmitidas a lo largo de la aorta a las pequeñas arterias de la parte inferior del cuerpo, desde donde se reflejan de nuevo a lo largo de la aorta como una onda reflejada que luego viaja hasta el dedo. La extremidad superior proporciona un conducto común tanto para la onda de presión transmitida directamente como para la onda reflejada y, por lo tanto, tiene poca influencia en su tiempo relativo. En la Figura 3.6 se muestra que el tiempo de retardo ΔT entre los picos sistólico y diastólico, está relacionado con el tiempo de tránsito de las ondas de presión desde la raíz de la arteria subclavia hasta el lugar aparente de reflexión y de vuelta a la arteria subclavia. Se supone que esta longitud de trayecto es proporcional a la altura del sujeto h . Por lo tanto se formula un índice del contorno de la señal PPG que se relaciona con la **rigidez de las grandes arterias**, tal como se muestra en la Ecuación 3-2.

$$SI = \frac{h}{\Delta T}$$

Ecuación 3-2. Rigidez de las grandes arterias.

Donde SI es la rigidez de las grandes arterias, h es la altura del sujeto y ΔT es el tiempo de retardo entre los picos sistólico y diastólico. El retardo temporal entre los picos sistólico y diastólico disminuye con la edad como consecuencia del aumento de la rigidez de las grandes arterias y de la mayor velocidad de la onda de pulso de las ondas de presión en la aorta y las grandes arterias, por otra parte se ha demostrado que el índice de rigidez de las grandes arterias aumenta con la edad.

En investigaciones recientes se ha descubierto que **la primera derivada de la señal PPG** contiene información más valiosa y tiene varios componentes que aún no han recibido un nombre oficial. De acuerdo con la literatura no existe un término de uso común para referirse a los componentes de la primera derivada de la señal PPG, lo que quizá limite la investigación sobre este tema. Por lo tanto, es necesario hacer referencia a una terminología específica, se sugiere el uso de w , x , y , y z , tal como se muestra en la Figura 3.7 para hacer referencia, respectivamente, al pico de pendiente máxima en la sístole, la pendiente mínima local en la sístole, la pendiente mínima global en la sístole y al pico de pendiente máxima en la diástole. Se utilizan letras minúsculas cursivas para los componentes de la forma de onda PPG para indicar la aplicación de la primera derivada.




Figura 3.7 Características de la primera derivada de la señal PPG.

Una de las características de la primera derivada de la señal PPG es la de **punto diastólico**, que se define como el punto en el que la primera derivada de la forma de onda está más próxima a cero, punto Z, tal como se muestra en la Figura 3-7, donde se muestra que las letras con los subíndices -1 representan una integral con respecto a la señal VPG que representa la primera derivada de la señal PPG y las letras con los subíndices +1 representan una derivada con respecto a la señal VPG que corresponde a la segunda derivada de la señal PPG o APG. Esta característica se utiliza para medir la frecuencia cardiaca.

El cálculo de ΔT es la característica de tiempo pico a pico relacionada con el tiempo que tarda la onda de presión en propagarse desde el corazón a la periferia y viceversa. El tiempo entre los picos sistólico y diastólico es ΔT . La definición de ΔT depende de la forma de onda PPG, ya que su contorno varía con los distintos sujetos. Cuando hay un segundo pico, ΔT se define como el tiempo entre los dos máximos. Sin embargo, en algunas formas de onda PPG no hay un segundo pico claro. En este caso, ΔT se define como el tiempo entre el pico de la forma de onda y el punto de inflexión en la pendiente descendente de la forma de onda, que es un máximo local de la primera derivada. Esta característica se utiliza para evaluar la rigidez arterial.

La característica de **cálculo del tiempo de cresta (TC)** es el tiempo transcurrido desde el pie de la onda PPG hasta su pico. De acuerdo con la literatura hay un método para clasificar a los sujetos según tengan una velocidad de onda de pulso alta o baja, equivalente a un riesgo alto o bajo de enfermedad cardiovascular, utilizando características extraídas de la señal PPG. Se ha descubierto que el tiempo pico a pico ΔT , el tiempo de cresta TC y el índice de rigidez $SI = \frac{h}{\Delta T}$, son las mejores características para una clasificación precisa de una enfermedad cardiovascular utilizando la primera derivada de la señal PPG. En la literatura se reporta que con ayuda de un clasificador basado en una máquina de vectores de soporte, se obtuvo un resultado de clasificación del 87.5 %. Por lo tanto esta característica se utiliza para la clasificación de enfermedades cardiovasculares.

La segunda derivada de la señal PPG se utiliza con más frecuencia que la primera derivada para el análisis de señales PPG, ya que contiene principalmente características útiles y refleja la aceleración del flujo sanguíneo. Cada latido de la segunda derivada de la señal PPG consta de cinco formas de onda, a, b, c, d y e, tal como se muestra en la Figura 3.8. Las primeras

formas de onda a, b, c y d representan un ciclo completo de sístole, mientras que la onda e, representa el inicio de la diástole. Dado que ya existen términos de uso común para referirse a estas formas de onda, no es necesario renombrarlas o sugerir otros nombres o terminologías. Obsérvese que se utilizan las letras minúsculas cursivas para las formas de onda de la segunda derivada de la señal PPG porque cada una de ellas es el resultado de aplicar una derivada.




Figura 3.8 Características de la segunda derivada de la señal PPG.

Como se mencionó anteriormente la forma de onda de la segunda derivada de la señal PPG incluye cuatro ondas sistólicas y una onda diastólica, la onda a es la onda positiva sistólica temprana, la onda b es la onda negativa sistólica temprana, la onda c es la onda sistólica tardía creciente, la onda d es la onda sistólica tardía decreciente y la onda e, es la onda positiva diastólica temprana que representa la muesca dicrótica. La altura de cada onda se mide a partir de la línea de base, siendo positivos los valores por encima de la línea de base y negativos los valores por debajo. Las relaciones entre la altura de cada onda y la de la onda a es decir b/a , c/a , d/a y e/a suelen utilizarse para el análisis de las ondas. La segunda derivada de la forma de onda de la señal PPG dactilar se utiliza para estabilizar la línea de base y permitir que las características individuales se visualicen y detecten con facilidad.

En la literatura se menciona que el **Índice de relación b/a** refleja un aumento de la rigidez arterial, por lo tanto, esta relación aumenta con la edad. Se ha demostrado que la magnitud del índice b/a de la segunda derivada de la señal PPG está relacionada con la distensibilidad de la arteria periférica. También se sugiere que la magnitud de b/a es un índice no invasivo útil para identificar aterosclerosis y distensibilidad arterial alterada. Asimismo se ha descubierto que este índice está asociado a la hipertensión.

El **Índice de relación c/a**, refleja una disminución de la rigidez arterial, por lo tanto, dicho índice disminuye con la edad. Por otra parte este índice distingue a los sujetos con hipertensión de los sujetos sanos. El **Índice de relación d/a** también refleja una disminución de la rigidez arterial, por lo tanto dicha relación también disminuye con la edad, además es útil para evaluar la poscarga ventricular izquierda. Un aumento en el **Índice de relación e/a** refleja una disminución de la rigidez arterial, por lo tanto, la relación e/a disminuye con la edad.

El **Índice (b - c - d - e)/a** aumenta con la edad y es útil para la evaluación del envejecimiento vascular y para el cribado de la enfermedad arteriosclerótica.

El intervalo R-R de la señal de ECG se correlaciona estrechamente con el **intervalo aa** de la segunda derivada de la señal PPG ya que ambos representan un ciclo cardiaco completo y se utiliza para calcular la frecuencia cardiaca y su variabilidad.

También se realizó un análisis de enfermedades cardiovasculares a nivel mundial y con base en ello se investigaron las enfermedades cardiovasculares que más prevalecen en México, de igual manera se identificaron los factores de riesgo para el desarrollo de enfermedades cardiovasculares, por último también se identificaron enfermedades que al mismo tiempo se convierten en factores de riesgo para el desarrollo de enfermedades cardiovasculares. En la Figura 3.9 se muestra un diagrama de la correlación de enfermedades cardiovasculares.




Figura 3.9 Correlación de Enfermedades Cardiovasculares.

Una vez identificadas dichas enfermedades cardiovasculares, se procedió a investigar qué tipo de equipos o análisis clínicos se utilizan para detectar dichas enfermedades, tal como se muestra en la Tabla 3.1.

Tabla 3.1 Equipos o análisis para Enfermedades Cardiovasculares

ENFERMEDADES	Equipos o Análisis utilizados
Insuficiencia Cardíaca	sangre, ECG, RT, ECO, Tomografía, PE
Infarto agudo al miocardio	ECG/sangre
Fibrilación auricular	ECG, ECO, sangre
Enfermedad aorta torácica	Examen físico, ECO, Tomografía, RM
Enfermedad vascular periférica	sangre
Amiloidosis cardíaca	sangre, ECG, ECO, RM
Arterioesclerosis	sangre, ECG, RM, Tomografía, PE
Aterosclerosis	sangre, ECG, RM, Tomografía, PE

También se investigó que tipo de unidades se utilizan para medir los factores de riesgo para el desarrollo de enfermedades cardiovasculares, tal como se muestra en la Tabla 3.2.

Tabla 3.2 Factores de Riesgo

Factores de Riesgo	Unidades
Hipertensión	mmHg
Tabaquismo	ppm
Obesidad	Kg/m2
diabetes	mg/dl
Colesterol	mg/dl
triglicéridos	mg/dl
tiroides	nmol/L

Se hizo un análisis comparativo de los equipos que se utilizan para medir señales ECG y que son capaces de detectar algún tipo de enfermedad cardiovascular, tal como se muestra en la Tabla 3.3, donde se muestra que este tipo de equipos son capaces de detectar fibrilación auricular, taquicardia, bradicardia y extrasístoles.

Tabla 3.3 Equipos para Medición de Señales ECG

Bioseñal	Equipo	Tipo	Detección	Tecnología
ECG	KARDIA MOBILE	Monitor inalámbrico.	Fibrilación auricular, Taquicardia, Bradicardia y ritmo normal.	Electrodos de Inox.
	LMEILI	Monitor portátil	ritmo cardiaco	Electrodos desechables y sensores de contacto
	D-HEART	monitor portátil	ritmo cardiaco	Electrodos desechables e inteligencia artificial
	BM95	con ECG integrado	Fibrilación auricular y extrasístoles	Electrodo de Inox
	Mindray	Monitor de signos vitales portátiles	Frecuencia Cardiaca, Presión Arterial, Saturación de Oxígeno, temperatura.	Electrodos desechables
	MKIU	Monitor portátil	Frecuencia Cardiaca, saturación de oxígeno.	Electrodos de Inox.
	FZXL P11	Smart Band	Frecuencia Cardiaca, temperatura, saturación de oxígeno, presión arterial, frecuencia respiratoria.	Electrodo de Inox, Sensor Óptico
	FRONTIER X	Monitor vestible	Frecuencia Cardiaca, Frecuencia respiratoria y esfuerzo cardiaco	Electrodo de Inox seco, IA

De igual manera se hizo un análisis comparativo de los equipos que se utilizan para medir señales PPG, tal como se muestra en la Tabla 3.4 donde se muestra que este tipo de equipos solo son capaces de detectar variables biomédicas, también conocidas como biomarcadores, tales como saturación de oxígeno, frecuencia cardíaca, presión arterial, glucosa en sangre, temperatura, etc. Esto proporciona un área de oportunidad para nuestra investigación con la tecnología PPG.

Tabla 3.4 Equipos para Medición de Señales PPG

Bioseñal	Equipo	Tipo	Detección	Tecnología
PPG	MEDLINKET	Oxímetro de pulso	saturación de oxígeno, temperatura, frecuencia cardíaca, índice de perfusión, pletismografía.	Electrodo de Inox, sensor óptico
	FZXL P11	Smart Band	Frecuencia Cardíaca, temperatura, saturación de oxígeno, presión arterial, frecuencia respiratoria.	Electrodo de Inox, sensor óptico
	ASRIZE	Smart Watch	Glucosa en sangre, temperatura, presión arterial, saturación de oxígeno, monitor de sueño.	Electrodo de Inox, sensor óptico

Las gráficas de la Figura 3.10 muestran que la tecnología ECG es capaz de detectar únicamente las ECV's como fibrilación auricular y la insuficiencia cardíaca, de igual manera la tecnología PPG es capaz de detectar dichas enfermedades con la diferencia de que requiere el apoyo de los algoritmos de inteligencia artificial para poder realizar dicha detección. Esto proporciona un área de oportunidad para realizar la detección de otras posibles enfermedades cardiovasculares.




Figura 3.10 Detección de ECV's con tecnologías ECG y PPG.

En la Tabla 3.5 se muestran las posibles enfermedades cardiovasculares a detectar y los niveles de los biomarcadores que indican el nivel necesario para desarrollar dichas enfermedades. La detección de dichas enfermedades se realizará con la tecnología fotoplethysmográfica y el apoyo de los algoritmos de aprendizaje automático.

Tabla 3.5 Biomarcadores de posibles enfermedades cardiovasculares a detectar

SALUD CARDIOVASCULAR								
Enfermedades Cardiovasculares	Variables Biomédicas							
	Hipertensión	Tabaquismo	Obesidad	Diabetes	Colesterol	Edad	Sexo	Triglicéridos
Arterioesclerosis	> 139 / 89	si	> 30	>= 200	> 200	si	si	> 150 mg/dl
	mmHg		kg/m2	mg/dl	mg/dl			
Aterosclerosis	> 139 / 89	si	> 30	>= 200	> 200	si	si	> 150 mg/dl
	mmHg		kg/m2	mg/dl	mg/dl			
Enfermedad aorta torácica	> 139 / 89	si	> 30	>= 200	> 200	si	si	> 150 mg/dl
	mmHg		kg/m2	mg/dl	mg/dl			
Enfermedad vascular periférica	> 139 / 89	si	> 30	>= 200	> 200	si	si	> 150 mg/dl
	mmHg		kg/m2	mg/dl	mg/dl			
Enfermedad de los vasos sanguíneos	> 139 / 89	si	> 30	>= 200	> 200	si	si	> 150 mg/dl
	mmHg		kg/m2	mg/dl	mg/dl			

Por otra parte también se analizaron los algoritmos de aprendizaje automático más adecuados para la medición y monitoreo de la presión arterial, de acuerdo con la literatura revisada se recomienda el uso de algoritmos de Deep Learning como las redes neuronales convolucionales (CNN) ya que se utilizan para la predicción de arritmias y para tareas de procesamiento de señales, tal es el caso de este tema de investigación ya que se requiere realizar la adquisición de señales PPG de buena calidad que permitan obtener información más precisa sobre sus características morfológicas. Por otra parte, la literatura también recomienda el uso de algoritmos de Machine Learning como K – Nearest Neighbors, Support Vector Machine, Linear Regression y Random Forest ya que estos algoritmos presentan el mejor desempeño en la predicción de la estimación de la presión arterial de manera más precisa.

3.3 Etapa de Diseño

En esta etapa se muestra el diseño de las fases de proceso del modelo de aprendizaje automático utilizado para realizar esta parte de nuestra investigación. En la Figura 3.11 se

muestran las 7 fases de dicho diseño en el cual se muestra que la fase 1 es la de entender el problema, lo que implica analizar en primer lugar que es la salud cardiovascular y que tipo de señales son las que se van a analizar, la fase 2 son los criterios de evaluación, es decir que métricas serán utilizadas para evaluar el modelo, la fase 3 es la evaluación de soluciones, es decir ver qué tipo de algoritmos serán utilizados para darle solución a nuestra problema, la fase 4 es la preparación de los datos, esto implica la adquisición de las señales que serán analizadas, la generación de la base datos, la limpieza y balanceo de los datos y la parte de entrenamiento del modelo.




Figura 3.11 Fases de proceso del modelo de aprendizaje automático.

En la Figura 3.12 se muestran las fases 5, 6 y 7 del modelo de aprendizaje automático, donde se muestra que la fase 5 es la construcción y entrenamiento del modelo de aprendizaje automático, en la cual se determinan los algoritmos específicos que serán utilizados para la construcción y entrenamiento del modelo, la fase 6 son los resultados, lo que implica la presentación de resultados y el análisis de errores de los mismos, por último la fase 7 es la validación de resultados, la cual se realizará con el apoyo de expertos en el área de la salud.




Figura 3.12 Fases 5, 6 y 7 del modelo de aprendizaje automático.

Por otra parte, se realizó la arquitectura del modelo basado en aprendizaje automático para la predicción de hipertensión y arteriosclerosis, tal como se muestra en la Figura 3.13.




Figura 3.13 Arquitectura del modelo de Machine Learning para la predicción de hipertensión y arteriosclerosis.

A continuación se describe paso a paso el flujo de trabajo de la arquitectura anteriormente mencionada.

1. Inicialmente, a partir de las yemas de los dedos se obtienen las señales PPG utilizando la tarjeta de adquisición de señales cardiacas.
2. Después se obtienen las características de la señal PPG es decir las características del tiempo, frecuencia, estadísticas y las características del dominio del tiempo de la

primera y segunda derivadas. A partir de dichas características se realiza la predicción de la presión arterial, la detección de hipertensión y arteriosclerosis.

3. Para la detección de hipertensión se establecieron reglas de clasificación para las categorías normal, baja, media y alta, es decir las predicciones se establecieron con valores entre 0 y 1 de esta forma si el valor de la predicción es igual o menor a 0.5 el valor de la presión arterial se clasifica como normal, en caso contrario si el valor de la predicción es menor o igual a 1 indicaría una probabilidad baja de padecer hipertensión. De igual forma para las categorías media y alta se establecieron reglas de clasificación es decir las predicciones se establecieron con valores entre 0 y 1 de esta forma si el valor de la predicción es igual o menor a 0.5 el valor indicaría una probabilidad media de padecer hipertensión, en caso contrario si el valor de la predicción es menor o igual a 1 indicaría una probabilidad alta de padecer hipertensión.
4. Por último para la detección de arteriosclerosis se establecieron reglas de clasificación para las categorías normal, baja, media y alta, es decir las predicciones se establecieron con valores entre 0 y 1 de esta forma si el valor de la predicción es igual o menor a 0.5 el valor de la presión arterial se clasifica como normal, en caso contrario si el valor de la predicción es menor o igual a 1 indicaría una probabilidad baja de padecer arteriosclerosis. De igual forma para las categorías media y alta se establecieron reglas de clasificación es decir las predicciones se establecieron con valores entre 0 y 1 de esta forma si el valor de la predicción es igual o menor a 0.5 el valor indicaría una probabilidad media de padecer arteriosclerosis, en caso contrario si el valor de la predicción es menor o igual a 1 indicaría una probabilidad alta de padecer arteriosclerosis.

3.4 Etapa de Implementación

En esta etapa se muestra la implementación de la metodología para el procesamiento de la señal PPG, la estimación de la presión arterial y la detección de alguna enfermedad cardiovascular, tal como se muestra en la Figura 3.14, donde se muestra la fase de adquisición de la señal PPG la cual se realiza a través de la tarjeta de adquisición de señales biomédicas

Max 86150, luego se tiene la fase de procesamiento de la señal PPG en la cual se realiza el filtrado de la señal PPG para eliminar el ruido de dicha señal, luego se tiene la fase de graficado de la señal PPG en la cual se muestran las gráficas de dicha señal sin procesar y ya procesada, por último se tiene la fase para el cálculo de las características de la señal PPG ya procesada donde se obtienen las características en el dominio del tiempo, en el dominio de la frecuencia y las características estadísticas.

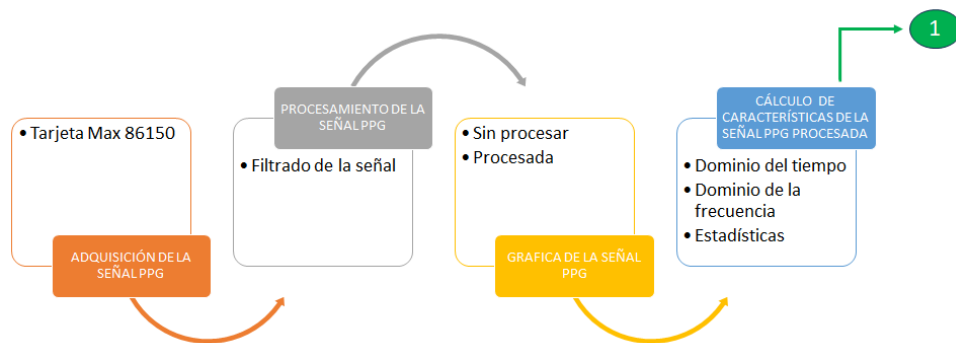


Figura 3.14 Diagrama de la metodología para la evaluación de la salud cardiovascular 1/3.

En la Figura 3.15 se muestra la fase de extracción de características de la señal PPG ya procesada como la amplitud del pico sistólico, la frecuencia del primer pico de la señal y la desviación estándar de la señal, luego se tiene la fase donde se calculan las derivadas de la señal PPG en este caso la primera y la segunda derivada, luego se tiene la extracción de características de la primera derivada de la señal PPG, como amplitud de las ondas “w”, duración de las ondas “w” y la amplitud de las ondas “y”, por último se tiene la fase extracción de características de la segunda derivada de la señal PPG, como la amplitud de las ondas “a”, duración de las ondas “a” y la amplitud de las ondas “b”.




Figura 3.15 Diagrama de la metodología para la evaluación de la salud cardiovascular 2/3.

Finalmente en la Figura 3.16 se muestra la fase de estimación de la presión arterial por medio de métodos no invasivos y algoritmos de aprendizaje automático y por último se tiene la fase de detección de enfermedades cardiovasculares, la cual se realiza a través de los algoritmos de aprendizaje automático.

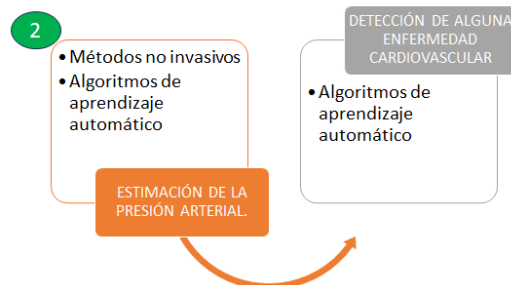


Figura 3.16 Diagrama de la metodología para la evaluación de la salud cardiovascular 3/3.

Por otra parte también se muestra la implementación del modelo de trabajo de aprendizaje automático, tal como se muestra en la Figura 3.17, y la forma en que será implementado dicho modelo.




Figura 3.17 Modelo de trabajo de aprendizaje automático.

En la Figura 3.18 se muestra la fase 1 la cual consiste en definir el objetivo, esto implica la obtención de información de las bioseñales adquiridas, la fase 2 consiste en recolectar los datos, esto se realizará por medio de una tarjeta de adquisición de señales cardiacas mencionada anteriormente, dicha tarjeta no solo realiza la adquisición de dichas señales sino que también tiene la capacidad de guardar y almacenar los datos generados por dichas señales en un archivo CSV de Excel.




Figura 3.18 Fase 1 definir objetivo, Fase 2 recolectar datos.

En la Figura 3.19 se muestra la fase 3 la cual consiste en procesar los datos, esto implica realizar la limpieza y balanceo de los mismos, la fase 4 consiste en crear el modelo, esto implica definir los parámetros de los modelos de aprendizaje automático, así como definir las variables, los biomarcadores, el umbral de decisión, etc.




Figura 3.19 Fase 3 procesar datos, Fase 4 crear modelo.

En la Figura 3.20 se muestra la fase 5 la cual consiste en entrenar el modelo, esto implica utilizar los algoritmos específicos de aprendizaje automático como KNN, SVM, DT o RF para realizar dicho entrenamiento, la fase 6 consiste en evaluar el modelo, esto implica definir las métricas que serán utilizadas para medir el desempeño de dichos algoritmos, dichas métricas son exactitud, precisión, sensibilidad y puntaje F1 que incluye la medida de la precisión y la sensibilidad.



Figura 3.20 Fase 5 entrenar el modelo, Fase 6 evaluar el modelo.

En la Figura 3.21 se muestra la fase 7 la cual consiste en realizar la predicción, esto implica, obtener los valores de la estimación de la presión arterial y los porcentajes de la probabilidad de desarrollar algún tipo de enfermedad cardiovascular, la fase 8 consiste en controlar los resultados, esto implica validar dichos resultados con la ayuda de expertos en el área de la salud.




Figura 3.21 Fase 7 realizar la predicción, Fase 8 controlar los resultados.

Por otra parte en la etapa de implementación de la metodología se muestra el procesamiento de la señal PPG, la estimación de la presión arterial y la detección de alguna enfermedad

cardiovascular, tal como se muestra en la Figura 3.22, donde se observa la fase de adquisición de la señal PPG que se realiza a través de la tarjeta de adquisición de señales biomédicas Max 86150, posteriormente se tiene la fase de procesamiento de la señal PPG en la que se realiza el filtrado de la señal PPG para eliminar el ruido de dicha señal, luego se tiene la fase de graficado de la señal PPG en la que se muestran las gráficas de la señal sin procesar y ya procesada. Finalmente, se tiene la fase para el cálculo de las características de la señal PPG ya procesada donde se obtienen las características en el **dominio del tiempo**, en el **dominio de la frecuencia** y **las características estadísticas**.



Figura 3.22 Diagrama de la metodología para la evaluación de la salud cardiovascular 1/3.

En la Figura 3.23 se muestra la fase de extracción de características de la señal PPG ya procesada como la **amplitud del pico sistólico**, la **frecuencia del primer pico de la señal** y la **desviación estándar de la señal**, luego se tiene la fase donde se calculan las derivadas de la señal PPG en este caso la primera y la segunda derivada, luego se tiene la extracción de características de la primera derivada de la señal PPG, como **amplitud de las ondas “w”**, **duración de las ondas “w”** y la **amplitud de las ondas “y”**, por último se tiene la fase extracción de características de la segunda derivada de la señal PPG, como la **amplitud de las ondas “a”**, **duración de las ondas “a”** y la **amplitud de las ondas “b”**.




Figura 3.23 Diagrama de la metodología para la evaluación de la salud cardiovascular 2/3.

Finalmente en la Figura 3.24 se muestra la fase de estimación de la presión arterial por medio de métodos no invasivos y algoritmos de aprendizaje automático y por último se tiene la fase de detección de enfermedades cardiovasculares (Hipertensión y Arteriosclerosis) la cual se realiza a través de los algoritmos de aprendizaje automático, para esta fase se utilizaron las mismas características del **dominio del tiempo**, el **dominio de la frecuencia** y las **características estadísticas** utilizadas para la estimación de la presión arterial pero también se utilizaron las características de la **primera y segunda derivadas**, ya que de acuerdo con la literatura dichas características son utilizadas para determinar el índice de rigidez de las arterias y la detección de enfermedades cardiovasculares.




Figura 3.24 Diagrama de la metodología para la evaluación de la salud cardiovascular 3/3.

También como parte de la etapa de implementación se muestran los listados de código correspondientes a la estimación de la presión arterial, la detección de hipertensión y la

detección de arteriosclerosis. En el Listado de código 1 se muestra el entrenamiento con 4 características de cada dominio, tiempo, frecuencia y estadísticas para la estimación de la presión arterial. En las líneas 1 y 2 se observa el llamado de los algoritmos combinados SVR y BaggingRegressor para construir el modelo que será entrenado, en las líneas 3 y 4 se definen los porcentajes de prueba y entrenamiento que serán utilizados en este caso se definieron 70% de los datos para entrenamiento y 30% para prueba, en las líneas 5 y 6 se define el tipo de kernel utilizado con el algoritmo SVR en este caso el mejor resultado se obtuvo con un kernel de tipo polinomial, en las líneas 7 y 8 se definieron 100 estimadores para que el modelo realizara 100 veces los cálculos para obtener las mejores predicciones, en las líneas 9 y 10 se realiza el ajuste y entrenamiento del modelo y en las líneas 11 y 12 el modelo realiza las predicciones de las presiones sistólica y diastólica.

```

1. from sklearn.svm import SVR
2. from sklearn.ensemble import BaggingRegressor
3. X_train, X_test, y_sbp_train, y_sbp_test = train_test_split(X, y_sbp, test_size=0.3,
    random_state=42)
4. X_train, X_test, y_dbp_train, y_dbp_test = train_test_split(X, y_dbp, test_size=0.3,
    random_state=42)
5. sbp_svr_p = SVR(kernel="poly", degree=6)
6. dbp_svr_p = SVR(kernel="poly", degree=6)
7. sbp_bgr_svr_p = BaggingRegressor(base_estimator=sbp_svr_p, n_estimators=100,
    random_state=42)
8. dbp_bgr_svr_p = BaggingRegressor(base_estimator=dbp_svr_p, n_estimators=100,
    random_state=42)
9. sbp_bgr_svr_p.fit(X_train, y_sbp_train)
10. dbp_bgr_svr_p.fit(X_train, y_dbp_train)
11. y_sbp_pred_bgr_svr_p = sbp_bgr_svr_p.predict(X_test)
12. y_dbp_pred_bgr_svr_p = dbp_bgr_svr_p.predict(X_test)

```

Listado de código 1. Entrenamiento con 4 datos

El código para realizar el entrenamiento con la base de datos PPG-BP es el mismo que se mostró en el Listado de código 1 con la diferencia de que en este caso se utilizaron 80% de los datos para entrenamiento y 20% para prueba, tal como se muestra en el Listado de código 2.

```

1. from sklearn.svm import SVR
2. from sklearn.ensemble import BaggingRegressor
3. X_train, X_test, y_sbp_train, y_sbp_test = train_test_split(X, y_sbp, test_size=0.2,
    random_state=42)
4. X_train, X_test, y_dbp_train, y_dbp_test = train_test_split(X, y_dbp, test_size=0.2,
    random_state=42)
5. sbp_svr_p = SVR(kernel="poly", degree=6)
6. dbp_svr_p = SVR(kernel="poly", degree=6)
7. sbp_bgr_svr_p = BaggingRegressor(base_estimator=sbp_svr_p, n_estimators=100,
    random_state=42)
8. dbp_bgr_svr_p = BaggingRegressor(base_estimator=dbp_svr_p, n_estimators=100,
    random_state=42)
9. sbp_bgr_svr_p.fit(X_train, y_sbp_train)
10. dbp_bgr_svr_p.fit(X_train, y_dbp_train)
11. y_sbp_pred_bgr_svr_p = sbp_bgr_svr_p.predict(X_test)
12. y_dbp_pred_bgr_svr_p = dbp_bgr_svr_p.predict(X_test)

```

Listado de código 2. Entrenamiento con el dataset PPG-BP

En el Listado de código 3 se muestra el código para obtener las probabilidades normal y baja para presión arterial normal y la probabilidad baja de padecer hipertensión. Para esta prueba se utilizaron 15 algoritmos de aprendizaje automático de tipo regresión de los cuales los mejores resultados se obtuvieron con los algoritmos **Regresión Lineal**, **KNN**, **Random Forest**, **Regresión Lineal Bagging**, **SVR Bagging** y **Árbol de decisión Bagging**. En el listado de código se muestra la prueba con Random Forest, se utilizó el 70 % de los datos para entrenamiento y 30 % para prueba, se hicieron 100 estimaciones, también se utilizó una función np.clip para que los resultados estuvieran dentro de rango entre 0 y 1 debido a que se utilizaron datos booleanos, así mismo se utilizó una función para conversión de categorías es decir que los resultados de las categorías aparecieran como NORMAL y BAJA en lugar de obtener 0 y 1, después se calculan las predicciones y se imprimen.

```

1. from sklearn.ensemble import RandomForestRegressor
2. X_train, X_test, y_hta_train, y_hta_test = train_test_split(X, y_hta, test_size=0.3,
    random_state=42)
3. hta_rfr = RandomForestRegressor(n_estimators=100, random_state=42)
4. hta_rfr.fit(X_train, y_hta_train)
5. y_hta_pred_rfr = hta_rfr.predict(X_test)
6. y_hta_pred_rfr = np.clip(y_hta_pred_rfr, 0, 1)
7. def convertir_a_categoria(pred):
8.     if pred <= 0.5:
9.         return "Normal"
10.    else:
11.        return "Baja"
12. categorias_pred = [convertir_a_categoria(pred) for pred in y_hta_pred_rfr]
13. for i, pred in enumerate(y_hta_pred_rfr):
14.    print(f"\nPredicción = {pred:.2f}, Categoría = {categorias_pred[i]}")

```

Listado de código 3. Hipertensión Random Forest Regressor

En el Listado de código 4 se muestra el código para obtener las probabilidades media y alta para la probabilidad media y la probabilidad alta de padecer hipertensión. Para esta prueba se utilizaron 15 algoritmos de aprendizaje automático de tipo regresión de los cuales los mejores resultados se obtuvieron con los algoritmos **KNN**, **SVR** con kernel polinomial, **Random Forest**, **KNN Bagging** y **Árbol de decisión Bagging**. En el listado de código se muestra la prueba con Árbol de decisión Bagging, se utilizó el 70 % de los datos para entrenamiento y 30 % para prueba, se hicieron 100 estimaciones, también se utilizó una función np.clip para que los resultados estuvieran dentro de rango entre 0 y 1 debido a que se utilizaron datos booleanos, así mismo se utilizó una función para conversión de categorías es decir que los resultados de las categorías aparecieran como MEDIA y ALTA en lugar de obtener 0 y 1, después se calculan las predicciones y se imprimen.

```

1. from sklearn.tree import DecisionTreeRegressor
2. from sklearn.ensemble import BaggingRegressor
3. X_train, X_test, y_hta_train, y_hta_test = train_test_split(X, y_hta, test_size=0.3,
    random_state=42)
4. hta_dtr = DecisionTreeRegressor(random_state=42)
5. hta_bgr_dtr = BaggingRegressor(estimator=hta_dtr, n_estimators=100, random_state=42)
6. hta_bgr_dtr.fit(X_train, y_hta_train)
7. y_hta_pred_bgr_dtr = hta_bgr_dtr.predict(X_test)
8. y_hta_pred_bgr_dtr = np.clip(y_hta_pred_bgr_dtr, 0, 1)
9. def convertir_a_categoria(pred):
10.     if pred <= 0.5:
11.         return "Media"
12.     else:
13.         return "Alta"
14. categorias_pred = [convertir_a_categoria(pred) for pred in y_hta_pred_bgr_dtr]
15. for i, pred in enumerate(y_hta_pred_bgr_dtr):
16.     print(f"\nPredicción = {pred:.2f}, Categoría = {categorias_pred[i]}")

```

Listado de código 4. Hipertensión Árbol de decisión Bagging

En el Listado de código 5 se muestra el código para obtener las probabilidades normal y baja para presión arterial normal y la probabilidad baja de padecer arteriosclerosis. Para esta prueba se utilizaron 15 algoritmos de aprendizaje automático de tipo regresión de los cuales los mejores resultados se obtuvieron con los algoritmos **Regresión Lineal**, **KNN**, **SVR**, **Random Forest**, **Regresión Lineal Bagging** y **Árbol de decisión Bagging**. En el listado de código se muestra la prueba con Random Forest, se utilizó el 70 % de los datos para entrenamiento y 30 % para prueba, se hicieron 100 estimaciones, también se utilizó una función np.clip para que los resultados estuvieran dentro de rango entre 0 y 1 debido a que se utilizaron datos booleanos, así mismo se utilizó una función para conversión de categorías es decir que los resultados de las categorías aparecieran como NORMAL y BAJA en lugar de obtener 0 y 1, después se calculan las predicciones y se imprimen.

```

1. from sklearn.ensemble import RandomForestRegressor
2. X_train, X_test, y_hta_train, y_hta_test = train_test_split(X, y_hta, test_size=0.3,
    random_state=42)
3. as_rfr = RandomForestRegressor(n_estimators=100, random_state=42)
4. as_rfr.fit(X_train, y_as_train)
5. y_as_pred_rfr = as_rfr.predict(X_test)
6. y_as_pred_rfr = np.clip(y_as_pred_rfr, 0, 1)
7. def convertir_a_categoria(pred):
8.     if pred <= 0.5:
9.         return "Normal"
10.    else:
11.        return "Baja"
12. categorias_pred = [convertir_a_categoria(pred) for pred in y_as_pred_rfr]
13. for i, pred in enumerate(y_as_pred_rfr):
14.    print(f"\nPredicción = {pred:.2f}, Categoría = {categorias_pred[i]}")

```

Listado de código 5. Arteriosclerosis Random Forest

Por último en el Listado de código 6 se muestra el código para obtener las probabilidades media y alta de padecer arteriosclerosis. Para esta prueba se utilizaron 15 algoritmos de aprendizaje automático de tipo regresión de los cuales los mejores resultados se obtuvieron con los algoritmos **Regresión Lineal**, **KNN**, **Random Forest**, **Regresión Lineal Bagging** y **Árbol de decisión Bagging**. En el listado de código se muestra la prueba con Árbol de decisión Bagging, se utilizó el 70 % de los datos para entrenamiento y 30 % para prueba, se hicieron 100 estimaciones, también se utilizó una función np.clip para que los resultados estuvieran dentro de rango entre 0 y 1 debido a que se utilizaron datos booleanos, así mismo se utilizó una función para conversión de categorías es decir que los resultados de las categorías aparecieran como MEDIA y ALTA en lugar de obtener 0 y 1, después se calculan las predicciones y se imprimen.

```

1. from sklearn.tree import DecisionTreeRegressor
2. from sklearn.ensemble import BaggingRegressor
3. X_train, X_test, y_hta_train, y_hta_test = train_test_split(X, y_hta,
    test_size=0.3, random_state=42)
4. as_dtr = DecisionTreeRegressor(random_state=42)
5. as_bgr_dtr = BaggingRegressor(estimator=as_dtr, n_estimators=100,
    random_state=42)
6. as_bgr_dtr.fit(X_train, y_as_train)
7. y_as_pred_bgr_dtr = as_bgr_dtr.predict(X_test)
8. y_as_pred_bgr_dtr = np.clip(y_as_pred_bgr_dtr, 0, 1)
9. def convertir_a_categoria(pred):
10.    if pred <= 0.5:
11.        return "Media"
12.    else:

```

Listado de código 6. Arteriosclerosis Árbol de decisión Bagging.

3.5 Etapa de Pruebas

En esta etapa se realizaron las pruebas iniciales que sirven como análisis comparativo del desempeño de los algoritmos tradicionales y el desempeño de los algoritmos conocidos como métodos ensamblados. Para estas pruebas se utilizó el lenguaje de programación Python con ayuda del software Spyder y una base de datos de cáncer de mama, que es una base de datos del área de la salud, en la Tabla 3.6, se muestran los resultados obtenidos del análisis comparativo de los métodos clásicos y los métodos ensamblados.

Tabla 3.6 Análisis Comparativo Métodos Clásicos contra Métodos Ensamblados

Algoritmos Clásicos	Puntaje F1	Algoritmos Ensamblados	Puntaje F1
KNN	93.14 %	KNN Bagging	92.62 %
Árbol de decisión	91.74 %	Árbol de decisión Bagging	95.07 %
Árbol aleatorio	91.55 %	Árbol aleatorio Bagging	96.66 %
SVM Polinomial	91.04 %		
SVM Gaussiano	62.73 %	SVM Bagging	91.91 %
		Adaboost	96.65 %
		GradientBoost	96.66 %
		RandomForest	96.14 %

Como se pudo observar en los resultados anteriores el peor puntaje F1 de los algoritmos clásicos fue de 62.73 % obtenido con el algoritmo SVM, el mejor puntaje F1 fue de 93.14 % obtenido con el algoritmo KNN. Sin embargo los métodos ensamblados DT tipo bagging, Adaboost, Gradientboost y RF superaron a los algoritmos clásicos con un puntaje F1 por arriba del 95 %.

Por otra parte en la etapa de pruebas, se realizó la documentación del código para el procesamiento y extracción de características de la señal PPG por medio de un diagrama de flujo, con ayuda de la documentación de la biblioteca de funciones BIOBSS, tal como se muestra en la Figura 3.25, cabe mencionar que esta parte del código se desarrolló en la plataforma Google Colab®.




Figura 3.25 Diagrama de flujo del código para el procesamiento y extracción de características de la señal PPG 1/4.

En la primera parte del código se realiza la instalación de la biblioteca BIOBSS que cuenta con diversos paquetes para realizar el procesamiento de bioseñales como la señal ECG (Electrocardiográfica), la señal PPG (Fotopletismográfica), etc. Para el propósito de este proyecto de investigación se está utilizando la biblioteca BIOBSS para realizar el procesamiento y obtener las características de la señal PPG.

A continuación se importan los paquetes necesarios para realizar dicho procesamiento como Numpy, Matplotlib, Pandas, etc.

Posteriormente se realiza la carga de la base de datos que contiene los datos de la señal PPG, dicha base de datos se proporciona en un archivo CSV de Excel. La base de datos contiene 100 segmentos PPG de 10 segundos de duración y una frecuencia de muestreo de 64 Hz para todos los segmentos.

Luego se tiene la etapa de preprocesamiento de la señal PPG donde se realiza el filtrado de dicha señal para eliminar el ruido. La biblioteca BIOBSS provee una función de filtrado llamada Scipy. Esta función se utiliza para implementar un filtro Butterworth definiendo los parámetros del filtro como, el tipo de filtro, orden del filtro y frecuencias de corte. De igual forma se utilizan filtros predefinidos para cada tipo de señal, en el caso de la señal PPG se utiliza la función `signal_type` y se selecciona el tipo PPG.



Figura 3.26 Diagrama de flujo del código para el procesamiento y extracción de características de la señal PPG 2/4.

En la siguiente etapa del código se realiza la detección de picos, tal como se muestra en el Figura 3.26, para esta parte la biblioteca BIOBSS cuenta con una función de detección de picos con diferentes opciones para el método de detección de picos. Estos métodos son apropiados para la señal PPG, sin embargo los parámetros se seleccionan apropiadamente si el segundo pico (pico diastólico) es observable en la señal. La función `ppg_detectpeaks` devuelve un diccionario que incluye las ubicaciones de los picos y de los valles de la señal.

Para análisis posteriores, se requiere de un control de picos para prevenir errores resultantes de detección de picos incorrectos ya sea picos faltantes o duplicados. La función `peak_control` comprueba las ubicaciones relativas de los picos y los valles, asegurándose de que sólo hay un pico entre valles consecutivos. Como opción, se aplica el procedimiento de corrección de picos estableciendo el parámetro `correct_peaks` de la función `ppg_detectpeaks` como verdadero. En caso de que la forma de onda de la señal PPG tenga baja amplitud los latidos PPG se detectan con mayor precisión a partir del borde ascendente de la señal en lugar de detectar los picos, la biblioteca BIOBSS cuenta con la función `ppg_detectbeats` para este propósito. Dicha función calcula la primera derivada de la señal PPG (pletismograma de velocidad - VPG) y detecta los picos VPG. Los picos máximos en la señal VPG corresponden al punto de máxima pendiente en el flanco ascendente de la señal PPG. Cabe mencionar que la función `ppg_detectbeats` devuelve solo las ubicaciones de los picos y el parámetro `delta` se ajusta teniendo en cuenta la amplitud de la señal VPG.

Para la detección de los picos también se utiliza la función `ppg_detectpeaks` configurando el tipo de parámetro como “beat”, en este caso se devuelven las posiciones de los picos y los valles de la señal.

Después continuamos con la etapa de delimitación, la forma de onda de la señal PPG incluye dos picos el sistólico y el diastólico, sin embargo, el pico diastólico es no observable en algunas condiciones, a partir de la ubicación de los picos diastólicos se calculan algunas características adicionales.

Para detectar la ubicación del pico diastólico, generalmente se necesitan las derivadas primera y segunda de la señal PPG. En primer lugar se detectan los puntos fiduciales de dichas derivadas, dichos puntos fiduciales también se utilizan para calcular las características de la primera y segunda derivadas que son útiles en algunos análisis, por ejemplo, la estimación de la presión arterial a partir de la señal PPG.

La biblioteca BIOBSS cuenta con funciones de delimitación para las señales PPG, VPG y APG (pletismograma de aceleración - APG) como `ppg_fiducials`, `vpg_fiducials` y `apg_fiducials` respectivamente. Cabe mencionar que la función de delimitación `apg_fiducials` requiere de las ubicaciones de los fiduciales VPG y la función de delimitación `ppg_fiducials` requiere las ubicaciones de los fiduciales VPG y APG. Por lo tanto el proceso de delimitación sigue un orden determinado.

La función `vpg_fiducials` detecta las ubicaciones de las ondas “w”, “y” y “z” de la señal VPG y devuelve un diccionario de fiduciales, esta función utiliza un algoritmo de búsqueda partiendo del pico máximo es decir la onda “w” de la señal. La función `apg_fiducials` detecta las ubicaciones de las ondas a, b, c, d y e de la señal APG y devuelve un diccionario de fiduciales, dicha función utiliza un algoritmo de búsqueda que parte del pico máximo es decir la onda a de señal, también es necesario proporcionar las ubicaciones de los puntos de referencia de la señal VPG ya que los intervalos de búsqueda se definen en función de estas ubicaciones. La función `ppg_fiducials` detecta las ubicaciones de las ondas S, N, O y D de la señal PPG y devuelve un diccionario de fiduciales, dicha función utiliza un algoritmo de búsqueda que parte de las ubicaciones de inicio de la señal es decir la onda O, calculadas mediante la función de detección de picos. También es necesario proporcionar las ubicaciones de los puntos de referencia VPG y APG, ya que los intervalos de búsqueda se

definen en función de estas ubicaciones. Para detectar todos los fiduciales simultáneamente se utiliza la función `ppg_waves`. Para la etapa de graficado la biblioteca BIOBSS cuenta con funciones de graficado específicas para cada tipo de señal. En el caso de la señal PPG se utiliza la función `plot_ppg`, las señales y los picos se proporcionan como diccionarios, dichos gráficos se generan utilizando los paquetes Matplotlib o Plotly, en la gráfica de la Figura 3.27 se muestra la señal PPG sin procesar en color azul y la señal ya filtrada en color naranja y también se muestra la ubicación relativa de sus picos. Además se muestra la duración del tiempo de la señal en segundos y su amplitud en unidades arbitrarias.




Figura 3.27 Gráfica de la señal PPG.

Con respecto a la etapa de evaluación de la calidad de la señal PPG la literatura reporta que la señal PPG es muy sensible a los artefactos de movimiento por lo que la evaluación de la calidad de la señal es un paso importante que es necesario antes del análisis de la señal, para esto se utilizan enfoques basados en reglas o en aprendizaje automático utilizando la información morfológica de la forma de onda PPG. La biblioteca BIOBSS proporciona módulos para evaluar la calidad de la señal que se aplica por separado o simultáneamente.



Figura 3.28 Diagrama de flujo del código para el procesamiento y extracción de características de la señal PPG 3/4.

Luego tenemos la etapa de detección de recortes y líneas planas como uno de los métodos de evaluación de la calidad de la señal PPG, tal como se muestra en la Figura 3.28. La función `detect_flatline_clipping` se utiliza para detectar segmentos recortados o planos de una señal estableciendo los parámetros y devuelve un diccionario de límites. El recorte se produce cuando se superan los límites de tensión de los circuitos de acondicionamiento de señal. Los segmentos recortados se detectan estableciendo un umbral y aplicando reglas a la amplitud de la señal. La detección de líneas planas difiere del recorte en que se produce en cualquier nivel de amplitud de la señal, la duración de los segmentos planos también es importante para detectar las líneas planas. Por lo tanto para aplicar las reglas es necesario definir un umbral de amplitud y duración, el umbral de amplitud se define como el nivel mínimo de cambio de amplitud necesario para que una señal se considere un segmento no plano.

La siguiente etapa es la de límites fisiológicos y morfológicos que es otro método para la evaluación de la calidad de señal PPG, para esta etapa las funciones `check_phys` y `check_morph` se utilizan para comprobar los límites fisiológicos y morfológicos respectivamente. Estas funciones toman como argumentos las ubicaciones de los picos y los valles y devuelven un diccionario de resultados booleanos de las reglas aplicadas.

Para poder calcular las características morfológicas, el número de picos y valles tienen que coincidir. Por lo tanto el control de picos también se aplica después de la detección de estos.

Un método común para la evaluación de la calidad de la señal es el conocido como "Template Matching" o ajuste de plantillas. Este método se basa en la expectativa de que las formas de onda del pulso tendrán una morfología similar en un segmento PPG. Se genera una plantilla alineando los pulsos por sus picos y promediándolos, a continuación se evalúa la similitud de cada pulso con la plantilla utilizando una medida.

La función `template_matching` utiliza la correlación de Pearson como medida de similitud, se determina un umbral para el coeficiente de correlación por debajo del cual el pulso es "inaceptable", este valor por defecto del umbral es de 0,9. La función devuelve una tupla de coeficientes de correlación y un resultado booleano para la calidad del segmento.

Los métodos definidos anteriormente también se aplican simultáneamente utilizando la función `sqa_ppg` del subpaquete `ppgtools`. Los métodos se proporcionan como una lista y la función devuelve un diccionario de resultados.




Figura 3.29 Diagrama de flujo del código para el procesamiento y extracción de características de la señal PPG 4/4.

La siguiente etapa del código es la extracción de características de la señal PPG, tal como se muestra en la Figura 3.29. La señal PPG se utiliza sobre todo para calcular la frecuencia cardíaca y analizar su variabilidad. Sin embargo, también se utiliza para estimar parámetros fisiológicos como la frecuencia respiratoria y la presión arterial. Existen varios enfoques diferentes para la estimación y uno de ellos es el uso de modelos de aprendizaje automático, generalmente se utilizan características morfológicas del dominio del tiempo, del dominio de la frecuencia y características estadísticas para entrenar los modelos de aprendizaje

automático. La biblioteca BIOBSS tiene módulos para el cálculo de las características más comunes en la literatura. Estas características se calculan por separado para cada dominio utilizando las funciones `get_time_features`, `get_freq_features` y `get_stat_features`, estas funciones requieren un parámetro “type” para seleccionar el subconjunto de características. Las características con base en el ciclo se calculan para cada ciclo es decir la forma de onda y se promedian para todos los ciclos de un segmento, las características con base en segmentos se calculan para todo el segmento, si se proporcionan puntos fiduciales las características se amplían calculando las características relacionadas con las ondas D (diástolica) y N (dicrótica).

Como alternativa se utilizan las funciones `from_cycles` y `from_segment` para calcular características de múltiples dominios, la función `get_ppg_features` se utiliza para calcular características de múltiples dominios y tipos de entrada (`input_types`) de manera simultánea.

En la Figura 3.30 se muestra la gráfica de las características de la señal PPG ya procesada en el dominio del tiempo, en dicha gráfica se observan características como `ppg_DW_SW_10` que corresponde a la duración media del pico diastólico y a la duración del pico sistólico al 10 % de la amplitud sistólica, también se observa que la característica que más sobresale es `ppg_PR_mean` que corresponde a la frecuencia media del pulso.




Figura 3.30 Características de la señal PPG procesada, en el dominio del tiempo.

En la Figura 3.31 se muestra la gráfica de las características de la señal PPG ya procesada en el dominio de la frecuencia, en dicha gráfica se observan características como `ppg_f_1` que

corresponde a la frecuencia a la que se produjo el primer pico de la señal, también se observa que la característica que más sobresale es ppg_f_3 que corresponde a la frecuencia a la que se produjo el tercer pico de la señal.




Figura 3.31 Características de la señal PPG procesada, en el dominio de la frecuencia.

En la Figura 3.32 se muestra la gráfica de las características estadísticas de la señal PPG ya procesada, en dicha gráfica se observan características como ppg_mean que corresponde al valor medio de la señal, también se observa que la característica que más sobresale es ppg_entropy que corresponde a la entropía de la señal.




Figura 3.32 Características estadísticas de la señal PPG procesada.

A continuación, se tienen las etapas de extracción de características de la primera y segunda derivadas, en esta etapa las funciones get_vpg_features y get_apg_features se utilizan para calcular las características VPG y APG respectivamente, y su relación entre ellas.

En la Figura 3.33 se muestra la gráfica de las características de la primera derivada de la señal PPG ya procesada en el dominio del tiempo, en dicha gráfica se observan características

como vpg_a_w que corresponde a la amplitud media de las ondas “w”, es decir, el punto sistólico de la señal, también se observa que la característica que más sobresale es vpg_t_z que corresponde a la duración media de las ondas “z”, es decir, el punto diastólico de la señal.




Figura 3.33 Características de la primera derivada de la señal PPG procesada, en el dominio del tiempo.

En la Figura 3.34 se muestra la gráfica de las características de la segunda derivada de la señal PPG ya procesada en el dominio del tiempo, en dicha gráfica se observan características como apg_a_b que corresponde a la amplitud media de las ondas “b”, también se observa que la característica que más sobresale es apg_a_a que corresponde a la amplitud media de las ondas “a” de la señal, dichas ondas “a” y “b” corresponden al ciclo de la sístole.




Figura 3.34 Características de la segunda derivada de la señal PPG procesada, en el dominio del tiempo.

Una vez realizado el procesamiento y extracción de características de la señal PPG, se desarrolló el código de programación para realizar la estimación de la presión arterial a partir de las características de tiempo, frecuencia y estadísticas de dicha señal, el código de programación se desarrolló en el lenguaje de programación Python con ayuda de la plataforma Google Colab® y del software Spyder. En la Tabla 3.7 se muestran algunas de las características antes mencionadas.

Tabla 3.7 Características PPG

Tiempo	Frecuencia	Estadísticas
ppg_a_S: Amplitud media de los picos sistólicos	ppg_p_1: amplitud del primer pico de la fft de la señal	ppg_std: desviación estándar de la señal
ppg_t_S: Duración media de los picos sistólicos	ppg_f_2: Frecuencia a la que se produjo el segundo pico de la fft de la señal	ppg_pct_25: percentil 25 de la señal
ppg_DW: Duración media del pico diastólico	ppg_f_1: La frecuencia a la que se produjo el primer pico de la fft de la señal	ppg_median: Valor medio de la señal
ppg_t_C: Duración media del ciclo	ppg_f_3: La frecuencia a la que se produjo el tercer pico de la fft de la señal	ppg_mean: Valor promedio de la señal

Los algoritmos de aprendizaje automático utilizados para la estimación de la presión arterial fueron cuatro algoritmos tradicionales: Regresión Lineal, KNN, SVM y DT, también se utilizaron cuatro algoritmos de tipo ensamblado: Adaboost, Gradientboosting, RandomForest y Bagging, debido a que los valores de la presión arterial son continuos y se desea saber el valor exacto de la presión arterial se decidió utilizar algoritmos de tipo Regresión ya que son los más adecuados para la estimación de este tipo de valores y así poder medir su eficiencia. Inicialmente se utilizaron cuatro características de cada dominio para hacer los entrenamientos de dichos algoritmos. En la Figura 3.35 se muestran los datos utilizados para realizar este entrenamiento.

tiempo	frecuencia	estadísticas
0.020172	0.004951	0.011591
0.211647	0.012331	0.853358
0.362216	0.842396	0.989167
0.454545	1.1	0.99875

Figura 3.35 4 datos utilizados de cada Dominio.

En la Tabla 3.8 se muestran los resultados obtenidos del entrenamiento con cuatro características de cada dominio.

Tabla 3.8 Prueba 4 datos

Algoritmos	Métricas					
	MSE		R ²		MAE	
	SBP	DBP	SBP	DBP	SBP	DBP
RL	29.1629418	25.2524406	0.87038693	0.74747559	5.39374164	3.59582776
KNN_w_uniform	325	200	0.44444444	-1	15	10
KNN_w_distance	118.542345	84.8173425	0.47314513	0.15182657	9.80676241	6.53784161
SVR_rbf	308.061637	186.48897	0.36916283	-0.8648897	14.6572668	9.65726677
SVR_poly	27.9404905	26.3051408	0.87582004	0.73694859	5.24453241	3.79411255
DT	100	100	0.55555556	0	10	10
AdaBoost	250	100	0.11111111	0	15	10
GradientBoosting	51.1798414	52.6663166	0.77253404	0.47333683	5.76806292	6.15462473
RandomForest	190.42	117.52	0.15368889	-0.1752	12.9	8.6
Bagging_RL	130.765073	93.8425327	0.4188219	0.06157467	10.0047457	7.02537505
Bagging_SVR_rbf	328.278038	200.931934	-0.4590135	1.00931934	14.8217787	10.2207924
Bagging_SVR_poly	5.41025717	17.7724061	0.97595441	0.82227594	2.12615532	3.98377018
Bagging_KNN_w_uniform	337.36	208.16	0.49937778	-1.0816	15	10.4
Bagging_KNN_w_distance	213.0487	140.73021	0.05311689	-0.4073021	12.2995165	8.57295144
Bagging_DT	190.42	117.52	0.15368889	-0.1752	12.9	8.6

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); Presión Sistólica (SBP); Presión Diastólica (DBP)

Como se muestra en la Tabla 3.8 los mejores resultados se obtuvieron con los algoritmos: Regresión Lineal, SVR polinomial, GradientBoosting y Bagging SVR polinomial, las

métricas utilizadas para medir la eficiencia de todos los algoritmos fueron el Error Cuadrático Medio (MSE), el Coeficiente de Determinación (r^2) y el Error Absoluto Medio (MAE).

En la Figura 3.36 se muestran las gráficas con las mejores predicciones para la estimación de la presión arterial sistólica y diastólica obtenidas con el algoritmo Bagging SVR polinomial, dichas gráficas muestran los mejores valores obtenidos de las muestras 2 y 4. La muestra 2 tiene un valor de presión sistólica de 86 mmHg y un valor de presión diastólica de 64 mmHg, por otra parte la muestra 4 tiene un valor de presión sistólica de 121 mmHg y un valor de presión diastólica de 87 mmHg. Por lo tanto el valor de presión sistólica más cercano al valor real fue con la muestra 4 y el valor de presión diastólica más cercano al valor real fue con la muestra 2.




Figura 3.36 Gráficas de la presión arterial con el algoritmo Bagging SVR polinomial.

Posteriormente se utilizaron seis características de cada tipo para entrenar los algoritmos y poder ver si se podían obtener resultados con errores más bajos, sin embargo los resultados obtenidos con seis características mostraron sobreajuste, lo que nos llevó a pensar que posiblemente el entrenamiento de los algoritmos para poder realizar la estimación de la presión arterial no requiere de muchos datos a diferencia de los entrenamientos para problemas de Clasificación donde se requieren bases de datos más grandes. En la Figura 3.37 se muestran los datos utilizados para realizar este entrenamiento.

tiempo	frecuencia	estadísticas
0.020172	0.004951	0.011591
0.211647	0.012331	0.853358
0.362216	0.842396	0.989167
0.454545	1.1	0.99875
0.579545	1.3	1.00009
0.791193	2.6	1.15917

Figura 3.37 6 datos utilizados de cada Dominio.

En la Tabla 3.9 se muestran los resultados obtenidos del entrenamiento con seis características.

Tabla 3.9 Prueba 6 datos

Algoritmos	Métricas					
	MSE		R ²		MAE	
	SBP	DBP	SBP	DBP	SBP	DBP
RL	227086.479	14738.6694	-9082.45914	-588.546777	353.281903	89.7778657
KNN_w_uniform	425	181.25	-16	-6.25	20	12.5
KNN_w_distance	406.146282	175.643042	-15.2458513	-6.02572168	19.4808227	12.2404114
SVR_rbf	807.357745	347.993838	-31.2943098	-12.9197535	27.9681954	17.9681954
SVR_poly	493.849529	160.551642	-18.7539812	-5.4220657	21.6648939	11.6648935
DT	250	125	-9	-4	15	10
AdaBoost	250	125	-9	-4	15	10
GradientBoosting	250.000001	125	-9.00000002	-4.00000002	15	10
RandomForest	387.9025	173.84	-14.5161	-5.9536	19.05	12.2
Bagging_RL	2664.01905	305.193797	-105.560762	-11.2077519	39.2043859	12.7577299
Bagging_SVR_rbf	768.197977	347.656971	-29.7279191	-12.9062788	27.2597315	17.9597315
Bagging_SVR_poly	197.994138	100.710909	-6.9197655	-3.02843635	13.1582266	8.70538612
Bagging_KNN_w_uniform	503.515625	221	-19.140625	-7.84	21.875	14
Bagging_KNN_w_distance	487.317209	214.211638	-18.4926884	-7.56846554	21.4780838	13.7324656
Bagging_DT	387.9025	173.84	-14.5161	-5.9536	19.05	12.2

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); Presión Sistólica (SBP); Presión Diastólica (DBP)

Por otra parte también se utilizó una base de datos llamada PPG-BP que contiene datos de biomarcadores de 219 sujetos de estudio para entrenar los algoritmos anteriormente

mencionados para realizar la estimación de la presión arterial. Esta base de datos contiene biomarcadores como, género, edad, estatura, peso, presión arterial sistólica y diastólica, frecuencia cardíaca, índice de masa corporal y datos de padecimientos cardiovasculares como, hipertensión, diabetes, infarto cerebral, enfermedad cerebrovascular e insuficiencia del riego sanguíneo cerebral, tal como se muestra en la Figura 3.38.

Num.	subject_ID	Sex(M/F)	Age(year)	Height(cm)	Weight(kg)	lod Press _s	lod Press _d	Heart Rate(b/m)	BMI(kg/m ²)	Hypertension	Diabetes	cerebral infarction	cerebrovascular disease
54	84	Female	76	150	58	106	53	69	22.22	Normal	nan	cerebral infarction	nan
55	85	Female	58	164	53	158	89	73	19.71	Stage 1 hypertension	nan	cerebral infarction	nan
56	86	Female	71	159	88	170	87	74	31.64	Stage 2 hypertension	nan	cerebral infarction	nan
57	87	Female	78	160	55	164	73	85	21.48	Stage 2 hypertension	nan	cerebral infarction	nan
58	88	Female	77	153	68	120	69	76	25.63	Prehyperten.	nan	cerebral infarction	nan
59	89	Female	74	152	56	100	55	63	24.24	Normal	nan	nan	insufficiency of ce.
60	90	Male	63	166	90	128	77	85	32.66	Prehyperten.	nan	nan	insufficiency of ce.
61	91	Female	53	160	64	116	58	71	25	Normal	nan	nan	cerebrovascular disease
62	92	Female	53	160	64	128	76	73	25	Prehyperten.	nan	nan	nan
63	93	Male	54	169	64	161	95	78	22.41	Stage 2 hypertension	nan	nan	cerebrovascular disease
64	95	Female	64	163	72	153	71	59	27.1	Stage 1 hypertension	nan	nan	insufficiency of ce.

Figura 3.38 Datos contenidos en el Dataset PPG-BP.

Para esta prueba se realizó un preprocesamiento del dataset para poder utilizar todos los datos numéricos, tal como se muestra en la Figura 3.39, sin embargo los resultados también mostraron sobreajuste esto nos confirmó que los valores de la presión arterial al ser continuos no se requieren muchos datos para realizar este entrenamiento.

Age(year)	Height(cm)	Weight(kg)	Heart Rate(b/m)	BMI(kg/m ²)
45	152	63	97	27.27
50	157	50	76	20.28
47	150	47	79	20.89
45	172	65	87	21.97
46	155	65	73	27.06
48	160	68	70	26.56
48	153	49	84	20.93
53	160	70	84	27.34
58	165	55	63	20.2

Figura 3.39 Datos utilizados después de preprocesar el Dataset PPG-BP.

En la Tabla 3.10 se muestran los resultados del entrenamiento con la base de datos PPG-BP.

Tabla 3.10 Prueba PPG-BP

Algoritmos	Métricas					
	MSE		R ²		MAE	
	SBP	DBP	SBP	DBP	SBP	DBP
RL	266.310009	74.8390415	0.22821635	0.16946085	12.1180902	6.87935338
KNN_w_uniform	261.083561	71.7434596	0.24336293	0.20381461	11.9734848	6.83712121
KNN_w_distance	246.018212	71.5467397	0.28702329	0.20599774	11.4216703	6.99173982
SVR_rbf	345.116317	90.1528196	-0.00016944	-0.00048643	14.3772723	7.44465251
SVR_poly	272.843405	71.6181509	0.20928214	0.20520524	12.0769666	6.67641763
DT	414.818182	203.113636	-0.20216996	-1.25408854	15.1818182	11.0227273
AdaBoost	241.401607	88.4903144	0.30040251	0.0179635	12.7106601	7.65468987
GradientBoosting	295.817955	108.495382	0.14270041	-0.20404618	13.6577135	8.24631814
RandomForest	261.216105	77.6242227	0.24297881	0.13855183	13.2359091	7.07636364
Bagging_RL	265.062666	73.1557394	0.23183123	0.18814159	12.051181	6.79503413
Bagging_SVR_rbf	345.133219	90.1645233	-0.00021842	-0.00061632	14.2806601	7.44704339
Bagging_SVR_poly	282.944322	65.7706686	0.18000903	0.27009868	12.4451291	6.56299705
Bagging_KNN_w_uniform	292.815523	88.3303165	0.15140165	0.01973911	12.3930682	7.55329545
Bagging_KNN_w_distance	290.211054	86.7671626	0.15894957	0.03708648	12.2113427	7.44939658
Bagging_DT	261.444852	77.9531114	0.24231589	0.13490193	13.3211364	7.05068182

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); Presión Sistólica (SBP); Presión Diastólica (DBP)

Por otra parte como actividad extra se realizó la correlación de la señal ECG y la señal PPG para ver si es posible detectar anomalías en la señal PPG con respecto al tiempo tomando como referencia la señal ECG. Sin embargo, esto no es posible ya que la señal ECG refleja el comportamiento eléctrico del corazón y la señal PPG refleja las variaciones de presión y volumen a través de las arterias debido al paso del flujo sanguíneo. En la Figura 3.40 se muestra la correlación de dichas señales, cabe mencionar que esta actividad no forma parte de los objetivos de esta Tesis Doctoral, sin embargo se realizó esperando encontrar información útil para poder realizar la detección de alguna enfermedad cardiovascular (Arteriosclerosis) a través de las características morfológicas de la señal PPG.




Figura 3.40 Correlación de las señales ECG y PPG.

También como parte de los avances en la etapa de pruebas, se aplicó la métrica RMSE (Root Mean Square Error) a los algoritmos utilizados para la predicción de la presión arterial debido a que al utilizar la métrica MSE (Mean Square Error) se obtienen los resultados elevados al cuadrado y al aplicar la métrica RMSE se obtienen los resultados directos, tal como se muestra en la Tabla 3.11, para la prueba con 4 datos.

Tabla 3.11 Prueba 4 datos

Algoritmos	Métricas							
	MSE		R^2		MAE		RMSE	
	SBP	DBP	SBP	DBP	SBP	DBP	SBP	DBP
RL	29.1629418	25.2524406	0.87038693	0.74747559	5.39374164	3.59582776	5.40027238	5.025180654
KNN_w_uniform	325	200	0.44444444	-1	15	10	18.0277564	14.14213562
KNN_w_distance	118.542345	84.8173425	0.47314513	0.15182657	9.80676241	6.53784161	10.8877153	9.209633139
SVR_rbf	308.061637	186.48897	0.36916283	-0.8648897	14.6572668	9.65726677	17.5516847	13.65609643
SVR_poly	27.9404905	26.3051408	0.87582004	0.73694859	5.24453241	3.79411255	5.28587651	5.128853747
DT	100	100	0.55555556	0	10	10	10	10
AdaBoost	250	100	0.11111111	0	15	10	15.8113883	10
GradientBoosting	51.1798414	52.6663166	0.77253404	0.47333683	5.76806292	6.15462473	7.15400876	7.257156232
RandomForest	190.42	117.52	0.15368889	-0.1752	12.9	8.6	13.7992753	10.84066419
Bagging_RL	130.765073	93.8425327	0.4188219	0.06157467	10.0047457	7.02537505	11.4352557	9.687235553
Bagging_SVR_rbf	328.278038	200.931934	-0.4590135	1.00931934	14.8217787	10.2207924	18.1184447	14.17504616
Bagging_SVR_poly	5.41025717	17.7724061	0.97595441	0.82227594	2.12615532	3.98377018	2.32599595	4.215733158

Bagging_KNN_w_uniform	337.36	208.16	0.49937778	-1.0816	15	10.4	18.3673624	14.42775104
Bagging_KNN_w_distance	213.0487	140.73021	0.05311689	-0.4073021	12.2995165	8.57295144	14.5961879	11.86297643
Bagging_DT	190.42	117.52	0.15368889	-0.1752	12.9	8.6	13.7992753	10.84066419

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); RMSE (Root Mean Square Error); Presión Sistólica (SBP); Presión Diastólica (DBP)

De igual forma se aplicó la métrica RMSE para la prueba con 6 datos, tal como se muestra en la Tabla 3.12.

Tabla 3.12 Prueba 6 datos

Algoritmos	Métricas							
	MSE		R ²		MAE		RMSE	
	SBP	DBP	SBP	DBP	SBP	DBP	SBP	DBP
RL	227086.479	14738.6694	-9082.45914	-588.546777	353.281903	89.7778657	476.535915	121.4029218
KNN_w_uniform	425	181.25	-16	-6.25	20	12.5	20.6155281	13.46291202
KNN_w_distance	406.146282	175.643042	-15.2458513	-6.02572168	19.4808227	12.2404114	20.1530713	13.25303897
SVR_rbf	807.357745	347.993838	-31.2943098	-12.9197535	27.9681954	17.9681954	28.4140413	18.65459293
SVR_poly	493.849529	160.551642	-18.7539812	-5.4220657	21.6648939	11.6648935	22.2227255	12.67089746
DT	250	125	-9	-4	15	10	15.8113883	11.18033989
AdaBoost	250	125	-9	-4	15	10	15.8113883	11.18033989
GradientBoosting	250.000001	125	-9.00000002	-4.00000002	15	10	15.8113883	11.18033991
RandomForest	387.9025	173.84	-14.5161	-5.9536	19.05	12.2	19.6952405	13.18483978
Bagging_RL	2664.01905	305.193797	-105.560762	-11.2077519	39.2043859	12.7577299	51.6141362	17.4697967
Bagging_SVR_rbf	768.197977	347.656971	-29.7279191	-12.9062788	27.2597315	17.9597315	27.7163846	18.64556169
Bagging_SVR_poly	197.994138	100.710909	-6.9197655	-3.02843635	13.1582266	8.70538612	14.071039	10.03548248
Bagging_KNN_w_uniform	503.515625	221	-19.140625	-7.84	21.875	14	22.4391538	14.86606875
Bagging_KNN_w_distance	487.317209	214.211638	-18.4926884	-7.56846554	21.4780838	13.7324656	22.0752624	14.6359707
Bagging_DT	387.9025	173.84	-14.5161	-5.9536	19.05	12.2	19.6952405	13.18483978

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); RMSE (Raíz del Error Cuadrático Medio); Presión Sistólica (SBP); Presión Diastólica (DBP)

También se aplicó la métrica RMSE para la prueba con la base de datos PPG, tal como se muestra en la Tabla 3.13.

Tabla 3.13 Prueba PPG-BP

Algoritmos	Métricas							
	MSE		R ²		MAE		RMSE	
	SBP	DBP	SBP	DBP	SBP	DBP	SBP	DBP

RL	266.310009	74.8390415	0.22821635	0.16946085	12.1180902	6.87935338	16.3190076	8.650956105
KNN_w_uniform	261.083561	71.7434596	0.24336293	0.20381461	11.9734848	6.83712121	16.1580804	8.470151096
KNN_w_distance	246.018212	71.5467397	0.28702329	0.20599774	11.4216703	6.99173982	15.6849677	8.458530586
SVR_rbf	345.116317	90.1528196	0.00016944	0.00048643	14.3772723	7.44465251	18.5773065	9.494883867
SVR_poly	272.843405	71.6181509	0.20928214	0.20520524	12.0769666	6.67641763	16.5179722	8.462750788
DT	414.818182	203.113636	0.20216996	1.25408854	15.1818182	11.0227273	20.3670857	14.25179415
AdaBoost	241.401607	88.4903144	0.30040251	0.0179635	12.7106601	7.65468987	15.5371042	9.406929065
GradientBoosting	295.817955	108.495382	0.14270041	0.20404618	13.6577135	8.24631814	17.1993592	10.41611165
RandomForest	261.216105	77.6242227	0.24297881	0.13855183	13.2359091	7.07636364	16.1621813	8.810460983
Bagging_RL	265.062666	73.1557394	0.23183123	0.18814159	12.051181	6.79503413	16.2807453	8.553112851
Bagging_SVR_rbf	345.133219	90.1645233	0.00021842	0.00061632	14.2806601	7.44704339	18.5777614	9.495500159
Bagging_SVR_poly	282.944322	65.7706686	0.18000903	0.27009868	12.4451291	6.56299705	16.8209489	8.109911751
Bagging_KNN_w_uniform	292.815523	88.3303165	0.15140165	0.01973911	12.3930682	7.55329545	17.1118533	9.398420957
Bagging_KNN_w_distance	290.211054	86.7671626	0.15894957	0.03708648	12.2113427	7.44939658	17.035582	9.314889298
Bagging_DT	261.444852	77.9531114	0.24231589	0.13490193	13.3211364	7.05068182	16.1692564	8.829105921

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); RMSE (Raíz del Error Cuadrático Medio)
Presión Sistólica (SBP); Presión Diastólica (DBP)

Al aplicar la métrica RMSE también se comprobó que los mejores resultados se obtuvieron con las pruebas de 4 datos, ya que al aumentar los datos los resultados se muestran lejanos de cero lo que indica que no hubo una buena precisión en la predicción de la presión arterial.

Por otra parte también se desarrolló el código para realizar validación cruzada a los algoritmos utilizados para la predicción de la presión arterial para evaluar el desempeño de los algoritmos, utilizando también la métrica RMSE, tal como se muestra en la Tabla 3.14.

Tabla 3.14 Prueba 4 datos CV

Algoritmos	Métricas	
	RMSE	
	SBP	DBP
RL	4.97350513	5.64951388
KNN_w_uniform	18.0277564	14.1421356
KNN_w_distance	12.8568567	10.9500485
SVR_rbf	17.738407	13.8944758
SVR_poly	5.92095598	5.98488819
DT	10	10
AdaBoost	12.9056942	10
GradientBoosting	8.57700438	8.62857812
RandomForest	12.8199417	10.7868952

Bagging_RL	10.8436547	9.49128492
Bagging_SVR_rbf	17.8794806	14.0127725
Bagging_SVR_poly	7.5449848	7.23000383
Bagging_KNN_w_uniform	18.0346698	14.1449649
Bagging_KNN_w_distance	15.1707924	12.3954242
Bagging_DT	12.8199417	10.7868952

*RMSE (Raíz del Error Cuadrático Medio) Presión Sistólica (SBP); Presión Diastólica (DBP)

En la Tabla 3.14 se observa que los resultados de la validación cruzada aplicada a la prueba con 4 datos utilizando la métrica RMSE son los más cercanos posible a cero a diferencia de las otras pruebas realizadas, lo que indica un buen desempeño de los algoritmos en cuanto a precisión.

También se aplicó la validación cruzada a la prueba con 6 datos, tal como se muestra en la Tabla 3.15.

Tabla 3.15 Prueba 6 datos CV

Algoritmos	Métricas	
	RMSE	
	SBP	DBP
RL	165.985879	41.9480698
KNN_w_uniform	14.034544	8.85102732
KNN_w_distance	13.576027	8.73584034
SVR_rbf	20.0137435	13.1371926
SVR_poly	30.4529046	19.1928504
DT	12.1548771	8.02867801
AdaBoost	12.1548771	8.02867801
GradientBoosting	11.6078799	7.58404188
RandomForest	13.0399035	8.47454446
Bagging_RL	24.4280831	9.28673775
Bagging_SVR_rbf	19.5057575	13.1832125
Bagging_SVR_poly	62.0995619	46.9342075
Bagging_KNN_w_uniform	15.1152906	9.96330713
Bagging_KNN_w_distance	14.6735589	9.65811532
Bagging_DT	12.6199397	8.18902012

*RMSE (Raíz del Error Cuadrático Medio) Presión Sistólica (SBP); Presión Diastólica (DBP)

De igual forma se aplicó la validación cruzada a la prueba con la base de datos PPG, tal como se muestra en la Tabla 3.16.

Tabla 3.16 Prueba PPG-BP CV

Algoritmos	Métricas	
	RMSE	
	SBP	DBP
RL	17.8888673	10.469075
KNN_w_uniform	18.4198959	10.4951567
KNN_w_distance	18.1083888	10.4470311
SVR_rbf	20.706657	11.1954507
SVR_poly	18.0590847	10.4836622
DT	23.8917253	14.9283146
AdaBoost	18.7418678	10.693859
GradientBoosting	20.6655667	12.4566976
RandomForest	18.8181593	11.2407905
Bagging_RL	17.938435	10.4815222
Bagging_SVR_rbf	20.7012794	11.1965489
Bagging_SVR_poly	18.973912	10.891721
Bagging_KNN_w_uniform	20.359719	11.4814704
Bagging_KNN_w_distance	20.4234734	11.56765
Bagging_DT	18.8546249	11.2652589

*RMSE (Raíz del Error Cuadrático Medio) Presión Sistólica (SBP); Presión Diastólica (DBP)

Como se pudo observar en las Tablas 3.15 y 3.16 el desempeño de los algoritmos debido al aumento de los datos no mostró buenos resultados ya que se observan más lejanos de cero lo que indica que no hubo un buen desempeño de los algoritmos en cuanto a precisión a pesar de haber utilizado la métrica RMSE.

Por otra parte también se desarrollaron los códigos en el lenguaje de Python para la detección de Hipertensión, con ayuda del software Spyder.

En la Figura 3.41 se muestran los datos que fueron utilizados para entrenar los algoritmos de aprendizaje automático para realizar la detección de Hipertensión. En dicha Figura se muestra que se utilizaron las mismas características de la señal PPG que fueron utilizadas para realizar la estimación de la presión arterial, es decir las características del dominio del tiempo, del dominio de la frecuencia y las características estadísticas pero también se utilizaron las características del dominio del tiempo de la primera y segunda derivadas y como columna objetivo la hipertensión con valores booleanos.

tiempo	frecuencia	estadísticas	vpg	apg	sistólica	hipertensión
0.020172	0.004951	0.011591	0.115057	0.056818	110	0
0.211647	0.012331	0.853358	0.294987	0.178977	119	0
0.362216	0.842396	0.989167	0.301136	1.41046	120	1
0.454545	1.1	0.99875	0.420455	3.5832	125	1

Figura 3.41 Datos para detección de hipertensión normal y baja

En la Tabla 3.17 se muestran los resultados obtenidos de la prueba con 4 datos para el entrenamiento de los algoritmos. En dicha Tabla se muestran las métricas utilizadas para realizar las predicciones es decir MSE (Mean Square Error), R^2 (Coeficiente de determinación) y RMSE (Root Mean Square Error), para la evaluación del desempeño del modelo se utilizó validación cruzada y se aplicó la métrica RMSE para determinar la precisión de los modelos.

Tabla 3.17 Prueba 4 datos

Algoritmos	Métricas					PREDICCIONES	
	MSE	R^2	RMSE	CV RMSE		NORMAL	BAJA
RL	0.28048478	0.12193912	0.52960814	0.94952788			0.75
KNN_w_uniform	0.25	0	0.5	0.5		0.5	
KNN_w_distance	0.28556337	0.14225349	0.5343813	0.45504804			0.89
SVR_rbf	0.25	0	0.5	0.5		0.5	
SVR_poly	0.20370868	0.18516528	0.45134098	0.39087441			0.64
DT	0	1	0	0.35355339		0	1
AdaBoost	0.5	-1	0.70710678	0.70710678			1
GradientBoosting	0.07393455	0.7042618	0.27190908	0.35116038		0.38	1
RandomForest	0.2138	0.1448	0.46238512	0.39882311			0.74
Bagging_RL	0.20456436	0.18174256	0.45228792	0.53833005			0.81
Bagging_SVR_rbf	0.2504	-0.0016	0.50039984	0.50039984		0.48	
Bagging_SVR_poly	0.14317276	0.42730896	0.37838176	0.36017117			0.82
Bagging_KNN_w_uniform	0.2504	-0.0016	0.50039984	0.50039984		0.48	
Bagging_KNN_w_distance	0.23536806	0.05852778	0.48514746	0.46008624			0.68
Bagging_DT	0.2138	0.1448	0.46238512	0.39882311			0.74

*MSE (Error Cuadrático Medio); R^2 (Coeficiente de Determinación); MAE (Error Absoluto Medio); RMSE (Raíz del Error Cuadrático Medio) Presión Sistólica (SBP); Presión Diastólica (DBP); Validación Cruzada (CV)

En la Figura 3.42 se muestran los resultados de las predicciones utilizando el algoritmo Random Forest. En dicha Figura se muestra que el sistema arroja las dos mejores predicciones con la probabilidad BAJA de padecer Hipertensión, los puntajes del MSE son iguales y cercanos a cero, los puntajes del RMSE también son iguales y cercanos a cero y el RMSE promedio también es cercano a cero lo que indica un buen desempeño del modelo.

```
Predicción = 0.60, Categoría = Baja
Predicción = 0.74, Categoría = Baja

Evaluación para Hipertensión:
Error cuadrático medio: 0.2138
Raíz del error cuadrático medio (RMSE): 0.46238512086787564
Coeficiente de determinación (R^2): 0.14480000000000004

Puntajes MSE cross_val_score: [0.2138 0.17 ]
RMSE para cada pliegue: [0.46238512 0.41231056]
RMSE promedio: 0.4373478417148209
```

Figura 3.42 Predicciones normal y baja.

En la Figura 3.43 se muestran los datos que fueron utilizados para entrenar los algoritmos de aprendizaje automático para realizar la detección de Hipertensión. En dicha Figura se muestra que se utilizaron las mismas características de la señal PPG que fueron utilizadas para realizar la estimación de la presión arterial, es decir las características del dominio del tiempo, del dominio de la frecuencia y las características estadísticas pero también se utilizaron las características del dominio del tiempo de la primera y segunda derivadas y como columna objetivo la hipertensión con valores booleanos.

tiempo	frecuencia	estadísticas	vpg	apg	sistólica	hipertensión
0.020172	0.004951	0.011591	0.115057	0.056818	126	0
0.211647	0.012331	0.853358	0.294987	0.178977	129	0
0.362216	0.842396	0.989167	0.301136	1.41046	130	1
0.454545	1.1	0.99875	0.420455	3.5832	139	1

Figura 3.43 Datos para detección de hipertensión media y alta

En la Tabla 3.18 se muestran los resultados obtenidos de la prueba con 4 datos para el entrenamiento de los algoritmos. En dicha Tabla se muestran las métricas utilizadas para realizar las predicciones es decir MSE (Mean Square Error), R^2 (Coeficiente de determinación) y RMSE (Root Mean Square Error), para la evaluación del desempeño del modelo se utilizó validación cruzada y se aplicó la métrica RMSE para determinar la precisión de los modelos.

Tabla 3.18 Prueba 4 datos

Algoritmos	Métricas						
	MSE	R^2	RMSE	CV	PREDICCIONES		
				RMSE	MEDIA	ALTA	
RL	0.121517	0.51393198	0.34859289	0.61860341	0.49		
KNN_w_uniform	0.25	0	0.5	0.5	0.5		
KNN_w_distance	0.17386195	0.30455221	0.41696756	0.44622511	0.49	0.68	
SVR_rbf	0.25	0	0.5	0.5	0.5		
SVR_poly	0.18226515	0.2709394	0.42692523	0.43865657	0.5	0.66	
DT	0	1	0	0.35355339	0	1	
AdaBoost	0.5	-1	0.70710678	0.70710678		1	
GradientBoosting	0.01042273	0.95830907	0.10209178	0.35116038	0.14		
RandomForest	0.149	0.404	0.38600518	0.39915787	0.48	0.74	
Bagging_RL	0.11345566	0.54617737	0.3368318	0.3939344	0.48		
Bagging_SVR_rbf	0.2504	-0.0016	0.50039984	0.50039984	0.48		
Bagging_SVR_poly	0.10609491	0.57562036	0.32572214	0.39390084	0.46		
Bagging_KNN_w_uniform	0.2504	-0.0016	0.50039984	0.50039984	0.48		
Bagging_KNN_w_distance	0.20514013	0.17943948	0.45292398	0.46591589	0.48	0.57	
Bagging_DT	0.1396	0.4416	0.37363083	0.39953589	0.46	0.74	

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); RMSE (Raíz del Error Cuadrático Medio) Presión Sistólica (SBP); Presión Diastólica (DBP)

En la Figura 3.44 se muestran los resultados de las predicciones utilizando el algoritmo Árbol de decisión Bagging. En dicha Figura se muestra que el sistema arroja las dos mejores predicciones con la probabilidad ALTA de padecer Hipertensión, los puntajes del MSE son iguales y cercanos a cero, los puntajes del RMSE también son iguales y cercanos a cero y el RMSE promedio también es cercano a cero lo que indica un buen desempeño del modelo.

```

Predicción = 0.60, Categoría = Alta
Predicción = 0.74, Categoría = Alta

Evaluación para Hipertensión:
Error cuadrático medio: 0.2138
Raíz del error cuadrático medio (RMSE): 0.46238512086787564
Coeficiente de determinación (R^2): 0.14480000000000004

Puntajes MSE cross_val_score: [0.2138 0.181 ]
RMSE para cada pliegue: [0.46238512 0.42544095]
RMSE promedio: 0.44391303429576434

```

Figura 3.44 Predicciones media y alta.

Cabe mencionar que las pruebas para detección de Hipertensión como más de 4 datos no se muestran debido a que al utilizar 5 datos por columna los resultados no muestran coherencia y al utilizar 6 datos por columna los resultados que se obtuvieron son perfectos esto quiere decir que el sistema está memorizando.

Por otra parte también se desarrollaron los códigos en el lenguaje de Python para la detección de Arteriosclerosis, con ayuda del software Spyder.

En la Figura 3.45 se muestran los datos que fueron utilizados para entrenar los algoritmos de aprendizaje automático para realizar la detección de Arteriosclerosis. En dicha Figura se muestra que se utilizaron las mismas características de la señal PPG que fueron utilizadas para realizar la estimación de la presión arterial, es decir las características del dominio del tiempo, del dominio de la frecuencia y las características estadísticas pero también se utilizaron las características del dominio del tiempo de la primera y segunda derivadas y como columna objetivo la Arteriosclerosis con valores booleanos.

tiempo	frecuencia	estadísticas	vpg	apg	sistólica	arteriosclerosis
0.020172	0.004951	0.011591	0.115057	0.056818	110	0
0.211647	0.012331	0.853358	0.294987	0.178977	119	0
0.362216	0.842396	0.989167	0.301136	1.41046	120	1
0.454545	1.1	0.99875	0.420455	3.5832	129	1

Figura 3.45 Datos para detección de arteriosclerosis normal y baja

En la Tabla 3.19 se muestran los resultados obtenidos de la prueba con 4 datos para el entrenamiento de los algoritmos. En dicha Tabla se muestran las métricas utilizadas para realizar las predicciones es decir MSE (Mean Square Error), R^2 (Coeficiente de determinación) y RMSE (Root Mean Square Error), para la evaluación del desempeño del modelo se utilizó validación cruzada y se aplicó la métrica RMSE para determinar la precisión de los modelos.

Tabla 3.19 Prueba 4 datos

Algoritmos	Métricas					PREDICCIONES	
	MSE	R ²	RMSE	CV RMSE		NORMAL	BAJA
RL	0.38626133	0.54504532	0.62149926	0.86207171			0.88
KNN_w_uniform	0.25	0	0.5	0.5		0.5	
KNN_w_distance	0.39993165	0.59972661	0.6324015	0.6328273			0.83
SVR_rbf	0.25000002	-7.13E-08	0.50000002	0.50000002		0.5	0.5
SVR_poly	0.19780502	0.20877993	0.44475276	0.45372384			0.69
DT	0	1	0	0.35355339		0	1
AdaBoost	0.5	-1	0.70710678	0.70710678			1
GradientBoosting	0.07393455	0.7042618	0.27190908	0.43606903		0.38	
RandomForest	0.2138	0.1448	0.46238512	0.43734784			0.74
Bagging_RL	0.22919496	0.08322015	0.47874311	0.51100065			0.68
Bagging_SVR_rbf	0.25040001	0.00160004	0.50039985	0.50039985		0.48	
Bagging_SVR_poly	0.20202483	0.19190067	0.44947173	0.48400846			0.64
Bagging_KNN_w_uniform	0.2504	-0.0016	0.50039984	0.50039984		0.48	
Bagging_KNN_w_distance	0.3052478	0.22099119	0.55249235	0.55731852			0.65
Bagging_DT	0.2138	0.1448	0.46238512	0.44391303			0.74

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); RMSE (Raíz del Error Cuadrático Medio) Presión Sistólica (SBP); Presión Diastólica (DBP)

En la Figura 3.46 se muestran los resultados de las predicciones utilizando el algoritmo Random Forest. En dicha Figura se muestra que el sistema arroja las dos mejores predicciones con la probabilidad BAJA de padecer Arteriosclerosis, los puntajes del MSE son iguales y cercanos a cero, los puntajes del RMSE también son iguales y cercanos a cero y el RMSE promedio también es cercano a cero lo que indica un buen desempeño del modelo.

```

Predicción = 0.60, Categoría = Baja
Predicción = 0.74, Categoría = Baja

Evaluación para Arteriosclerosis:
Error cuadrático medio: 0.2138
Raíz del error cuadrático medio (RMSE): 0.46238512086787564
Coeficiente de determinación (R^2): 0.14480000000000004

Puntajes MSE cross_val_score: [0.2138 0.17 ]
RMSE para cada pliegue: [0.46238512 0.41231056]
RMSE promedio: 0.4373478417148209

```

Figura 3.46 Predicciones normal y baja

En la Figura 3.47 se muestran los datos que fueron utilizados para entrenar los algoritmos de aprendizaje automático para realizar la detección de Arteriosclerosis. En dicha Figura se muestra que se utilizaron las mismas características de la señal PPG que fueron utilizadas para realizar la estimación de la presión arterial, es decir las características del dominio del tiempo, del dominio de la frecuencia y las características estadísticas pero también se utilizaron las características del dominio del tiempo de la primera y segunda derivadas y como columna objetivo la Arteriosclerosis con valores booleanos.

tiempo	frecuencia	estadísticas	vpg	apg	sistólica	arteriosclerosis
0.020172	0.004951	0.011591	0.115057	0.056818	130	0
0.211647	0.012331	0.853358	0.294987	0.178977	139	0
0.362216	0.842396	0.989167	0.301136	1.41046	140	1
0.454545	1.1	0.99875	0.420455	3.5832	149	1

Figura 3.47 Datos para detección de arteriosclerosis media y alta

En la Tabla 3.20 se muestran los resultados obtenidos de la prueba con 4 datos para el entrenamiento de los algoritmos. En dicha Tabla se muestran las métricas utilizadas para realizar las predicciones es decir MSE (Mean Square Error), R^2 (Coeficiente de determinación) y RMSE (Root Mean Square Error), para la evaluación del desempeño del modelo se utilizó validación cruzada y se aplicó la métrica RMSE para determinar la precisión de los modelos.

Tabla 3.20 Prueba 4 datos

Algoritmos	Métricas					PREDICCIONES	
	MSE	R ²	RMSE	CV RMSE		MEDIA	ALTA
RL	0.38626133	0.54504532	0.62149926	0.86207171		0.88	
KNN_w_uniform	0.25	0	0.5	0.5	0.5		
KNN_w_distance	0.39993165	0.59972661	0.6324015	0.6328273		0.83	
SVR_rbf	0.25000002	-7.13E-08	0.50000002	0.50000002	0.5	0.5	
SVR_poly	0.20926142	0.1629543	0.45745101	0.46374102		0.63	
DT	0	1	0	0.35355339	0	1	
AdaBoost	0.5	-1	0.70710678	0.70710678		1	
GradientBoosting	0.07393455	0.7042618	0.27190908	0.43606903	0.38		
RandomForest	0.2138	0.1448	0.46238512	0.43734784		0.74	
Bagging_RL	0.22919496	0.08322015	0.47874311	0.51100065		0.68	
Bagging_SVR_rbf	0.25040001	0.00160004	0.50039985	0.50039985	0.48		
Bagging_SVR_poly	0.18062329	0.27750685	0.42499799	0.4457527		0.6	
Bagging_KNN_w_uniform	0.2504	-0.0016	0.50039984	0.50039984	0.48		
Bagging_KNN_w_distance	0.3052478	0.22099119	0.55249235	0.55731852		0.65	
Bagging_DT	0.2138	0.1448	0.46238512	0.44391303		0.74	

*MSE (Error Cuadrático Medio); R² (Coeficiente de Determinación); MAE (Error Absoluto Medio); RMSE (Raíz del Error Cuadrático Medio) Presión Sistólica (SBP); Presión Diastólica (DBP)

En la Figura 3.48 se muestran los resultados de las predicciones utilizando el algoritmo Random Forest. En dicha Figura se muestra que el sistema arroja las dos mejores predicciones con la probabilidad ALTA de padecer Arteriosclerosis, los puntajes del MSE son iguales y cercanos a cero, los puntajes del RMSE también son iguales y cercanos a cero y el RMSE promedio también es cercano a cero lo que indica un buen desempeño del modelo.

```
Predicción = 0.60, Categoría = Alta
Predicción = 0.74, Categoría = Alta

Evaluación para Arteriosclerosis:
Error cuadrático medio: 0.2138
Raíz del error cuadrático medio (RMSE): 0.46238512086787564
Coeficiente de determinación (R^2): 0.14480000000000004

Puntajes MSE cross_val_score: [0.2138 0.181 ]
RMSE para cada pliegue: [0.46238512 0.42544095]
RMSE promedio: 0.44391303429576434
```

Figura 3.48 Predicciones media y alta

Se concluye que después de obtener las características morfológicas de los dominios del tiempo, frecuencia y estadísticas de la señal PPG para realizar la estimación de la presión arterial y confirmar que al utilizar más de 4 características de cada dominio se obtuvieron resultados con sobreajuste, se procedió a realizar las mismas pruebas para identificar el riesgo de hipertensión y arteriosclerosis obteniendo de igual manera resultados con sobreajuste. Lo cual nos confirmó una vez más que no se requieren muchos datos al realizar pruebas con valores continuos por lo que las pruebas para la identificación del riesgo de hipertensión y arteriosclerosis se realizaron con 4 características de cada dominio.

Para dichas pruebas se utilizó también la métrica RMSE (Root Mean Square Error) para obtener resultados directos de la precisión de las predicciones. Por otra parte, se aplicó validación cruzada para evaluar el desempeño de los algoritmos utilizados y se obtuvieron las curvas ROC para ver de manera gráfica la precisión de las predicciones sobre dichos padecimientos.

Los mejores resultados para la identificación del riesgo de hipertensión se obtuvieron con los algoritmos: RL, KNN, SVR, RF, RLBagging, KNNBagging, SVRBagging y DTBagging. Por otra parte, los mejores resultados para la identificación del riesgo de arteriosclerosis se obtuvieron con los algoritmos: RL, KNN, SVR, RF, RLBagging y DTBagging.

CAPÍTULO 4. RESULTADOS Y DISCUSIÓN

En este capítulo se describe la validación de los resultados obtenidos de los algoritmos de aprendizaje automático con ayuda de expertos en el área de la salud, a través de por lo menos un caso de estudio. Por otra parte se presenta un análisis de los hallazgos de esta investigación.

4.1 Resultados

Para esta validación se recolectaron 110 señales fotopletismográficas (PPG) con el apoyo de la Fundación Doctor Hernández Zurita (*Fundación Oftalmológica*, s/f), dichas señales PPG se obtuvieron de sujetos de estudio entre hombres y mujeres con edades de entre 20 y 90 años que presentan diferentes padecimientos cardiovasculares como diabetes, hipertensión y problemas cardiacos, cabe mencionar que también se tomaron en cuenta sujetos de estudio que no presentaron ningún padecimiento cardiovascular es decir sujetos sanos. En la Figura 4.1 se muestran 3 de los 110 sujetos de estudio quienes participaron en la recolección de las señales PPG en las instalaciones de la Fundación (véase tabla “Datos basales de los sujetos de estudio” en la sección de anexos).



Figura 4.1 participantes para el estudio con pacientes de la Fundación Doctor Hernández Zurita.

Cabe señalar que, al adquirir señales PPG, la posición de los dedos, el movimiento y la presión aplicada al sensor PPG pueden afectar a la calidad de la señal. Incluso la luz ambiental puede introducir ruido en la señal del sensor. Sin embargo, estos problemas se resuelven gracias a las características de diseño de la tarjeta de adquisición de señales cardíacas Max86150. Estas características se enumeran a continuación:

- Amplificador de instrumentación para eliminar el ruido de entrada.
- Filtro adaptativo que actúa en el dominio del tiempo.
- Filtro notch para establecer la frecuencia de funcionamiento.
- Filtro de paso bajo para dejar pasar las frecuencias de señal deseadas.
- Función de control automático de ganancia para ajustar dinámicamente la corriente de los LED rojos e infrarrojos del sensor PPG.
- Función para cancelar la luz ambiental.
- Función de proximidad para detectar la posición del dedo en el sensor PPG. Estas son solo algunas de las funciones de la tarjeta Max86150.

Posteriormente se realizó el procesamiento y extracción de características de dichas señales PPG, la extracción de características se realizó en el dominio del tiempo, el dominio de la frecuencia y características estadísticas (véase tabla “Características morfológicas de la señal PPG” en la sección de anexos), también se calcularon la primera y segunda derivadas de las señales PPG incluyendo la extracción de características en el dominio del tiempo de las derivadas de las señales para poder realizar la estimación de la presión arterial, identificar el riesgo de hipertensión y arteriosclerosis, y verificar la correlación entre estos dos padecimientos con el apoyo de los algoritmos de aprendizaje automático.

Antes de realizar el procesamiento y extracción de características de las señales PPG se realizó un análisis de la morfología de cada una de las señales para descartar aquellas señales PPG que no cumplen con una morfología bien definida de este tipo de señales. Dicho análisis morfológico consistió en verificar que la señales cumplen con los segmentos de la señal PPG como por ejemplo; el origen de la señal, fase anacrótica, pico sistólico, fase catacrótica, muesca dicrótica y pico diastólico. Cabe señalar que al procesar la señal PPG resulta difícil

encontrar la muesca dicrótica, especialmente en adultos mayores. Sin embargo, esto se logró gracias a los siguientes aspectos:

- La tarjeta de adquisición de señales cardíacas Max86150 nos proporciona señales PPG con el menor ruido posible.
- Aunque nuestro sistema tiene sus limitaciones, nuestro código Python para el procesamiento de señales PPG, aunque es capaz de detectar el pico sistólico, aún requiere mejoras para que el sistema no confunda la muesca diastólica con el pico diastólico.

Dicho análisis fue necesario debido a que los sujetos de estudio al momento de recolectar su señal PPG presentaron en algunos casos síntomas como el síndrome de la bata blanca, estaban nerviosos por el hecho de ver la tarjeta de adquisición de señales cardíacas o presentaban acrofobia (miedo a las alturas) por la altura del edificio de la Fundación Doctor Hernández Zurita, ya que la recolección de las señales PPG se realizó en el cuarto piso del edificio de la Fundación. Este edificio tiene ventanas de suelo a techo, lo que permite una vista completa del exterior, lo que provoca acrofobia en los sujetos de estudio, además, los sujetos de estudio proceden de diferentes regiones rurales y muchos de ellos no están acostumbrados a estar en alturas, lo que afecta a las lecturas, también se presentaron artefactos de movimiento, miedo a recibir una descarga eléctrica al tocar la tarjeta Max86150 y en otros casos mala posición de la yema del dedo sobre el sensor PPG, además del miedo que experimentan los sujetos de estudio al descubrir que tienen otros padecimientos a parte de los que ya tienen conocimiento. Todos estos inconvenientes generaron que varias señales tuvieran que ser descartadas porque no eran viables para este estudio.

Una vez hecho este análisis se descartaron 80 señales y se utilizaron las 30 señales restantes para el procesamiento, extracción de características y análisis cardiovascular de las mismas, en total se realizaron 150 pruebas de análisis cardiovascular de las señales PPG utilizando 15 algoritmos de aprendizaje automático para cada señal.

4.1.1 Sujeto saludable (S2)

En la Figura 4.2 se muestra el procesamiento de la señal PPG que consiste en el graficado de la señal PPG filtrada y el graficado de la primera y segunda derivadas obtenidas de la señal recolectada del sujeto de estudio S2 (Masculino, 43 años, Sano) con apoyo de la tarjeta Max 86150.




Figura 4.2 Señal PPG S2

Cabe señalar que la eliminación de la línea de base de la señal PPG se logra gracias a las características del diseño exclusivo de la tarjeta de adquisición de señales cardíacas Max86150. Estas características se enumeran a continuación:

- Amplificador de instrumentación para eliminar el ruido de entrada.
- Filtro adaptativo que actúa en el dominio del tiempo.
- Filtro notch para establecer la frecuencia de funcionamiento.
- Filtro de paso bajo para permitir el paso de las frecuencias deseadas de la señal.
- Hay una función de control automático de ganancia para ajustar dinámicamente la corriente de los LED rojos e infrarrojos del sensor PPG.
- Hay una función para cancelar la luz ambiental.

- Cuenta con una función de proximidad para detectar la posición del dedo en el sensor PPG, por mencionar solo algunas de las funciones de la tarjeta Max86150.
- Nuestro código Python para el procesamiento de señales PPG.

Cabe mencionar que una vez realizado el procesamiento de la señal S2 se observó que la gráfica de la señal PPG filtrada se mostraba al revés en forma horizontal esto es porque la tarjeta Max 86150 al recolectar las señales PPG las muestra al revés debido a la forma en que los dispositivos electrónicos y el sensor PPG de dicha tarjeta procesan las señales por cuestiones de diseño de la misma. Por lo tanto se procedió a realizar la programación en el lenguaje de Python con ayuda del software Spyder que permitiera mostrar la señal PPG invertida al realizar el procesamiento de la misma, lo cual ayudó a corregir las gráficas de la señal PPG filtrada y las gráficas de las derivadas, tal como se muestra en la Figura 4.3.




Figura 4.3 Señal S2 invertida

En la Tabla 4.1 se muestran los resultados del análisis de la señal PPG del sujeto S2 para la estimación de la presión arterial, donde se observa que lo mejores resultados de las predicciones se obtuvieron con los algoritmos KNN y RL BAGGING, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático Medio), R^2 (Coeficiente de determinación) y RMSE (Raíz del Error Cuadrático Medio),

además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño de los algoritmos.

Tabla 4.1 Validación Sujeto S2 (SANO) PA

Algoritmos	Métricas							
	MSE		R ²		RMSE		RMSE (CV)	
	SBP	DBP	SBP	DBP	SBP	DBP	SBP	DBP
KNN_w_distance	114.463695	44.8830554	4.65252815	1.21644718	10.6987707	6.69948172	13.0435943	7.52189411
Bagging_RL	40.4652578	6.32281631	0.99828434	0.68776216	6.36123084	2.51452109	10.501906	5.05354269

En la Figura 4.4 se muestra la gráfica de la presión arterial de la señal PPG del sujeto S2 donde se observa que el sistema arroja las dos mejores predicciones para la estimación de la presión arterial que son, predicción 1: 100 mmHg para la sístole y 66.5 mmHg para la diástole y predicción 2: 107 mmHg para la sístole y 71 mmHg para la diástole, lo que indica en cualquier caso una presión arterial normal de acuerdo con los niveles de presión arterial de la norma americana de cardiología (*AHA Research Grant Funding Opportunities*, s/f).




Figura 4.4 Gráfica de la presión arterial del sujeto S2

En la Tabla 4.2 se muestran los resultados del análisis de la señal PPG del sujeto S2 para la identificación de riesgo de hipertensión, donde se observa que lo mejores resultados de las predicciones se obtuvieron con los algoritmos KNN y RL BAGGING, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático

Medio), R^2 (Coeficiente de determinación) y RMSE (Raíz del Error Cuadrático Medio), además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño de los algoritmos. En dicha tabla se observa que las dos predicciones para la categoría elevada no son confiables ya que 0.68 no es un valor por arriba de 70 % y 1 es un resultado perfecto y de acuerdo con la literatura este valor indica que el sistema está memorizando por lo tanto nos quedamos con los valores de 0.43 y 0.44 que indican que la categoría de la presión arterial es normal de acuerdo con las reglas de clasificación que se establecieron para esta prueba (Carlini et al., 2023), (Dhar et al., 2019).

Tabla 4.2 S2 HTA

Algoritmos	Métricas				PREDICCIONES	
	MSE	R^2	RMSE	CV RMSE	NORMAL	ELEVADA
KNN_w_distance	0.14495632	0.4201747	0.3807313	0.41336409	0.43	0.68
Bagging_RL	0.09832275	0.606709	0.31356459	0.37501865	0.44	1

En la Tabla 4.3 se muestran los resultados del análisis de la señal PPG del sujeto S2 para la identificación de riesgo de arteriosclerosis, donde se observa que lo mejores resultados de las predicciones se obtuvieron con los algoritmos KNN y RL BAGGING, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático Medio), R^2 (Coeficiente de determinación) y RMSE (Raíz del Error Cuadrático Medio), además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño de los algoritmos. En dicha tabla se observa que las dos predicciones para la categoría baja no son confiables ya que 0.68 no es un valor por arriba de 70% y 1 es un resultado perfecto y de acuerdo con la literatura este valor indica que el sistema está memorizando por lo tanto nos quedamos con los valores de 0.43 y 0.44 que indican que la categoría del riesgo de arteriosclerosis es nula de acuerdo con las reglas de clasificación que se establecieron para esta prueba (*AHA Research Grant Funding Opportunities*, s/f).

Tabla 4.3 S2 AS1

Algoritmos	Métricas				PREDICCIONES	
	MSE	R ²	RMSE	CV RMSE	NULA	BAJA
KNN_w_distance	0.14495632	0.4201747	0.3807313	0.41336409	0.43	0.68
Bagging_RL	0.09832275	0.606709	0.31356459	0.37501865	0.44	1

4.1.2 Sujeto Diabético (S4)

En la Figura 4.5 se muestra el procesamiento de la señal PPG que consiste en el graficado de la señal PPG filtrada y el graficado de la primera y segunda derivadas obtenidas de la señal recolectada del sujeto de estudio S4 (Masculino, 48 años, Diabético) con apoyo de la tarjeta Max 86150.




Figura 4.5 Señal S4 invertida

En la Tabla 4.4 se muestran los resultados del análisis de la señal PPG del sujeto S4 para la estimación de la presión arterial, donde se observa que lo mejores resultados de las predicciones se obtuvieron con los algoritmos KNN y RL BAGGING, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático Medio), R^2 (Coeficiente de determinación) y RMSE (Raíz del Error Cuadrático Medio), además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño de los algoritmos.

Tabla 4.4 Validación Sujeto S4 (DIABÉTICO) PA

Algoritmos	Métricas							
	MSE		R ²		RMSE		RMSE (CV)	
	SBP	DBP	SBP	DBP	SBP	DBP	SBP	DBP
KNN_w_distance	114.347872	47.9495273	4.64680848	1.36787789	10.6933564	6.92455972	13.0484241	7.66986597
Bagging_RL	50.0419466	5.93115604	1.47120724	0.70710341	7.07403326	2.43539649	10.9254026	5.09284567

En la Figura 4.6 se muestra la gráfica de la presión arterial de la señal PPG del sujeto S4 donde se observa que el sistema arroja las dos mejores predicciones para la estimación de la presión arterial que son, predicción 1: 102.5 mmHg para la sístole y 67.5 mmHg para la diástole y predicción 2: 106 mmHg para la sístole y 69.5 mmHg para la diástole, lo que indica en cualquier caso una presión arterial normal de acuerdo con los niveles de presión arterial de la norma americana de cardiología (*AHA Research Grant Funding Opportunities*, s/f).




Figura 4.6 Gráfica de la presión arterial del sujeto S4

En la Tabla 4.5 se muestran los resultados del análisis de la señal PPG del sujeto S4 para la identificación de riesgo de hipertensión, donde se observa que los mejores resultados de las predicciones se obtuvieron con los algoritmos KNN y RL BAGGING, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático Medio), R^2 (Coeficiente de determinación) y RMSE (Raíz del Error Cuadrático Medio), además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño de los algoritmos. En dicha tabla se observa que las dos predicciones para la categoría elevada

no son confiables ya que 0.64 no es un valor por arriba de 70 % y 1 es un resultado perfecto y de acuerdo con la literatura este valor indica que el sistema está memorizando por lo tanto nos quedamos con el valor de 0.48 que indica que la categoría de la presión arterial es normal de acuerdo con las reglas de clasificación que se establecieron para esta prueba (Carlini et al., 2023), (Dhar et al., 2019).

Tabla 4.5 S4 HTA1

Algoritmos	Métricas				PREDICCIONES	
	MSE	R ²	RMSE	CV RMSE	NORMAL	ELEVADA
KNN_w_distance	0.19234829	0.23060683	0.4385753	0.48133115		0.64
Bagging_RL	0.115845	0.53662002	0.3403601	0.4466637	0.48	1

En la Tabla 4.6 se muestran los resultados del análisis de la señal PPG del sujeto S4 para la identificación de riesgo de arteriosclerosis, donde se observa que lo mejores resultados de las predicciones se obtuvieron con el algoritmo KNN, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático Medio), R^2 (Coeficiente de determinación) y RMSE (Raíz del Error Cuadrático Medio), además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño de los algoritmos. En dicha tabla se observa que la predicción para la categoría baja no es confiable ya que 0.50 no es un valor por arriba de 70 % y de acuerdo con la literatura este valor indica indecisión es decir que el sistema no está seguro del resultado por lo tanto nos quedamos con el valor de 0.48 que indica que la categoría del riesgo de arteriosclerosis es nula de acuerdo con las reglas de clasificación que se establecieron para esta prueba.

Tabla 4.6 S4 AS1

Algoritmos	Métricas				PREDICCIONES	
	MSE	R ²	RMSE	CV RMSE	NULA	BAJA
KNN_w_distance	0.19234829	0.23060683	0.4385753	0.48133115	0.48	0.5

4.1.3 Sujeto Hipertenso y Diabético (S14)

En la Figura 4.7 se muestra el procesamiento de la señal PPG que consiste en el graficado de la señal PPG filtrada y el graficado de la primera y segunda derivadas obtenidas de la señal recolectada del sujeto de estudio S14 (Masculino, 69 años, Hipertenso y Diabético) con apoyo de la tarjeta Max 86150.




Figura 4.7 Señal S14 invertida

En la Tabla 4.7 se muestran los resultados del análisis de la señal PPG del sujeto S14 para la estimación de la presión arterial, donde se observa que los mejores resultados de las predicciones se obtuvieron con el algoritmo RL BAGGING, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático Medio), R^2 (Coeficiente de determinación) y RMSE (Raíz del Error Cuadrático Medio), además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño del algoritmo.

Tabla 4.7 Validación Sujeto S14 (HIPERTENSO Y DIABÉTICO) PA

Algoritmos	Métricas							
	MSE		R ²		RMSE		RMSE (CV)	
	SBP	DBP	SBP	DBP	SBP	DBP	SBP	DBP
Bagging_RL	606.113844	188.0911	28.9315478	8.28844937	24.6193794	13.7146309	20.0725919	11.1174032

En la Figura 4.8 se muestra la gráfica de la presión arterial de la señal PPG del sujeto S14 donde se observa que el sistema arroja las dos mejores predicciones para la estimación de la presión arterial que son, predicción 1: 100 mmHg para la sístole y 65 mmHg para la diástole y predicción 2: 150 mmHg para la sístole y 100 mmHg para la diástole, lo que indica que la predicción 2 muestra hipertensión nivel 2 de acuerdo con los niveles de presión arterial de la norma americana de cardiología (*AHA Research Grant Funding Opportunities*, s/f).




Figura 4.8 Gráfica de la presión arterial del sujeto S14

En la Tabla 4.8 se muestran los resultados del análisis de la señal PPG del sujeto S14 para la identificación de riesgo de hipertensión, donde se observa que lo mejores resultados de las predicciones se obtuvieron con el algoritmo RL BAGGING, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático Medio), R^2 (Coeficiente de determinación) y RMSE (Raíz del Error Cuadrático Medio), además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño de los algoritmos. En dicha tabla se observa que la predicción para la categoría nivel 2 muestra un valor confiable de 74 % por lo tanto indica un riesgo de hipertensión nivel 2 de

acuerdo con las reglas de clasificación que se establecieron para esta prueba (*AHA Research Grant Funding Opportunities*, s/f).

Tabla 4.8 S14 HTA2

Métricas						
Algoritmos	MSE	R ²	RMSE	CV	PREDICCIONES	
				RMSE	NIVEL 1	NIVEL 2
Bagging_RL	0.09298517	0.62805933	0.30493469	0.79458069	0.43	0.74

En la Tabla 4.9 se muestran los resultados del análisis de la señal PPG del sujeto S14 para la identificación de riesgo de arteriosclerosis, donde se observa que lo mejores resultados de las predicciones se obtuvieron con el algoritmo RL BAGGING, también se muestran las métricas utilizadas para la evaluación de dichos algoritmos como: MSE (Error Cuadrático Medio), R^2 (Coeficiente de determinación) y RMSE (Raí del Error Cuadrático Medio), además de la validación cruzada realizada con la métrica RMSE para evaluar el desempeño de los algoritmos. En dicha tabla se observa que la predicción para la categoría alta muestra un valor confiable de 74 % por lo tanto indica un riesgo de arteriosclerosis de acuerdo con las reglas de clasificación que se establecieron para esta prueba.

Tabla 4.9 S14 AS2

Métricas						
Algoritmos	MSE	R ²	RMSE	CV	PREDICCIONES	
				RMSE	MEDIA	ALTA
Bagging_RL	0.09298517	0.62805933	0.30493469	0.79458069	0.43	0.74

Por otro lado, la Tabla 4.10 muestra los resultados del intervalo de confianza aplicado al algoritmo KNN_w_distance, que fue el que obtuvo la mejor precisión en su rendimiento, con un intervalo de confianza del 95 % tanto en la estimación de la presión arterial sistólica (SBP) como en la estimación de la presión arterial diastólica (DBP). Estos resultados se obtuvieron utilizando el lenguaje Python 3.10 con la ayuda del software Spyder versión 5.4.1.

Tabla 4.10 Intervalo de confianza de la presión arterial

Presión arterial	Mediciones
SBP	Predicción promedio = 103.30
SBP	Intervalo de confianza 95% = [90.00, 115.00]
DBP	Predicción promedio = 67.64
DBP	Intervalo de confianza 95% = [60.00, 75.00]

Por último, los resultados nos permiten confirmar la correlación entre el riesgo de hipertensión y la arteriosclerosis. De acuerdo con la literatura médica, un tratamiento o cuidado inadecuado de la hipertensión aumenta el riesgo de arteriosclerosis (*Hipertensión, s/f*).

4.2 Discusión

Como se pudo observar en esta sección, uno de los retos de la adquisición, procesamiento y análisis de las señales PPG fue que los sujetos de estudio al momento de recolectar su señal PPG presentaron en algunos casos síntomas como el síndrome de la bata blanca, o estaban nerviosos por el hecho de ver la tarjeta de adquisición de señales cardíacas, o presentaban acrofobia (miedo a las alturas) por la altura del edificio de la Fundación Doctor Hernández Zurita, también se presentaron artefactos de movimiento y en otros casos una posición incorrecta de la yema del dedo sobre el sensor PPG, además del miedo que experimentan los sujetos de estudio por descubrir que tienen otros padecimientos a parte de los que ya tienen conocimiento, todos estos inconvenientes generaron que varias señales tuvieran que ser descartadas porque no eran viables para este estudio. Por lo tanto es recomendable que la autogestión de la salud cardiovascular sea llevada a cabo de manera domiciliar en donde el sujeto de estudio se sienta cómodo, seguro y tranquilo para que las señales PPG no sufran alteraciones.

Por otro lado, una limitación de este estudio fue que la tarjeta de adquisición de señales cardíacas Max 86150 cuenta con la certificación de la FDA, sin embargo, esta certificación se refiere a diseños compactos de bajo consumo, como la tarjeta Max 86150, que incluyen teléfonos móviles, ordenadores portátiles, tabletas y altavoces inteligentes, no es una certificación para su uso en entornos clínicos; sin embargo, al ser un dispositivo desarrollado

por Analog Devices, una empresa estadounidense reconocida mundialmente por el diseño y desarrollo de soluciones de presión arterial no invasivas, consideramos que el uso de la Max 86150 y su rendimiento son viables y fiables para el desarrollo de este tipo de proyectos de investigación, en lugar de utilizar un prototipo de diseño propio, poniendo en riesgo la fiabilidad de los datos recopilados (*Módulo de biosensores integrado de PPG y ECG para dispositivos móviles MAX86150*, s/f).

CONCLUSIONES Y TRABAJO FUTURO

En este estudio experimental, comparamos el rendimiento de quince algoritmos de aprendizaje automático para estimar la presión arterial mediante un método no invasivo a través de señales PPG e identificar el riesgo de hipertensión y su correlación con la arteriosclerosis utilizando diferentes métricas con la estrategia de división de entrenamiento-prueba y métodos de validación cruzada k-fold. Nuestros principales hallazgos revelaron que los algoritmos de aprendizaje automático analizados que mostraron el mejor rendimiento para la estimación de la presión arterial fueron la regresión lineal, el SVR polinómico, el GradientBoosting y el SVR polinómico bagging utilizando métricas MSE y RMSE. Los algoritmos de aprendizaje automático analizados que mostraron el mejor rendimiento para identificar el riesgo de hipertensión fueron la regresión lineal, KNN, SVR, RF, LR bagging, KNN bagging, SVR bagging y DT bagging utilizando métricas MSE y RMSE. Los algoritmos de aprendizaje automático analizados que mostraron el mejor rendimiento para identificar el riesgo relacionado con la aterosclerosis fueron la regresión lineal, KNN, SVR, RF, LR bagging y DT bagging. La principal contribución de esta investigación es validar los mejores modelos de riesgo. Estos resultados sugieren que esta investigación es prometedora y ofrece información valiosa sobre la adquisición y el procesamiento de señales PPG. Sin embargo, dado que se trata de un estudio experimental, la eficacia de nuestro modelo debe validarse con una base de datos más amplia antes de utilizarlo en un entorno clínico. Por otro lado, este modelo representa una herramienta de apoyo para los especialistas sanitarios en la detección temprana de la salud cardiovascular, lo que permite a las personas autogestionar su salud y buscar atención médica en una fase temprana.

En cuanto al trabajo futuro, consideramos los siguientes objetivos: 1) Recopilar señales PPG en los hogares de los sujetos del estudio (o pedirles que monitoricen sus propias señales PPG) para evitar el síndrome de la bata blanca y otros tipos de estrés que experimentan los sujetos del estudio cuando se someten a estudios clínicos en instituciones médicas, y para evitar descartar señales que no se ajustan a la morfología de las señales PPG; 2) Utilizar otros dispositivos aprobados por la FDA para la adquisición de señales PPG, incluidos los dispositivos portátiles; 3) Detectar otras anomalías en el sistema arterial basándose en la morfología de las señales PPG y sus derivadas, que indican a los especialistas sanitarios el riesgo de hipertensión y arteriosclerosis; 4) Detectar otras enfermedades relacionadas con el sistema cardiovascular mediante fotopletimografía, y 5) Desarrollar servicios y una plataforma web para el uso de algoritmos de aprendizaje automático identificados como los mejores para la detección precoz de la hipertensión y la arteriosclerosis, que sirvan de apoyo al público en general y en la toma de decisiones de los especialistas sanitarios.

RECOMENDACIONES

Aunque el uso de bibliotecas especializadas en el procesamiento de señales biomédicas como BIOBSS, fue de gran ayuda para el desarrollo de esta Tesis Doctoral si representó un gran reto cuando dicha biblioteca dejó de funcionar debido a la incompatibilidad de sus paquetes de funciones o por falta de actualizaciones de software. Esta situación se pudo resolver a marchas forzadas y de manera inesperada al desarrollar nuestro propio código para el procesamiento de las señales PPG tomando como guía los códigos de los paquetes de funciones de la biblioteca BIOBSS.

REFERENCIAS BIBLIOGRÁFICAS

- Aguirre, N., Grall-Maës, E., Cymberknop, L. J., & Armentano, R. L. (2021). Blood pressure morphology assessment from photoplethysmogram and demographic information using deep learning with attention mechanism. *Sensors*, 21(6), 1–19. <https://doi.org/10.3390/s21062167>
- Athaya, T., & Choi, S. (2021). An estimation method of continuous non-invasive arterial blood pressure waveform using photoplethysmography: A u-net architecture-based approach. *Sensors*, 21(5), 1–18. <https://doi.org/10.3390/s21051867>
- Attarpour, A., Mahnam, A., Aminitabar, A., & Samani, H. (2019). Cuff-less continuous measurement of blood pressure using wrist and fingertip photo-plethysmograms: Evaluation and feature analysis. *Biomedical Signal Processing and Control*, 49, 212–220. <https://doi.org/10.1016/j.bspc.2018.12.006>
- Augusto, M. (2018). *Desarrollo de Dispositivo para Medición de Presión Arterial No Invasiva Continua*.
- Baek, S., Jang, J., & Yoon, S. (2019). End-to-end blood pressure prediction via fully convolutional networks. *IEEE Access*, 7, 185458–185468. <https://doi.org/10.1109/ACCESS.2019.2960844>
- Bersano, N., & Sanson, H. (2018). Non-invasive blood pressure estimation from photoplethysmography signals using artificial neural networks. *International Conference on Advanced Communication Technology, ICACT, 2018-Febru*, 29–35. <https://doi.org/10.23919/ICACTION.2018.8323636>
- Chen, S., Ji, Z., Wu, H., & Xu, Y. (2019). A non-invasive continuous blood pressure estimation approach based on machine learning. In *Sensors (Switzerland)* (Vol. 19, Issue 11). <https://doi.org/10.3390/s19112585>
- Chowdhary, K. R. (2020). *Natural Language Processing BT - Fundamentals of Artificial Intelligence*. https://doi.org/10.1007/978-81-322-3972-7_19

- Chowdhury, M. H., Shuzan, M. N. I., Chowdhury, M. E. H., Mahbub, Z. B., Monir Uddin, M., Khandakar, A., & Reaz, M. B. I. (2020). Estimating blood pressure from the photoplethysmogram signal and demographic features using machine learning techniques. *Sensors (Switzerland)*, 20(11). <https://doi.org/10.3390/s20113127>
- Davidovits, P. (2019). Physics in Biology and Medicine. In *Angewandte Chemie International Edition*, 6(11), 951–952.
- el Hajj, C., & Kyriacou, P. A. (2020). Cuffless and Continuous Blood Pressure Estimation from PPG Signals Using Recurrent Neural Networks. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2020-July*, 4269–4272. <https://doi.org/10.1109/EMBC44109.2020.9175699>
- El-Hajj, C., & Kyriacou, P. A. (2021). Cuffless blood pressure estimation from PPG signals and its derivatives using deep learning models. *Biomedical Signal Processing and Control*, 70(June), 102984. <https://doi.org/10.1016/j.bspc.2021.102984>
- Eom, H., Lee, D., Han, S., Sun Hariyani, Y., Lim, Y., Sohn, I., Park, K., & Park, C. (2020). End-to-end deep learning architecture for continuous blood pressure estimation using attention mechanism. *Sensors (Switzerland)*, 20(8), 1–21. <https://doi.org/10.3390/s20082338>
- AHA Research Grant Funding Opportunities. (s/f). Professional.Heart.Org. Recuperado el 29 de agosto de 2025, de <https://professional.heart.org/en/research-programs/aha-funding-opportunities>
- Cardiovascular diseases (CVDs). (s/f). Recuperado el 28 de agosto de 2025, de [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- Carlini, N., Ippolito, D., Lee, K., Tramèr, F., Jagielski, M., & Zhang, C. (2023). QUANTIFYING MEMORIZATION ACROSS NEURAL LANGUAGE MODELS. *ICLR*, 1–19.

- Dhar, P., Singh, R. V., Peng, K.-C., Wu, Z., & Chellappa, R. (2019). Learning Without Memorizing. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 5133–5141. <https://doi.org/10.1109/CVPR.2019.00528>
- Día Mundial de la Hipertensión 2024—OPS/OMS | Organización Panamericana de la Salud. (s/f). Recuperado el 29 de agosto de 2025, de <https://www.paho.org/es/campanas/dia-mundial-hipertension-2024>
- Fundación Oftalmológica. (s/f). Recuperado el 2 de septiembre de 2025, de <https://fundacionzurita.com.mx/>
- Hipertensión. (s/f). Recuperado el 29 de agosto de 2025, de <https://www.who.int/es/news-room/fact-sheets/detail/hypertension>
- MAX86150 Datasheet and Product Info | Analog Devices. (s/f). Recuperado el 29 de agosto de 2025, de <https://www.analog.com/en/products/max86150.html>
- Módulo de biosensores integrado de PPG y ECG para dispositivos móviles MAX86150. (s/f). DigiKey. Recuperado el 29 de agosto de 2025, de <https://www.digikey.com.mx/es/product-highlight/m/maxim-integrated/max86150-integrated-ppg-and-ecg-biosensor-module>
- Fati, S. M., Muneer, A., Akbar, N. A., & Taib, S. M. (2021). A continuous cuffless blood pressure estimation using tree-based pipeline optimization tool. *Symmetry*, 13(4). <https://doi.org/10.3390/sym13040686>
- fluido newtoniano | Oilfield Glossary. (n.d.). Retrieved October 26, 2021, from https://glossary.oilfield.slb.com/es/terms/n/newtonian_fluid
- Gunther, T., Bovendeerd, P., & Vosse, F. Van De. (2006). *Hemodinamica arterial y venosa*. 30.
- Han, C., Gu, M., Yu, F., Huang, R., Huang, X., & Cui, L. (2020). Calibration-free Blood Pressure Assessment Using An Integrated Deep Learning Method. *Proceedings - 2020*

- IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2020*, 1001–1005. <https://doi.org/10.1109/BIBM49941.2020.9313586>
- Harfiya, L. N., Chang, C. C., & Li, Y. H. (2021). Continuous blood pressure estimation using exclusively photoplethysmography by lstm-based signal-to-signal translation. *Sensors*, 21(9). <https://doi.org/10.3390/s21092952>
- Hsu, Y. C., Li, Y. H., Chang, C. C., & Harfiya, L. N. (2020). Generalized deep neural network model for cuffless blood pressure estimation with photoplethysmogram signal only. *Sensors (Switzerland)*, 20(19), 1–18. <https://doi.org/10.3390/s20195668>
- Jorge, J., Proenca, M., Aguet, C., van Zaen, J., Bonnier, G., Renevey, P., Lemkaddem, A., Schoettker, P., & Lemay, M. (2020). Machine Learning Approaches for Improved Continuous, Non-occlusive Arterial Pressure Monitoring Using Photoplethysmography. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2020-July*, 910–913. <https://doi.org/10.1109/EMBC44109.2020.9176512>
- Jung, J., Shin, S., Kang, M., Kang, K. H., & Kim, Y. T. (2019). Development of semi-supervised learning-based continuous blood pressure estimation system. *Proceedings - 6th Annual Conference on Computational Science and Computational Intelligence, CSCI 2019*, 920–923. <https://doi.org/10.1109/CSCI49370.2019.00175>
- Khalid, S. G., Zhang, J., Chen, F., & Zheng, D. (2018). Blood Pressure Estimation Using Photoplethysmography Only: Comparison between Different Machine Learning Approaches. *Journal of Healthcare Engineering*, 2018. <https://doi.org/10.1155/2018/1548647>
- Kilickaya, S., Guner, A., & Dal, B. (2020). Comparison of Different Machine Learning Techniques for the Cuffless Estimation of Blood Pressure using PPG Signals. *HORA 2020 - 2nd International Congress on Human-Computer Interaction, Optimization and Robotic Applications, Proceedings*, 4–9. <https://doi.org/10.1109/HORA49412.2020.9152602>
- Li, Y. H., Harfiya, L. N., & Chang, C. C. (2021). Featureless Blood Pressure Estimation Based on Photoplethysmography Signal Using CNN and BiLSTM for IoT Devices.

Wireless Communications and Mobile Computing, 2021.
<https://doi.org/10.1155/2021/9085100>

- Li, Y. H., Harfiya, L. N., Purwandari, K., & Lin, Y. der. (2020). Real-time cuffless continuous blood pressure estimation using deep learning model. *Sensors (Switzerland)*, 20(19), 1–19. <https://doi.org/10.3390/s20195606>
- Lin, W. H., Chen, F., Geng, Y., Ji, N., Fang, P., & Li, G. (2021). Towards accurate estimation of cuffless and continuous blood pressure using multi-order derivative and multivariate photoplethysmogram features. *Biomedical Signal Processing and Control*, 63(August 2020), 102198. <https://doi.org/10.1016/j.bspc.2020.102198>
- Manamperi, B., & Chitraranjan, C. (2019). A robust neural network-based method to estimate arterial blood pressure using photoplethysmography. *Proceedings - 2019 IEEE 19th International Conference on Bioinformatics and Bioengineering, BIBE 2019*, 681–685. <https://doi.org/10.1109/BIBE.2019.00128>
- Maqsood, S., Xu, S., Springer, M., & Mohawesh, R. (2021). A Benchmark Study of Machine Learning for Analysis of Signal Feature Extraction Techniques for Blood Pressure Estimation Using Photoplethysmography (PPG). In *IEEE Access* (Vol. 9, pp. 138817–138833). <https://doi.org/10.1109/ACCESS.2021.3117969>
- Mejía-Mejía, E., May, J. M., Kyriacou, P. A., & Elgendi, M. (2021). Classification of blood pressure in critically ill patients using photoplethysmography and machine learning. *Computer Methods and Programs in Biomedicine*, 208. <https://doi.org/10.1016/j.cmpb.2021.106222>
- Moreno, L., Calderas, F., Sanchez, G., & Medina, L. (2013). La sangre humana desde el punto de vista de la reología. *Materiales Avanzados*, 20(May 2014), 33–37.
- Munir, D., Sheikh, N., Raziq, A., Rehman, A., & Basit, A. (2021). *Blood Pressure Estimation Using Artificial Neural Network and Multitaper Model*. April 2022.
- Pandey, R. K., Lin, T. Y., & Chao, P. C. P. (2021). Design and implementation of a photoplethysmography acquisition system with an optimized artificial neural network

- for accurate blood pressure measurement. *Microsystem Technologies*, 27(6), 2345–2367. <https://doi.org/10.1007/s00542-020-05109-9>
- Panwar, M., Gautam, A., Biswas, D., & Acharyya, A. (2020). PP-Net: A Deep Learning Framework for PPG-Based Blood Pressure and Heart Rate Estimation. *IEEE Sensors Journal*, 20(17), 10000–10011. <https://doi.org/10.1109/JSEN.2020.2990864>
- Park, J. U., Kang, D. W., Erdenebayar, U., Kim, Y. J., Cha, K. C., & Lee, K. J. (2020). Estimation of Arterial Blood Pressure Based on Artificial Intelligence Using Single Earlobe Photoplethysmography during Cardiopulmonary Resuscitation. *Journal of Medical Systems*, 44(1). <https://doi.org/10.1007/s10916-019-1514-z>
- Peter, L., Noury, N., & Cerny, M. (2014). A review of methods for non-invasive and continuous blood pressure monitoring: Pulse transit time method is promising? *Irbm*, 35(5), 271–282. <https://doi.org/10.1016/j.irbm.2014.07.002>
- Priyanka, K. N. G., Chao, P. C. P., Tu, T. Y., Kao, Y. H., Yeh, M. H., Pandey, R., & Eka, F. P. (2018). Estimating Blood Pressure via Artificial Neural Networks Based on Measured Photoplethysmography Waveforms. *Proceedings of IEEE Sensors, 2018-Octob*, 1–4. <https://doi.org/10.1109/ICSENS.2018.8589796>
- Qiu, Y., Liu, D., Yang, G., Qi, D., Lu, Y., He, Q., Qian, X., Li, X., Cao, Y., & Shuai, J. (2021). Cuffless blood pressure estimation based on composite neural network and graphics information. *Biomedical Signal Processing and Control*, 70(July), 103001. <https://doi.org/10.1016/j.bspc.2021.103001>
- Rong, M., & Li, K. (2021). A multi-type features fusion neural network for blood pressure prediction based on photoplethysmography. *Biomedical Signal Processing and Control*, 68(April), 102772. <https://doi.org/10.1016/j.bspc.2021.102772>
- Sadrawi, M., Lin, Y. T., Lin, C. H., Mathunjwa, B., Fan, S. Z., Abbod, M. F., & Shieh, J. S. (2020). Genetic deep convolutional autoencoder applied for generative continuous arterial blood pressure via photoplethysmography. *Sensors (Switzerland)*, 20(14), 1–18. <https://doi.org/10.3390/s20143829>

- Sannino, G., de Falco, I., & de Pietro, G. (2020). Non-invasive risk stratification of hypertension: A systematic comparison of machine learning algorithms. *Journal of Sensor and Actuator Networks*, 9(3). <https://doi.org/10.3390/JSAN9030034>
- Schrumpf, F., Frenzel, P., Aust, C., Osterhoff, G., & Fuchs, M. (2021). Assessment of non-invasive blood pressure prediction from ppg and rppg signals using deep learning. *Sensors*, 21(18), 1–27. <https://doi.org/10.3390/s21186022>
- Senturk, U., Polat, K., & Yucedag, I. (2020). A non-invasive continuous cuffless blood pressure estimation using dynamic Recurrent Neural Networks. *Applied Acoustics*, 170, 107534. <https://doi.org/10.1016/j.apacoust.2020.107534>
- Shimazaki, S., Kawanaka, H., Ishikawa, H., Inoue, K., & Oguri, K. (2019). Cuffless Blood Pressure Estimation from only the Waveform of Photoplethysmography using CNN. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 5042–5045. <https://doi.org/10.1109/EMBC.2019.8856706>
- Slapni Č Ar, G., Mlakar, N., & Luštrek, M. (2019). Blood pressure estimation from photoplethysmogram using a spectro-temporal deep neural network. *Sensors (Switzerland)*, 19(15). <https://doi.org/10.3390/s19153420>
- Slapničar, G., Luštrek, M., & Marinko, M. (2018). Continuous blood pressure estimation from PPG signal. *Informatica (Slovenia)*, 42(1), 33–42.
- Song, K., Chung, K. Y., & Chang, J. H. (2020). Cuffless Deep Learning-Based Blood Pressure Estimation for Smart Wristwatches. *IEEE Transactions on Instrumentation and Measurement*, 69(7), 4292–4302. <https://doi.org/10.1109/TIM.2019.2947103>
- Sun, X., Zhou, L., Chang, S., & Liu, Z. (2021). Using cnn and hht to predict blood pressure level based on photoplethysmography and its derivatives. *Biosensors*, 11(4), 1–13. <https://doi.org/10.3390/bios11040120>
- Tanveer, M. S., & Hasan, M. K. (2019). Cuffless blood pressure estimation from electrocardiogram and photoplethysmogram using waveform based ANN-LSTM

- network. *Biomedical Signal Processing and Control*, 51, 382–392.
<https://doi.org/10.1016/j.bspc.2019.02.028>
- Thambiraj, G., Gandhi, U., Mangalanathan, U., Jose, V. J. M., & Anand, M. (2020). Investigation on the effect of Womersley number, ECG and PPG features for cuff less blood pressure estimation using machine learning. *Biomedical Signal Processing and Control*, 60, 101942. <https://doi.org/10.1016/j.bspc.2020.101942>
- Tjahjadi, H., & Ramli, K. (2020). Noninvasive blood pressure classification based on photoplethysmography using K-nearest neighbors algorithm: A feasibility study. *Information (Switzerland)*, 11(2). <https://doi.org/10.3390/info11020093>
- Torres, J. (2012). *Dinámica de Fluidos - Universidad de Granada*. 18–37.
- Wang, D., Yang, X., Liu, X., Fang, S., Ma, L., & Li, L. (2020). Photoplethysmography based stratification of blood pressure using multi information fusion artificial neural network. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 2020-June, 1113–1119.
<https://doi.org/10.1109/CVPRW50498.2020.00146>
- Wang, L., Zhou, W., Xing, Y., & Zhou, X. (2018). A novel neural network model for blood pressure estimation using photoplethysmography without electrocardiogram. *Journal of Healthcare Engineering*, 2018. <https://doi.org/10.1155/2018/7804243>
- Yang, S., Sohn, J., Lee, S., Lee, J., & Kim, H. C. (2021). Estimation and Validation of Arterial Blood Pressure Using Photoplethysmogram Morphology Features in Conjunction with Pulse Arrival Time in Large Open Databases. *IEEE Journal of Biomedical and Health Informatics*, 25(4), 1018–1030.
<https://doi.org/10.1109/JBHI.2020.3009658>
- Yi, C., Jian, C., & Wenqiang, J. (2019). Continuous blood pressure measurement based on photoplethysmography. *2019 14th IEEE International Conference on Electronic Measurement and Instruments, ICEMI 2019*, 1656–1663.
<https://doi.org/10.1109/ICEMI46757.2019.9101774>

Yin, S., Li, G., Luo, Y., & Lin, L. (2021). Cuff-less continuous blood pressure measurement based on multiple types of information fusion. *Biomedical Signal Processing and Control*, 68(December 2020), 102549. <https://doi.org/10.1016/j.bspc.2021.102549>

PRODUCTOS ACADÉMICOS

En esta sección se presenta información sobre los productos académicos que se han generado.

Artículo de revista indizada – Journal Citation Reports

 applied sciences	Como primer autor Marco Antonio Arroyo-Ramírez, Isaac Machorro-Cano, Augusto Javier Reyes-Delgado, Jorge Ernesto González-Díaz y José Luis Sánchez-Cervantes (2025). Cuff-less Estimation of Blood Pressure and Detection of Hypertension / Arteriosclerosis from Fingertip PPG Using Machine Learning: An Experimental Study. <i>Appl. Sci.</i> 2025, Volume 15, Issue 21, 11829. Doi: https://doi.org/10.3390/app152111829 Estatus: Publicado
---	--

Artículo de congreso

	En colaboración Augusto Javier Reyes-Delgado, Marco Antonio Arroyo-Ramírez, Jorge Ernesto González-Díaz, Mariana Méndez-López y José Luis Sánchez-Cervantes (2025). Integration of Artificial Intelligence Techniques for Disease Prediction and Health Awareness: Review and Proposed Architecture. Congreso Mexicano de Inteligencia Artificial COMIA 2025. Estatus: Publicado
---	--

Registro de derechos de autor

	Participación como Autor Marco Antonio Arroyo Ramírez, José Luis Sánchez Cervantes, Oscar Osvaldo Sandoval González y Guillermo Cortes Robles. Módulo para la detección de riesgo cardiovascular basado en la monitorización de flujo sanguíneo a través de señales fotopletismográficas y ensambles de aprendizaje automático. Estatus: Enviado
---	--

ANEXOS

Revisión y Aprobación del Comité de Bioética

 Universidad Veracruzana	Participación como Autor Marco Antonio Arroyo Ramírez, José Luis Sánchez Cervantes, Isaac Machorro Cano, Jorge Ernesto González Díaz, Oscar Osvaldo Sandoval González, Guillermo Cortes Robles y Eduardo Baltazar Gaytán (2025). “Monitorización de flujo sanguíneo para identificar riesgo cardiovascular utilizando fotopletismografía y aprendizaje automático” Declaración del Comité de Ética: Ha sido revisado y aprobado por los Comités de Bioética e Investigación de la Universidad Veracruzana Campus Cd Mendoza, México, quedando registrado con el código: 046-202601-FMCM. Estatus: Registrado
--	---

Características Morfológicas de la señal PPG

Dominio del tiempo	Dominio de la frecuencia	Características Estadísticas
RR mean (Intervalo RR medio)	VLF Power (Potencia en la banda de frecuencia muy baja)	Mean (Media de la señal PPG)
RR std (Desviación estándar de los intervalos RR)	LF Power (Potencia en la banda de baja frecuencia)	Std (Desviación estándar de la señal PPG)
HR mean (Frecuencia cardíaca media)	HF Power (Potencia en la banda de alta frecuencia)	Skewness (Asimetría de la señal PPG)
HR std (Desviación estándar de la frecuencia cardíaca)	Total Power (Suma total de la potencia espectral en el rango de interés)	Kurtosis (Curtosis de la señal PPG)
HRV RMSSD (Raíz cuadrada de la media de las diferencias sucesivas al cuadrado)	LF/HF Ratio (Relación entre las potencias LF y HF)	Max (Valor máximo de la señal PPG)
	VLF (%) (Porcentaje de potencia en la banda VLF respecto al total)	Min (Valor mínimo de la señal PPG)
	LF (%) (Porcentaje de potencia en la banda LF respecto al total)	Range (Rango (máx - mín) de la señal PPG)
	HF (%) (Porcentaje de potencia en la banda HF respecto al total)	Energy (Energía total de la señal PPG)

Datos Basales de los sujetos de estudio

Sujeto	Género	Edad	Enfermedades Cardiovasculares
S1	Masculino	72	Diabetes
S2	Masculino	43	Sano
S3	Masculino	29	Sano
S4	Masculino	48	Diabetes
S5	Masculino	27	Hipertensión
S6	Masculino	42	Sano
S7	Masculino	42	Sano
S8	Femenino	66	Sano
S9	Masculino	27	Sano
S10	Masculino	27	Sano
S11	Femenino	73	Sano
S12	Masculino	73	Diabetes
S13	Femenino	63	Hipertensión y diabetes melitus tipo 2
S14	Masculino	69	Hipertensión y diabetes
S15	Femenino	41	Hipertensión y diabetes
S16	Femenino	62	Sano
S17	Femenino	67	Hipertensión y diabetes
S18	Femenino	72	Hipertensión
S19	Masculino	64	Hipertensión
S20	Femenino	66	Hipertensión
S21	Masculino	61	Hipertensión
S22	Femenino	75	Sano
S23	Femenino	61	Sano
S24	Masculino	63	Hipertensión y diabetes
S25	Masculino	52	Sano
S26	Femenino	35	Sano
S27	Femenino	62	Hipertensión y diabetes
S28	Femenino	48	Hipertensión
S29	Masculino	37	Sano
S30	Femenino	60	Sano
S31	Femenino	51	Hipertensión
S32	Masculino	61	Hipertensión y diabetes
S33	Masculino	54	Sano
S34	Masculino	75	Hipertensión y diabetes
S35	Femenino	54	Sano
S36	Masculino	71	Sano
S37	Masculino	74	Sano
S38	Masculino	66	Sano
S39	Masculino	51	Diabetes
S40	Masculino	72	Hipertensión

S41	Masculino	55	Hipertensión
S42	Masculino	67	Sano
S43	Femenino	68	Hipertensión y diabetes
S44	Masculino	48	Diabetes
S45	Femenino	46	Sano
S46	Masculino	72	Diabetes
S47	Femenino	26	Sano
S48	Masculino	42	Sano
S49	Femenino	35	Sano
S50	Femenino	80	Sano
S51	Femenino	61	Sano
S52	Masculino	73	Sano
S53	Femenino	45	Sano
S54	Femenino	43	Sano
S55	Femenino	68	Sano
S56	Femenino	66	Diabetes
S57	Femenino	28	Sano
S58	Femenino	60	Hipertensión y diabetes
S59	Femenino	38	Sano
S60	Masculino	65	Sano
S61	Femenino	58	Sano
S62	Femenino	74	Sano
S63	Femenino	53	Sano
S64	Masculino	68	Diabetes
S65	Femenino	57	Sano
S66	Masculino	57	Sano
S67	Masculino	64	Sano
S68	Masculino	71	Hipertensión y diabetes
S69	Femenino	24	Sano
S70	Femenino	50	Diabetes
S71	Femenino	24	Sano
S72	Masculino	44	Hipertensión
S73	Masculino	65	Hipertensión
S74	Masculino	65	Diabetes
S75	Masculino	82	Hipertensión
S76	Masculino	33	Sano
S77	Femenino	63	Hipertensión
S78	Masculino	71	Hipertensión y diabetes
S79	Femenino	70	Hipertensión y diabetes
S80	Femenino	86	Sana
S81	Femenino	48	Hipertensión
S82	Masculino	57	Hipertensión y diabetes
S83	Masculino	75	Sano

S84	Femenino	70	Sano
S85	Masculino	48	Sano
S86	Femenino	42	Diabetes
S87	Masculino	54	Sano
S88	Femenino	70	Sano
S89	Femenino	42	Diabetes
S90	Femenino	68	Hipertensión y diabetes
S91	Femenino	30	Sano (anemia)
S92	Masculino	66	Hipertensión
S93	Masculino	46	Sano
S94	Femenino	68	Diabetes (insuficiencia renal)
S95	Femenino	44	Hipertensión
S96	Masculino	76	Sano
S97	Femenino	69	Sano
S98	Femenino	44	Sano
S99	Femenino	61	Diabetes
S100	Femenino	73	Hipertensión (marcapasos)
S101	Masculino	75	Hipertensión y prediabético
S102	Femenino	36	Taquicardia y arritmia, hipotensión
S103	Femenino	27	Sano
S104	Femenino	66	Sano
S105	Femenino	51	Sano
S106	Femenino	43	Anemia
S107	Masculino	64	Hipertensión y diabetes
S108	Masculino	46	Sano
S109	Femenino	61	Sano
S110	Femenino	41	Sano
