# SEÑALES FOTOPLETISMOGRÁFICAS PARA ESTIMAR LA PRESIÓN ARTERIAL

# SEÑALES FOTOPLETISMOGRÁFICAS PARA ESTIMAR LA PRESIÓN ARTERIAL

DEPARTAMENTO DE INGENIERÍA DE SISTEMAS

**UNIVERSIDAD SIMÓN BOLÍVAR**

TESIS PARA EL GRADO DE MAESTRÍA EN INGENIERÍA DE SISTEMAS Y COMPUTACIÓN

**POR**

**ROY DARWIN RODRIGUEZ MÁRQUEZ**

ASESOR:

**SILVIA MORENO TRILLOS, MSc**

BARRANQUILLA – UNIVERSIDAD SIMÓN BOLÍVAR

**2021**

**TABLA DE CONTENIDO**

1. Introducción ..... 8
1.1 Formulación Del Problema ..... 9
1.2 Pregunta De Investigación ..... 14
1.3 Justificación ..... 15
2. Marco Teórico ..... 19
2.1 Fundamentos Teóricos ..... 19
2.2 Antecedentes De La Investigación ..... 23
2.2 Bases Teóricas Enfocadas Métodos Existentes ..... 25
3.0 Objetivos ..... 29
3.1 Objetivo General ..... 29
3.2 Objetivos Específicos ..... 29
4. Metodología ..... 30
4.1 Método ..... 30
5. Mapa Del Documento ..... 31
6. Capítulo 1: Los Fundamentos Teóricos y Epistemológicos para la Estimación Continua Y no Invasiva de la Presión Arterial ..... 33
6.1 Esfigmomanómetro (Método Indirecto) ..... 33
6.2 Intraarterial (Método Directo) ..... 36
6.3 Alternativas Para La Obtención De La Presión Arterial De Forma No Invasiva Y Continua ..... 37
7. Capítulo 2: Los Conceptos Categorías Referentes A La Estimación Continua Y No Invasiva De La Presión Arterial. ..... 43
7.1 Fotopletismografía ..... 43
7.2 Estimar La Presión Arterial Con Fotopletismografía ..... 47
7.3 Método Propuesto ..... 50
7.3.1 Inteligencia artificial (IA) ..... 51
7.3.2 Aprendizaje Supervisado vs Aprendizaje No Supervisado ..... 54
7.3.4 Aprendizaje profundo ..... 56
8. Capítulo 3: Las Relaciones Entre Los Elementos Y Componentes De La Estimación Continua Y No Invasiva De La Presión Arterial ..... 66
8.1 Bases de datos (*dataset* origen) ..... 67
8.2 Preprocesamiento ..... 69
8.3 Procesamiento ..... 73
8.3.1 Redes Neuronales Convolucionales ..... 76
8.3.2 Arquitecturas redes neuronales convolucionales ..... 77

8.4 Lenguaje de programación y *framework* de desarrollo..... 80
8.5 Métricas ..... 81
8.6 Resultados..... 82
9. Conclusiones..... 86
9.1 Alcances y limitaciones ..... 87
9.2 Recomendaciones y trabajos futuros ..... 88

Lista de figuras

FIGURA 1 SISTEMA CIRCULATORIO ..... 20
FIGURA 2 CICLO CARDIACO ..... 22
FIGURA 3 PRESIÓN ARTERIAL ..... 23
FIGURA 4 ESFIGMOMANOMETRO ..... 35
FIGURA 5 LOS PRINCIPIOS DE FUNCIONAMIENTO DE LOS MÉTODOS AUSCULTATORIOS Y OSCILOMÉTRICAS ..... 39
FIGURA 6 FUNCIONAMIENTO DEL MÉTODO DE TONOMETRÍA ..... 40
FIGURA 7 TRANSMISIÓN Y REFLEXIÓN ..... 44
FIGURA 8 FOTOPLETISMOGRAMA ..... 46
FIGURA 9 DIAGRAMA DE BLOQUES ..... 48
FIGURA 10 FORMA DE ONDA SEÑAL PPG ..... 49
FIGURA 11MAPA DE LOS ENFOQUES DE INTELIGENCIA ARTIFICIAL ..... 51
FIGURA 12 JERARQUIA DE LA INTELIGENCIA ARTIFICIAL ..... 54
FIGURA 13 COMPARTICIÓN DE PARÁMETROS ..... 57
FIGURA 14 DIFERENCIAS ENTRE REDES NEURONALES ..... 59
FIGURA 15 CONVOLUCIÓN ..... 61
FIGURA 16 SUBMUESTREO ..... 64
FIGURA 17 ETAPAS RED CONVOLUCIONAL ..... 66
FIGURA 18 DIAGRAMA DE MACROPROCESOS ..... 68
FIGURA 19 FORMA DE ONDA TÍPICA PPG ..... 72
FIGURA 20 FORMA DE ONDA ATÍPICA ..... 72
FIGURA 21 ALTURA, ANCHO Y PROFUNDIDAD DELA IMAGEN Y EL FILTRO ..... 75
FIGURA 22 ARQUITECTURA PROPUESTA ..... 78
FIGURA 23 RESULTADOS DE LA PRIMERA ARQUITECTURA DE RED PROPUESTA APLICANDO TRES TASAS DE APRENDIZAJE ..... 83
FIGURA 24 RESULTADOS DE LA SEGUNDA ARQUITECTURA DE RED PROPUESTA APLICANDO TRES TASAS DE APRENDIZAJE ..... 84
FIGURA 25 RESULTADOS DE LA TERCERA ARQUITECTURA DE RED PROPUESTA APLICANDO TRES TASAS DE APRENDIZAJE ..... 85
FIGURA 26 MÉTRICAS OBTENIDAS CON 500 MUESTRAS NO EMPLEADAS EN EL ENTRENAMIENTO ..... 86

Lista de Tablas

TABLA 1 PROCEDIMIENTOS ESTIMACIÓN PRESIÓN ARTERIAL ..... 10
TABLA 2 MÉTODOS PARA ES TIMAR PRESIÓN ARTERIAL CON DOS SENSORES ..... 50
TABLA 3 CANTIDAD DE DATOS SEGUN PRESION ARTERIAL ..... 71

# 1. Introducción

La presión arterial es uno de los parámetros fisiológicos más significativos en el estado de salud de una persona, junto con la frecuencia cardiaca, la temperatura corporal y la frecuencia respiratoria, estas circunstancias hacen necesario el control de estos parámetros y en especial monitoreo de la presión arterial en las unidades de cuidados intensivos. Normalmente ingresan pacientes con una inestabilidad hemodinámica que puede causar fallo de un órgano o multiorgánico.

Las dos formas de medir la presión arterial en las unidades de cuidados intensivos son la invasiva a través de la canalización de una arteria y la no invasiva a través de un esfigmomanómetro que en la mayoría de las UCI esa conectada a la monitorización del paciente.

En la práctica clínica surgen problemas de riesgos en la salud del paciente con el método arterial y de credibilidad con el esfigmomanómetro por no ser continuo

De esta forma se están realizando muchas investigaciones con otros métodos para la medición de la presión arterial, aunque están todavía en estudio y no está confirmada su eficacia. En este proyecto se propone un método para estimación, que a partir de la señal fotopletismográfica se pueda medir los valores de presión sistólica y diastólica.

Para ello se utiliza un modelo sistémico la cual nos llevara a la interacción con el problema y a la determinación de los elementos fundamentales involucrados en el objeto de estudio (Doyle, et al., 1996).

## 1.1 Formulación Del Problema

Cuando medimos la presión arterial, estamos observando la presión que ejerce la sangre sobre la pared de la arteria y la reacción de dicha arteria ante la citada presión en mm Hg. Al tener en cuenta estos dos factores, la presión de la sangre y la presión de los vasos, se observan las siguientes variables: presión sistólica, presión diastólica, presión de pulso y presión media dinámica. Cada una de estas presiones tiene un significado para el mantenimiento de la estabilidad (homeostasis) del organismo.

La presión arterial es un índice hemodinámico básico, el cual se utiliza regularmente para orientar las intervenciones terapéuticas en pacientes críticos y con estancias muy prolongadas. La inexactitud en la medición de la presión arterial puede llevar a un mal diagnóstico y por ende un mal manejo en el tratamiento del paciente.(Blasco et al., 2011)

Actualmente para la medición de la Presión Arterial (PA) existen dos metodologías: las invasivas y las no invasivas. Dependiendo de la situación clínica, como las enfermedades cardiovasculares, se utilizan técnicas invasivas donde el monitoreo continuo es medido utilizando un método implantación de una cánula intraarterial, o técnicas no invasivas donde la medición es intermitente utilizando métodos con brazalete y los continuos utilizan métodos sin brazalete, como se puede observar en la siguiente tabla.

**Tabla 1**

*Procedimientos estimación presión arterial*

| Category | |
|---|---|
| *Invasive* | Invasive blood pressure catheter |
| *Non Invasive* | *Cuff-based* |
| | Auscultatory, Oscillometric, Tonometric, Value clamp or Vascular unloading, Ultrasonic, Electronic palpation |
| | *Cuff-less* |
| | Photoplethysmographic |

Podemos decir que la metodología invasiva intraarterial es directa y provee las variables de presión más exactas, mientras que las metodologías no invasivas son indirectas pero las más utilizadas en la práctica asistencial.

Debido a que la vigilancia de la presión arterial es esencial en el manejo de pacientes cuya hemodinámica es inestable, métodos de monitorización continua invasiva de la presión arterial "latido a latido" son considerados como el "*gold standard"* o patrón de oro (Lehman et al., 2013). Este método de monitoreo de la presión arterial es el recomendado en personas bajo control médico en una unidad de cuidados intensivos (UCI) donde los pacientes tienen probabilidades de presentar cambios repentinos en este índice vital.

El método de monitorización continúa invasiva de la presión arterial "latido a latido" utiliza la introducción de una cánula o catéter en una arteria. El ser considerado como el "*gold standard*" o patrón de referencia implica que es el método que otorga la máxima fiabilidad dentro de una serie de condiciones específicas. Es decir, este método aporta indicadores médicos que son utilizados como punto de comparación por otras metodologías de medición de presión arterial para demostrar su validez diagnóstica.

A pesar que se reconoce, que este método es utilizado clínicamente en estas situaciones, presenta las siguientes desventajas: posibilidad de infección en la cánula introducida en la arteria, lesiones arteriales, embolia, la dificultad de la aplicación del método en pacientes en estado de shock.(Gupta, n.d.)

Las unidades de cuidados intensivos (UCI) siguen utilizando este procedimiento muy común en la actualidad, es decir, utilizan la canalización arterial o línea arterial. Este método fue empleado por primera vez en año de 1949 por Peterson (Peterson et al., 1949) como control perioperatorio[1] en pacientes inestables para registrar el pulso y la presión arterial.

Aunque la literatura sobre este procedimiento es extensa y muy utilizada por el valor de información que proporciona, los resultados obtenidos indican complicaciones derivadas de la técnica. Estadísticamente existe un 43% de tasa de fracaso en la inserción del catéter y por ende es necesario realizar múltiples intentos para lograr una canalización exitosa. (Arangure, 2013)

Tomando en consideración las posibles complicaciones en el procedimiento, se implementaron ayudas con otras tecnologías como el ultrasonido que, aunque está poco documentada, ha permitido visualizar la trayectoria de los vasos sanguíneos, la profundidad de la arteria, el tamaño de la arteria, si tiene buen flujo y si el trayecto de esta es bueno. Este soporte en la medición de la presión arterial ha permitido reducir el índice de fracaso a un 14%, sin embargo, esta asistencia requiere capacitación, experiencia y habilidad para su exitosa aplicación. (Arangure, 2013). Aunque existe este soporte tecnológico al utilizar el método *standard* para la medición de la presión arterial en pacientes en UCI, los riesgos siguen presentes.

[1] Alrededor del momento de la cirugía

Las investigaciones alrededor de este tópico muestran que la arteria radial es el sitio preferido para este procedimiento por su fácil acceso, su simplicidad y su escasa supervisión por parte del personal médico, sin embargo, la mayoría de las complicaciones tras la canalización son asintomáticas y se presentan días después del procedimiento. Investigaciones realizadas por Bedford y Wollman en 100 pacientes arrojaron índices de 38,5% de trombosis[2] tras la canalización de la arteria radial. (Bedford & Wollman, 1973) En este mismo estudio se encontró una incidencia del 10% en signos clínicos de compromiso vascular en aquellos pacientes, cuyo tiempo de canalización fue mayor a 20 horas; en este subgrupo se formaron trombos y vasoespasmos[3] después de la decanulación[4].

Bernd Volker Scheer, Azriel Perel, and Ulrich J Pfeiffer documentaron en su revisión las complicaciones más comunes en tres sitios de canalización arterial: coronaria, femoral y axilar. En la muestra utilizada: 19.617 por canulación en la arteria coronaria, 3.899 en la arteria femoral y 1.989 en la arteria axilar; se encontraron complicaciones existentes por lesión isquémica permanente de la mano en un 0,09% de los casos, sepsis en un 0,13% de los casos, infección local en un 0,72% de los casos, pseudoaneurisma en un 0,09% de los casos, hematomas en un 14% de los casos y sangrado en un 0,5% de los casos.(Scheer et al., 2002)

En este contexto, un creciente interés en el monitoreo no invasivo y sin brazalete de la **presión arterial** está estimulando las investigaciones destinadas a introducir nuevos sistemas que provean eliminación o disminución de los riesgos, además de **mediciones**

[2] Formación de un coagulo en el interior de un vaso sanguíneo
[3] Estrechamiento de un vaso sanguíneo
[4] Proceso de cierre de la traqueostomía

igual o más precisas que la metodología invasiva en pacientes con enfermedades cardiovasculares, el cual es esencial para el adecuado control médico en unidades de cuidados intensivos (UCI).

Estudios teóricos y clínicos donde se han comparado los procedimientos para la medición de la presión arterial con la técnica invasiva y no invasiva (Kaur et al., 2019) (Lakhal, Ehrmann, et al., 2018)(Lakhal, Martin, et al., 2018) (Ray et al., 2017) sugieren que sus mediciones pueden diferir en sus estimaciones. Sin embargo, los datos clínicos que comparan la medición de la presión arterial en UCI con la técnica invasiva comparada con la no invasiva son escasos, especialmente en los valores extremos de la estimación de presión arterial diastólica y sistólica.

La “toma” de la presión arterial de manera tradicional (comúnmente conocida), es un método de medición intermitente no invasivo que requiere un manto presurizado alrededor del brazo o la pierna. La “estimación” de la presión arterial (PA) puede obtenerse enviando presión de aire al brazalete y liberándolo alternativamente, la monitorización continua de la presión arterial es imposible. En este escenario, un dispositivo de medición de la PA no invasivo, continuo y fiable sería deseable en pacientes que se someten a una cirugía, y, además, sería especialmente beneficioso para los pacientes inconscientes bajo vigilancia continua durante un largo período de tiempo, reduciendo la ocurrencia de peligrosas complicaciones en la salud del paciente. (Yoo, 2019)

Del estudio de métodos no invasivos y sin brazalete surge el tonómetro arterial, este dispositivo puede ofrecer una onda de presión latido a latido continua, pero está sujeta al movimiento de los artefactos causada por la sensibilidad del sensor de presión y el movimiento de la muñeca. (Khalid et al., 2018)

Del tonómetro digital podemos pasar al dispositivo PTT (Pulso Transito Tiempo) que necesitan señales como son el electrocardiograma (ECG) y la fotopletismografía (PPG) para poder calcular las variables de la presión arterial. El método del tiempo de tránsito de pulso (PTT) está definido como el intervalo de tiempo entre el pico de la onda R del electrocardiograma (ECG) y un punto característico de la onda de fotopletismografía (PPG) en el mismo ciclo cardiaco.

Estos mecanismos y dispositivos han llevado a un mayor análisis en el estudio de la señal PPG, que representa una opción de estudio e investigación para abordar estos problemas. Investigaciones como la de Gloria Martínez et al demuestran que existe una gran similitud en la morfología de la señal PPG y la ABP (arterial blood pressure) con una diferencia significativa ($p = 0,0069$) lo que significa una validez estadística importante.

## 1.2 Pregunta De Investigación

En esta investigación se va a explorar, analizar y diseñar un método que permita desarrollar a través de redes neuronales convolucionales una forma de estimación de la presión arterial a partir de señales fotopletismográficas.

En base a esta descripción surge la siguiente pregunta:

***¿De qué manera puede contribuir el análisis de las señales fotopletismográficas a través de Inteligencia Artificial a la medición de la presión arterial continua en condiciones favorables para la salud del paciente y fiables para la interpretación diagnóstica?***

## 1.3 Justificación

La medición de las variables de presión arterial esta normalmente incluida dentro de la medición de las funciones básicas del cuerpo humano. De manera rutinaria está acompañada de la medición de los parámetros vitales más importantes para los profesionales de la salud: el ritmo cardiaco, la frecuencia respiratoria y la temperatura corporal.

Cuando un paciente con problemas cardiovasculares se encuentra en una unidad de cuidados intensivos (UCI), se hace necesario, por protocolo médico, un monitoreo y control preciso de estos parámetros vitales. Cambios repentinos en las variables de presión arterial de estos pacientes indican posibles problemas al personal médico responsable del monitoreo continuo en UCI.(Lehman et al., 2013)

La estimación de la presión arterial en estos casos debe ser medida de manera continua "latido a latido" por lo que precisa ser utilizada la técnica invasiva "*gold standard*" de la introducción de una cánula en una arteria. Otros métodos para medir la presión arterial no muestran de manera continua la variabilidad de la señal y por consiguiente cambios repentinos en estas. El uso de medicamentos que cambian la fuerza de las contracciones del corazón (inotropos) en este tipo de pacientes, exige que la medición de las variables de presión correspondientes (sistólica, diastólica, media y de pulso) sea lo más precisa posible.

Valores altos en la presión arterial sistólica (cuando el corazón late) significa mayor riesgo de accidente cerebrovascular, mientras que valores altos en la presión arterial diastólica (cuando el corazón se relaja) son indicadores de aneurisma de la aorta

abdominal. La presión arterial sistólica (PAS) y diastólica (PAD) tienen fuertes asociaciones con las enfermedades cardiovasculares, por ello es de particular importancia su monitoreo en estos pacientes. Además, PAS y PAD ayudan a estimar otros valores como la presión arterial media (PAM) y la presión de pulso (PP).(Suárez, 2017)

La PAM es una media de la presión arterial durante el ciclo cardiaco la cual le dice al médico como el cuerpo está procesando la sangre oxigenada que llega a los tejidos y órganos, donde sus niveles si son bajos el paciente puede entrar en shock o si es alta puede presentar otras complicaciones.

La PP también se maneja como un marcador de diversas enfermedades entre los que se encuentra el infarto agudo al miocardio y accidentes vasculares debido a que un alto valor de este parámetro indica un alto grado de rigidez arterial (Hernández Gárciga & González Chacón, 2015)

De esta forma el método de monitorización invasivo intraarterial es el más empleado para estas situaciones y tipos de pacientes por ser el más exacto y avalado durante años de estudio, sin embargo, esta técnica no esta exenta de riesgos y complicaciones hacia el paciente. (Suárez, 2017)

Los métodos no invasivos para la medición de la presión arterial como el de palpación, el de auscultación, el oscilo métrico, y el método de tonometría utilizan distintas técnicas para estimar estas variables. Sin embargo, ninguno de estos métodos de estimación de las variables de la presión arterial, documentados médicamente, que no son invasivos y que no presentan riesgos para la salud, son capaces de obtener indicadores fiables para el monitoreo del paciente cardiovascular en UCI (es decir

seguimiento continuo “latido a latido” de la PAS, PAD, PAM y PP). (Meneses & Lemos, 2013)

En este contexto surge el análisis de señales obtenidas por fotopletismografía (PPG) para la estimación de parámetros vitales en humanos, entre ellos la presión arterial. Otros parámetros hemodinámicos importantes pueden ser evaluados a partir de la señal PPG, como la frecuencia cardíaca, la estimación de la frecuencia respiratoria o la velocidad del pulso. Los recientes avances en la tecnología hacen que el uso de esta técnica permita mediciones por contacto de la piel proporcionando un mecanismo sencillo, práctico, seguro y de medición continua en tiempo real. Dado que tienen una misma fuente de excitación que es el corazón, existe una gran similitud entre la morfología de la señal intrarterial (IBP: *invasive blood pressure*) y la señal PPG. La técnica de medición no es invasiva por naturaleza pues utiliza una señal óptica relacionada con las pulsaciones arteriales volumétricas de la sangre.(Martínez et al., 2018)

Implementaciones que soportan el uso de señales PPG involucran el control electo neumático (Fortin et al., 2006), controladores de presión, sensores magnéticos (Khalid, Zhang, Chen, & Zheng, 2018), el tiempo de transito de pulso (Poon & Zhang, 2005), el tiempo de transito vascular (Foo, Wilson, & Wang, 2008). Problemas como la necesaria calibración cada cierto tiempo, y la validez de la estimación en tiempo real, hacen que estas implementaciones sean complejas.

Estos estudios han mostrado una alta correlación en la estimación de la presión arterial como lo demuestra Foo et al, Poom &Zhang y Khalid et al. pero requieren de la disponibilidad de dos señales, es decir contar con instrumentación adicional al PPG lo cual involucraría más costos.

Es por eso, que otros estudios han mostrado enfoques para estimación directa de la presión arterial a partir de la señal PPG, como es el caso de Kurylak en el año 2013 y Gaurav en el año 2016 donde se extraen características de esta señal para estimar la presión arterial.

El procesamiento de la señal PPG utilizando primeras, segundas derivadas y transformadas de Fourier han llevado a la obtención de buenos resultados en la estimación. Sugiriendo estas investigaciones obtener otras características de la señal para mejor estimación y reducir un poco más el error.(Kurylyak et al., 2013)(Gaurav et al., 2016)

Recientemente, se ha descrito el uso de PPG como una alternativa potencial a los monitores de presión arterial basados en brazalete (Nitzan, Slotki, & Shavit, 2017). El pequeño tamaño del sensor y su sencillo funcionamiento hacen que la PPG sea ampliamente aplicable para la detección de enfermedades cardiovasculares y de microcirculación periférica (Njoum & Kyriacou, 2017).

Dada la existencia de métodos alternativos de estimación de la PA soportados por PPG, estos pueden usarse en pacientes en UCI con problemas cardiovasculares. Por la naturaleza de la forma de medición son seguros, no invasivos y se realizan de forma continua, sin embargo, aún presentan deficiencias en la fiabilidad de su estimación. Está investigación propone abordar esta problemática estudiando el comportamiento y características de la señal PPG en este contexto mediante el uso de IA y buscara las predicciones más fiables posibles.

# 2. Marco Teórico

## 2.1 Fundamentos Teóricos

En este proyecto se trabajará con señales ópticas capaces de monitorear funciones fisiológicas del sistema cardiovascular, además del enfoque holístico aplicado para entender el problema, se hace necesario explicar y entender su funcionamiento

### 2.1.1 Sistema Cardiovascular

El sistema cardio vascular está compuesto por tres componentes el corazón, la sangre y los vasos sanguíneos, el corazón se comporta como una bomba hidráulica, creando la fuerza impulsora detrás de flujo sanguíneo pulsátil a través del sistema arterial.

La magnitud y el comportamiento de este flujo sanguíneo dependen de las propiedades mecánicas del musculo cardiaco y de la pared de los vasos sanguíneos, así como de las propiedades de la sangre.

El lado derecho del corazón recolecta la sangre desoxigenada del sistema venoso para enviarlas a las arterias pulmonares, mientras que el lado izquierdo recolecta sangre oxigenada de las venas pulmonares para enviarla a través de la aorta del cuerpo

**Figura 1**
*Sistema circulatorio*

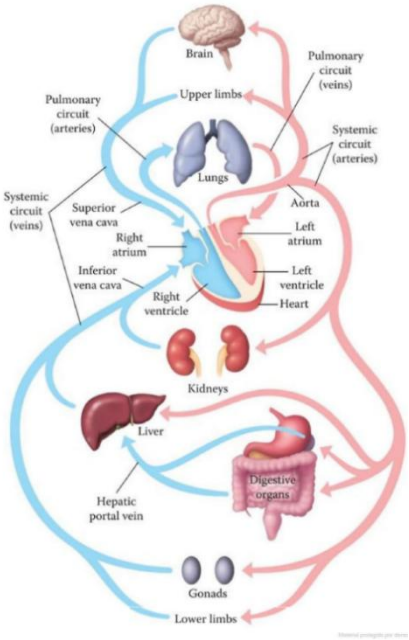


*Nota*. Mientras que el circuito pulmonar recibe el 100% del flujo sanguíneo, el sistema sistémico está dispuesto como un circuito paralelo. Adaptado de sistema circulatorio, Definición ABC, 2011, https://www.definicionabc.com/ciencia/sistema-circulatorio.php

### 2.1.2 Ciclo Cardiaco

El ciclo cardiaco consta de la diástole o relajación y sístole o contracción, el cual suele durar unos 800ms. La mayor parte de este ciclo ocurre en la fase diastólica (unos 500ms) y unos 300ms en la sístole.

Durante el llenado diastólico las aurículas y los ventrículos se relajan recibiendo sangre del sistema venoso y la presión resultante es suficiente para mantener abiertas las válvulas. Con el inicio de la onda P (identificada en el electrocardiograma) hay una contracción en las aurículas y una expulsión final de la sangre hacia los ventrículos, surgiendo así el próximo evento eléctrico la onda QRS (identificada en el electrocardiograma) iniciando la contracción ventricular y el inicio de la sístole ventricular. (Labrosse, 2018)

**Figura 2**

*Ciclo Cardiaco*

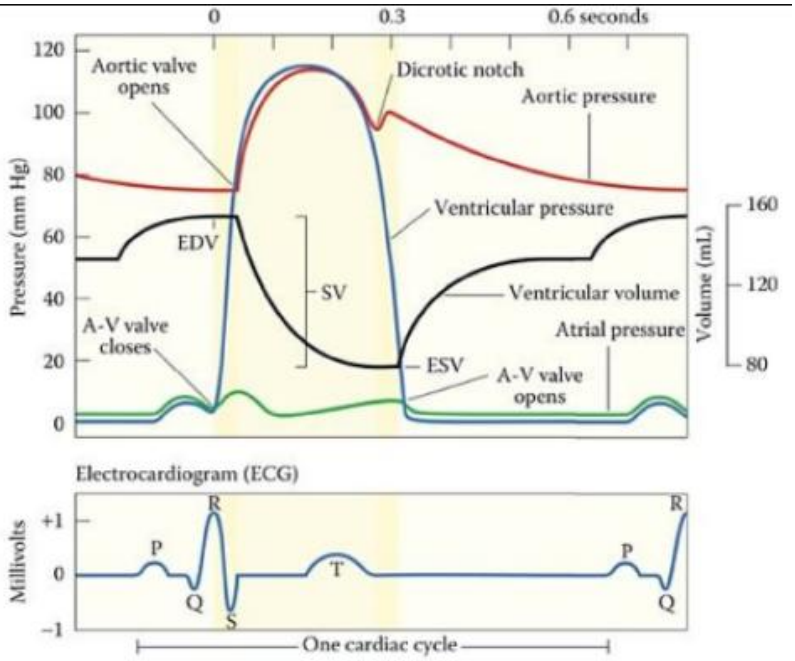


Nota. Adaptado de ciclo cardiaco, universidad de Cantabria, 2017, https://ocw.unican.es/mod/page/view.php?id=535

### 2.1.3 Presión Arterial

La presión arterial es la fuerza o empuje de la sangre en las paredes de las arterias a medida que se bombea desde el corazón a todo el cuerpo, esto es importante porque sin ella, nuestra sangre no fluiría en absoluto.

La medición de la presión arterial está compuesta por dos números medidos en unidades de milímetros de mercurio (mmHg), el primer número es la presión sistólica que representa la presión en las arterias cuando el corazón hace pasar sangre por ellas.

El segundo valor es la presión diastólica es la presión en sus arterias cundo su corazón se relaja entre latidos

**Figura 3**
*Presión arterial*

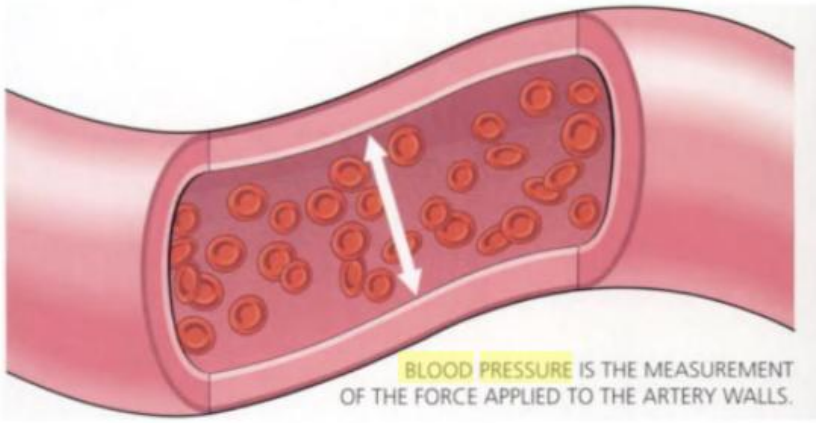


Nota. Adaptado de presión arterial, Carolina Betancourth, 2021, https://mejorconsalud.as.com/todo-lo-que-hay-que-saber-sobre-la-presion-arterial-alta

## 2.2 Antecedentes De La Investigación

El método tradicional para monitorear la presión arterial que se realiza en pacientes con estados hemodinámicos inestables se realiza de forma invasiva. Este método puede generar riesgos y complicaciones en los pacientes como se evidencia en los estudios que se presentan a continuación.

Investigaciones realizadas por Scheer, Bernd Volker et al donde se realizó un estudio en la bibliografía de los años 1978 a 2001 de las complicaciones y riesgos en la canalizacion de la arteria para a monitorización hemodinámica de los pacientes, se observó una baja tasa de incidencia en complicaciones importantes como daños isquémicos, sepsis y formación de pseudoaneurismas que se producen en menos del 1%, sin embargo aunque el estudio de esta bibliografía arrojo un riesgo bajo se hace la advertencia de las posibles complicaciones graves que puede tener este método. (Scheer et al., 2002)

Otras investigaciones más actuales muestran con intervenciones en la arterial radial para estimación de la presión arterial llevan riesgos incluso después de retirar la cánula arterial en donde una paciente “sufrió una isquemia permanente en su mano después de insertar un catéter en la arteria radial”. Se demuestra que la colocación de la línea en la arteria radial puede causar lesiones isquémicas hasta en un 0,09% de los casos y el 38% de los casos desarrollan trombosis con el procedimiento.(Mendoza, 2012)

Según Arangure una desactualizacion en los procedimientos de la guia de manejo de insercion de linea arterial por parte del personal de enfermeria ademas de la falta de experiencia, desconocimiento y capacitacion han producido las siguientes complicaciones en los pacientes como hemorragias, lesiones de nervios perifericos, multiples punsiones, trombosis arterial y ademas se reconoce las complicaciones de la canulizacion desde la introduccion de la tecnica. (Arangure, 2013)

En una investigación más actual referente a la población pediátrica se encontró que pocos estudios reflejan los riesgos de esta población, por lo cual se estudió una población de 10000 niños encontrándose que el 10% presentaba complicaciones asociadas con los catéteres arteriales como infecciones y complicaciones trombóticas. (Hebal et al., 2018)

## 2.2 Bases Teóricas Enfocadas Métodos Existentes

Las enfermedades cardiovasculares (ECV) son un grupo de desórdenes del corazón y de los vasos sanguíneos. Los ataques al corazón, trombosis y accidentes cerebrovasculares son los fenómenos agudos comúnmente conocidos.

Según la Organización Mundial de la Salud (17 mayo 2017) las enfermedades cardiovasculares son la principal causa de muerte en todo el mundo. Se calcula que en 2015 murieron por esta causa 17,7 millones de personas, lo cual representa un 31% de todas las muertes registradas en el mundo. Más de tres cuartas partes de las defunciones por ECV se producen en los países de ingresos bajos y medios.

Para las personas con enfermedades cardiovasculares o con alto riesgo cardiovascular, son fundamentales la detección precoz y el tratamiento temprano, por medio de servicios de orientación o la administración de fármacos, según corresponda.

Para los pacientes que han sido diagnosticados con alguna enfermedad cardiovascular es esencial el monitoreo de la presión arterial. esta es estimada por la sangre que circula por los vasos sanguíneos. Que son principalmente arterias y venas.

La sangre que circula constantemente por los vasos ejerce presión sobre las paredes vasculares y la presión viene determinada por la fuerza de bombeo del corazón y la elasticidad de los vasos.(Mousavi et al., 2019)

Por esta razón es necesario el estudio de la biofísica del flujo de la sangre en el sistema circulatorio conocido como hemodinámica que es la que nos ayuda a establecer los parámetros para el diagnóstico y monitorización de enfermedades cardiovasculares.

La literatura muestra dos metodologías para el monitoreo de la Presión Arterial (PA): las invasivas y las no invasivas.

Dependiendo de la situación clínica del paciente, el profesional de la salud elige el monitoreo continuo que es medido utilizando un método invasivo de una cánula intraarterial o la (2) medición intermitente que es realizada no invasivamente utilizando el tradicional brazalete de presión (esfigmomanómetro).

El método invasivo (intraarterial) el cual es objeto de nuestro estudio presenta riesgos potenciales para el paciente como la incomodidad, la infección, el sangrado, la obstrucción arterial, o el daño vascular que eventualmente puede producir este procedimiento. Así entonces, un método de monitoreo continuo no invasivo de la PA es deseable y valioso clínicamente.(Scheer et al., 2002)

La fotopletismografía (PPG) produce una señal óptica relacionada con las pulsaciones arteriales volumétricas de la sangre y su análisis puede utilizarse como una alternativa para estimar la PA de manera continua, simple y no invasiva. Así entonces, la PPG es ampliamente aplicable para la detección y evaluación temprana no invasiva de patologías cardiovasculares y de microcirculación periférica (Martínez et al., 2018)

Sin embargo, a pesar de las mejoras de muchos grupos de investigación que han intentado la medición de la presión arterial (PA) sin brazalete, como la de tiempo tránsito de impulso (PTT por sus siglas en inglés) que es el tiempo que tomo el pulso desde el corazón hasta el dedo, otra es la del tiempo de transito vascular (VTT por sus siglas en inglés) que se calcula a partir de la diferencia de tiempo de la medida PPG

tomada en él dedo y  la medida del electrocardiograma (ECG) tomada en el pecho, también se han utilizado múltiples sensores magnéticos para medir la velocidad de la onda de pulso (PWV por sus siglas en inglés) logrando mediciones aceptables pero era necesario la utilización de por lo menos dos sensores lo que lo hace inapropiado para algunas aplicaciones como es la de tener que llevar dos sensores puestos al tiempo durante el ejercicio o durante el sueño. (Khalid, Zhang, Chen, & Zheng, 2018) Así entonces, investigar un método donde solo se aplique la señal PPG con la suficiente precisión seria clínica y prácticamente muy útil.

Otros estudios buscan optimizar la selección de los puntos de las características de la señal fotopletismografía y por ello diseñaron una función para evaluar la calidad de esta. Los resultados de la comparación muestran que el método de fusión (filtro Kalman) de datos es capaz de obtener un subproducto bruto más preciso que otros métodos convencionales, utilizando puntos de característica PPG fijos únicos. (Xu & Gao, 2015)

Otro método el cual se busca estimar la presión arterial a través de un algoritmo support vector machine (SVM por sus siglas en inglés). Es este estudio se encontró que existen dos señales PPG según su forma de onda: la de pulso dicrótico evidente y la no evidente, seleccionándose la señal de pulso dicrótico no evidente como objeto de estudio por ser la más universal o la que más se muestra. También se simplificaron las características extraídas de la señal de 21 a 9 con la premisa de mejorar la precisión y reducir la complejidad del algoritmo. (Zhang & Feng, 2017)

Siguiendo con los estudio que buscan la extracción de los puntos de las características de la señal PPG, se investigó un nuevo método para la estimación continua de dos características principales de la forma de onda de la presión arterial sistólica y diastólica, Para este propósito, se usaron picos de señal PPG para modelar la presión arterial sistólica y canales de señal PPG para modelar la presión arterial diastólica y se

utilizó el modelo ARMA (que es un método de identificación de sistemas que puede proporcionar modelos matemáticos de sistemas dinámicos). (Soltan zadi, Alex, Zhang, Watenpaugh, & Behbehani, 2018)

En este estudio se comparó tres algoritmos de aprendizaje de maquina (árbol de regresión, regresión lineal múltiple (MLR) y máquina vectorial de apoyo (SVM) donde se utilizaron tres características de pulso más significativas (área de pulso, tiempo de aumento de pulso y ancho 25%) además se realizó sobre tres tipos de categoría de presión arterial hipotensión, hipertensión y normal. Arrojando que el algoritmo de árbol de regresión alcanzara la mejor precisión en la estimación de la presión arterial. (Khalid et al., 2018)

Otro estudio demuestra las similitudes tanto en el dominio del tiempo como en la frecuencia de las señales IBP (presión arterial invasiva) y PPG. Se encuentra que la señal PPG es la que más características informativas tiene en comparación con las que existen en IBP. Se realizaron tres hipótesis: H1, H2 Y H3. H1: muestra que las amplitudes de las formas de onda PPG y sus correspondientes formas de onda IBP no están correlacionadas, demostrando que las amplitudes de PPG no pueden sustituir a las amplitudes de IBP. H2: Si la morfología de la PPG (Análisis del dominio del tiempo lineal) está correlacionada con la morfología del IBP, entonces la morfología de la forma de onda de la PPG contiene información valiosa que puede ser usada para evaluar la PA. H3: Si la forma de onda PPG y el IBP tienen información mutua y coherencia (Análisis de dependencia no lineal), entonces la morfología de la forma de onda PPG contiene información valiosa que puede ser usada para evaluar la PA. El rechazo de la hipótesis 1, confirma y valida las otras hipótesis dando pie a la gran similitud que existen entre las dos señales. (Martínez et al., 2018)

# 3.0 Objetivos

## 3.1 Objetivo General

Proponer un método continuo no invasivo para la estimación de la presión arterial a través de señales fotopletismográficas

## 3.2 Objetivos Específicos

- Identificar los fundamentos teóricos y epistemológicos para la estimación continua y no invasiva de la presión arterial.
- Describir los conceptos categorías referentes a la estimación continua y no invasiva de la presión arterial.
- Caracterizar las relaciones entre los elementos y componentes de la estimación continua y no invasiva de la presión arterial.

# 4. Metodología

## 4.1 Método

La siguiente investigación tiene como objetivo proponer un método para estimar la presión arterial basándose en la señal fotopletismográfica, se aplicará el método sistémico como herramienta metodología para abordar fenómenos complejos que ameritan el estudio de técnicas que permitan comprender y mejorar la forma como se abordan estos problemas, donde las situaciones se ven de manera holística, compuesta como un conjunto de elementos diversos que interactúan dentro de un entorno. (Liévano Martínez & Londoño, 2012)

## 5. Mapa Del Documento

Este documento está dividido en seis secciones:

**Introducción:** nos proporcionara los antecedentes suficientes que permitirán identificar el propósito de la propuesta de investigación

**Capítulo 1:** Muestra el desarrollo del primer objetivo donde se muestra la naturaleza del conocimiento creado. Y nos permite interrogarnos acerca de la realidad, el conocimiento, y las relaciones entre sujeto y objeto.

**Capítulo 2:** Muestra el desarrollo del segundo objetivo donde se define cuáles son los conceptos que explicare en mi propuesta de investigación, también defino cuales son los límites y alcances.

**Capítulo 3:** Muestra el desarrollo del tercer objetivo en donde se desarrolla y se evalúa un modelo de predicción de la presión arterial sistólica y diastólica a partir de señales fotopletismográficas aplicando Redes Neuronales Convolucionales.

**Conclusiones:** Este ítem recoge las conclusiones generales del trabajo de investigación, respuestas a las preguntas de investigación y trabajos futuros.

**Referencias:** Se muestran las referencias bibliográficas utilizadas para la construcción del trabajo de investigación**.**

# 6. Capítulo 1: Los Fundamentos Teóricos y Epistemológicos para la Estimación Continua Y no Invasiva de la Presión Arterial

## 6.1 Esfigmomanómetro (Método Indirecto)

En 1896 Riva Rocci introdujo un método indirecto para medir la presión sanguínea basada en hacer la comprensión necesaria para colapsar la arteria en la parte superior del brazo o la pierna para que las pulsaciones arteriales no pudieran ser transmitidas a través de la arteria.

La extremidad se envuelve con un brazalete inflable con un maguito oclusor y se infla hasta que la presión exceda al la de la arteria, cuando esta se ocluye las ondas de pulso transmitida no se pueden palpar ni escuchar distalmente al punto de oclusión.

Luego se empieza a reducir la presión en el brazalete a través de una válvula en el bulbo de inflado y el flujo pulsátil reaparece en la zona ocluida, produciendo sonidos repetitivos provocados por este flujo pulsátil conocidos como sonidos de “korotkoff” en honor al médico ruso que lo descubrió.

Las cinco fases de este cambio de flujo se caracterizan de la siguiente manera:

Fase I: Coincide con la reaparición de un pulso palpable y la aparición de repetitivos golpecitos sonoros.

Fase II: Los sonidos son más suaves y largos, con la calidad de un murmullo intermitente.

Fase III: Los sonidos vuelven a ser más nítidos y fuertes.

Fase IV: Los sonidos son amortiguados, menos distintivos y más suaves

Fase V: Los sonidos desaparecen completamente.

De esta forma los sonidos aparecen por primera vez en el inicio de la Fase I corresponde a la presión sistólica. La presión al comienzo de la amortiguación Fase IV o la desaparición de sonido Fase V se corresponde con la presión arterial diastólica. (Perloff et al., 2012)

### 6.1.1 Equipos para medir la presión sanguínea

El sistema consiste del estetoscopio, el esfigmomanómetro y un sistema de inflación.

- Estetoscopio: consiste en un micrófono o cabeza, tubo y auriculares, se coloca sobre la arteria ocluida para amplificar lo sonidos Korotkoff. La campana, o el filtro de baja frecuencia del micrófono, permite una auscultación más precisa de la Korotkoff suena que el diafragma, especialmente en presiones diastólicas
- Esfigmomanómetro: Un sistema de inflación compuesto por una cámara de aire que puede ser envuelto firmemente alrededor de la extremidad, una bombilla de inflado manual en el manguito, el tubo conectando tanto el manómetro como la bombilla de inflación a la cámara de aire y el manómetro.
- Manómetro: Puede ser de mercurio o aneroide, con una escala calibrada para medir la presión, que es reflejada por la altura de una columna de mercurio o por la ubicación de una aguja giratoria en un escala de marcación. Se prefiere el

manómetro de mercurio y recomendado sobre el manómetro aneroide porque es más preciso, más fácil de mantener y menos probable que se descalibren.

**Figura 4**

*Esfigmomanómetro*

Nota. Adaptado de esfigmomanómetro, venta de equipos medicos, 2017, https://www.ventaequipomedico.top/belmalia-esfigmomanometro-aneroide-con-estetoscopio/

Los métodos directos e indirectos arrojan medidas similares, pero no son métodos idénticos uno mide la presión y el otro es más indicativo del flujo, aunque este método indirecto es menos preciso sin embargo cumple los estándares para su utilización en muchos estudios diagnósticos y terapéuticos por ser practico, simple, de bajo costo y no invasivo.

### 6.2 Intraarterial (Método Directo)

Es una técnica comúnmente utilizada en la Unidad de Cuidados Intensivos (UCI) y también se suele emplear en el quirófano. La técnica implica la inserción de un catéter en una arteria adecuada y luego la visualización de la onda de presión medida en un monitor. La razón más común para utilizar la monitorización de la presión arterial intraarterial es obtener un registro "latido a latido" de la presión arterial de un paciente. Las arterias sobre las cuales se pueden aplicar este procedimiento son: la radial, braquial, femoral y axilar.

Existen tres componentes principales para su monitoreo

- El aparato de medición: Consiste en una cánula arterial para adultos o niños conectada a un tubo que contiene una solución salina el cual conduce la onda de presión al transductor
- El transductor: es un dispositivo que convierte una forma de energía en otra. En este caso un diafragma flexible que cada vez que recibe presión se estira y su resistencia cambia, produciendo una salida eléctrica.
- El monitor: amplifican la señal de entrada haciendo que la señal sea más fuerte, filtran ondas no deseadas mostrando continuamente la forma de onda de la presión arterial en tiempo real.

En cuanto al procedimiento de esta técnica debe desarrollarse de la siguiente forma:

- Con todos los protocolos de asepsia necesarios.
- El brazo debe ser abducido
- La muñeca en una posición anatómica hiperextendida para ayudar a la canulación de la arteria radial.

- El catéter arterial debería estar conectado al tubo.
- El transductor asegurado en una posición aproximadamente a nivel del corazón y colocarlo "a cero", es decir, cerrado al paciente y abierto a la atmósfera para obtener una lectura de la presión atmosférica.
- A menudo es conveniente pegar el transductor a la parte superior del brazo del paciente para asegurar está al nivel del corazón.

## 6.3 Alternativas Para La Obtención De La Presión Arterial De Forma No Invasiva Y Continua

Cuando consideramos los métodos continuos nos referimos a la necesidad de medir la presión arterial en tiempos prolongados de tiempo y los no invasivos a los que no necesitan penetración en la piel. Estas dos condiciones ofrecen una de las formas ideales para medir la presión arterial debido a que ofrecen las características necesarias que permitirán a los médicos obtener parámetros vitales del paciente sin riesgos.

### 6.3.1 Métodos Auscultatorio Y Oscilométrico.

Dos de los métodos no invasivos más conocidos, ambos utilizan un brazalete colocado alrededor del brazo que se infla con una presión superior a la diastólica y luego se desinfla lentamente.

El auscultatorio se basa en captar los sonidos Korotkoff bajo el brazalete que aparecen cuando la presión es igual a la sistólica y desaparecen cuando es igual a la diastólica. Este método es impreciso y depende mucho del usuario. Además, este método no puede ser utilizado para el control a largo plazo porque es necesaria la supervisión de un médico. La presión sanguínea puede ser medida sólo en intervalos de tiempo, con más

de 3 minutos de retraso entre las sucesivas mediciones. Por lo tanto, el método auscultatorio sólo se utiliza durante los exámenes estándar.

El oscilométrico se basa en las oscilaciones de presión que aparecen en la sistólica y desaparecen en la diastólica. Es más utilizado para el control continuo y no invasivo de la presión sanguínea utilizado un método de monitorización conocido como Holter. En este método el paciente necesita una monitorización prolongada de la presión sanguínea, para los cual se le instala un brazalete alrededor de la parte superior del brazo. Durante los días siguientes, este dispositivo automático registra los valores de la presión sanguínea aproximadamente cada 20 minutos con el inflado del manguito. Finalmente, el paciente regresa al consultorio del médico donde se evalúa el perfil de hipertensión y se propone un tratamiento adecuado. Finalmente, el paciente regresa al consultorio del médico donde se evalúa el perfil de hipertensión y se propone un tratamiento adecuado.

Los valores de medición son exactos, pero después de un par de horas, la precisión disminuye y la incomodidad del paciente aumenta. Tal medida no es idealista, porque es incómoda, ruidosa y dolorosa. Especialmente durante la noche, los inflados periódicos del brazalete crean una excitación del sueño y además afectan a los valores de la presión sanguínea. (Geddes LA, 1991)

**Figura 5**

*Los principios de funcionamiento de los métodos auscultatorios y oscilométricas*

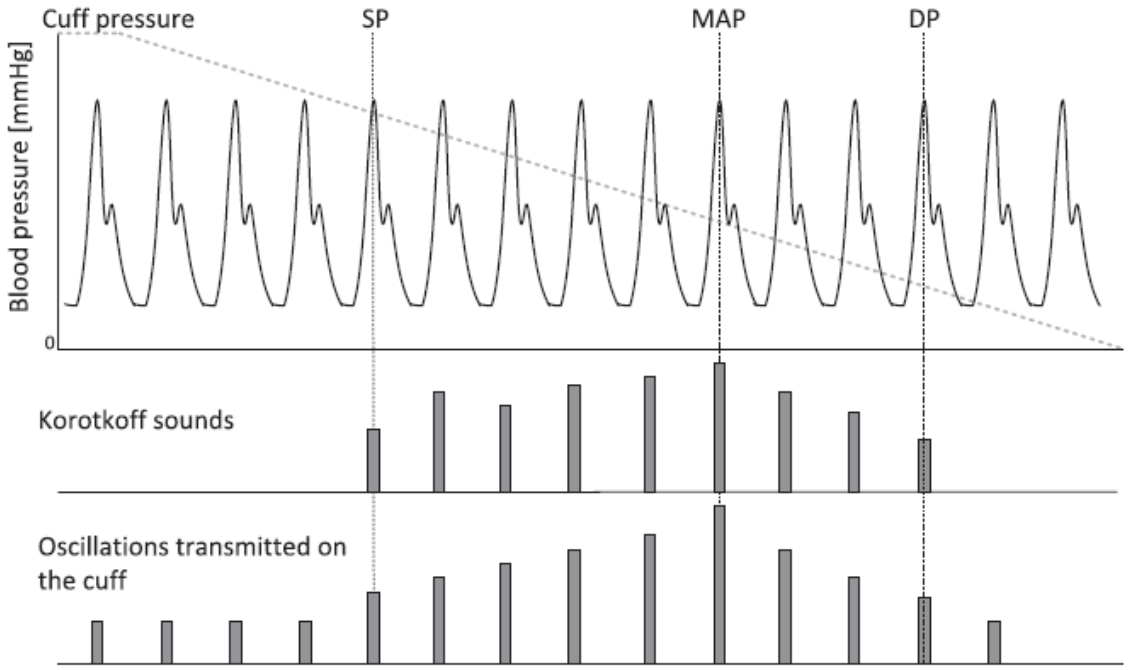


*Nota. los principios de funcionamiento de los métodos auscultatorios y oscilométricos. El primer método evalúa el nivel de los sonidos de Korotkoff, mientras que el segundo método detecta las vibraciones oscilométricas bajo el brazalete braquial.*

### 6.3.2 Método De Tonometría

Es uno de los métodos más apropiados para el monitoreo continuo de la presión arterial, se basa en la aplicación de una fuerza controlada aplicada ortogonalmente en la pared de una arteria superficial, que podría ser la arteria radial por su gran diámetro y fácil accesibilidad la cual debe estar ubicada delante de un hueso. (Sato et al., 1993)

Un sensor en contacto con la piel mide la fuerza sobre la arteria superficial que produce una oclusión local. De este modo no se necesita un brazalete, pero si un dispositivo de apoyo que ejerza una fuerza de empuje, la cual debe ser pequeña para no cerrar completamente la arteria de lo contario no existiría flujo sanguíneo y no se podría medir la fuerza que esta hacia la pared de la arteria.

Debido a la peculiar anatomía de las arterias no solamente es importante aplanar ligeramente la pared vascular con el sensor si no la ubicación de este sobre el centro de la arteria donde la diferencia en milímetros puede ser de correcta a incorrecta llevándonos a que la posición ideal para la medición por tonometría sea la de reposo.(Hermida Amejeiras et al., 2012)

**Figura 6**
*Funcionamiento del método de tonometría*

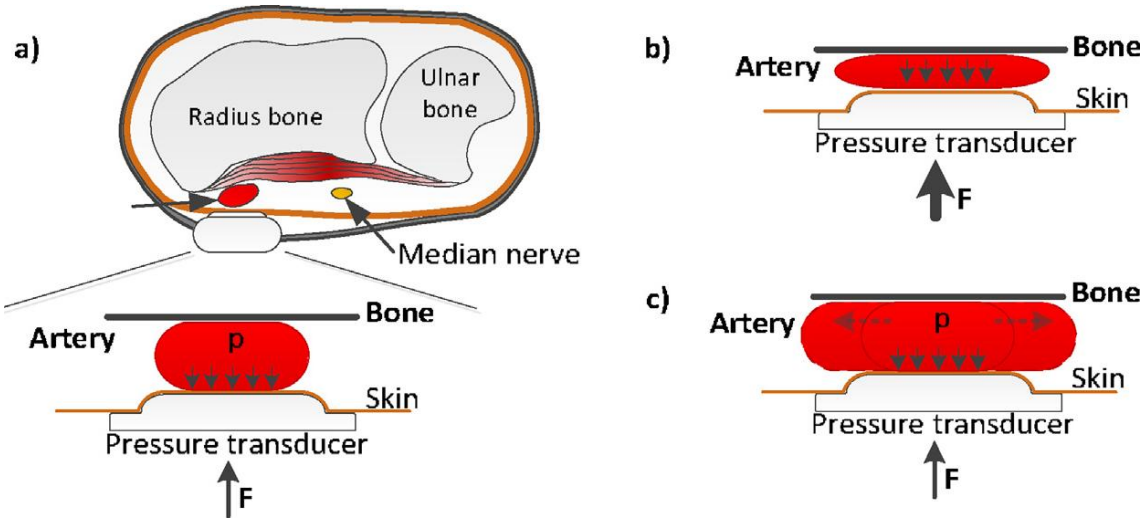


(a): una arteria superficial se comprime contra un hueso plano. Los dos problemas principales del método de tonometría son: (b): si la fuerza aplicada es demasiado alta, la arteria se cierra y no se puede medir la presión sanguínea; (c): cuando la arteria se mueve bajo el sensor, la presión sanguínea también se mide incorrectamente.

### 6.3.3 Método De Pinza De Volumen

En el año 1969, el Dr. Checo Jan Peñaz describió el primer método de medición continua y no invasiva de la presión arterial. Este método sigue siendo parcialmente oclusivo debido a que utiliza un pequeño brazalete que rodea el dedo para ayudar a mantener constante el flujo de la sangre. Además del brazalete inflable alrededor del dedo, utiliza un sensor fotopletismografico que mide el volumen del flujo sanguíneo y una unidad de control de la presión en la muñeca que mantiene un flujo constante.

Este sistema funciona de dos maneras

- Lazo abierto: La presión del brazalete se fija aun nivel constante y el volumen de la sangre en la arteria oscila según los latidos del corazón ocasionando la presión transmural en la arteria
- Lazo cerrado: El volumen vascular controla la presión del brazalete de al forma que cualquier cambio de este es compensado instantáneamente con un cambio en la presión del brazalete.

De este modo surge el nombre de este método donde el volumen de la arteria es fijado como si le colocáramos una pinza para proporcionar un valor constante siendo de crucial importancia para que la presión registrada sea igual a la presión arterial.(Penáz, 1992)

### 6.3.4 Método De Velocidad De Onda De Pulso

Es uno de los métodos que elimina la utilización de un brazalete para obtener la presión sanguínea, debido a que se basa en la medición de la velocidad de las ondas de pulso provocadas por cada latido del corazón y que se propagan a lo largo del árbol arterial.

Se evalúa la medida de tiempo transito pulso a partir de dos valores de tiempo diferente donde el primer valor es el tiempo de retardo entre el pico de la onda R del ECG y la onda de pulso de la carótida, el segundo valor el tiempo de retardo del pico de onda de ECG y la onda de pulso de la femoral donde es el mejor lugar para medir porque se aprovecha la elasticidad de estas arteria centrales y más accesibles. Que se generan durante la eyección del ventrículo izquierdo, después de la apertura de la válvula aórtica.

Es importante recalcar que los profesionales de la salud consideran importante medir la velocidad de los pulsos en estas arterias porque depende directamente de las propiedades elásticas y geométricas de las paredes arteriales, que nos proporcionan mediciones indirectas de la presión sanguínea midiendo continuamente la velocidad de la onda de pulso.

# 7. Capítulo 2: Los Conceptos Categorías Referentes A La Estimación Continua Y No Invasiva De La Presión Arterial.

## 7.1 Fotopletismografía

Etimológicamente la palabra fotopletismografía está formada por: foto del griego phos que significa luz y pletismografía del griego plethusmos que significa agrandamiento. Esta definición está directamente relacionada con la presión sanguínea, la temperatura, la resistencia y elasticidad de los vasos sanguíneos.

Este invento se relaciona con un método de determinación de la presión sanguínea de forma no invasiva y continua mediante un fotopletismógrafo. Este dispositivo proporciona datos que al ser procesados brindan información relacionada al estado de un paciente.

En este caso donde estudiamos la presión arterial, el corazón el cual actúa de forma cíclica produce un máximo de presión al contraer algunas cámaras de este musculo cardiaco conocido como presión sistólica, y una presión mínima que es la fase de relajación del musculo cardiaco permitiendo la entrada de sangre a este, y conocida como presión diastólica.

El estado del arte de a mostrado que sistemas tipo brazalete requieren de la oclusión del flujo sanguíneo y no son adecuados para un uso continuo. Por otro lado, los sistemas tipo intraarteriales que utilizan un piezoeléctrico y generalmente utilizan técnicas

invasivas requieren tiempo, materiales costosos, personal capacitado y causan riesgos la salud del paciente.(Island, 1993)

Sin embargo, durante ciertos momentos críticos, como la cirugía, la unidad de cuidados intensivos, la vigilancia de la presión arterial de forma continua es muy deseable. Por lo tanto, un método continuo, no invasivo de la presión sanguínea de un paciente sería muy beneficioso.

Los métodos que utilizan un fotopletismógrafo, utilizan la luz para determinar y registrar las variaciones en el volumen de la sangre, además de instanciar nítidamente los cambios en el volumen de la sangre en el ciclo cardiaco. La fotopletismografía es una técnica no invasiva y continua para la detección de ondas cardiovasculares que se propagan a través de este sistema el cual va registrando las variaciones en el volumen sanguíneo que ocurre en cada ciclo cardiaco.

El procedimiento para su implementación consiste en irradiar una zona del tejido con luz de un diodo emisor de luz conocido como LED para medir la intensidad de señal de salida obtenida por reflexión si el diodo receptor es adyacente al emisor o transmisión si el receptor es opuesto al emisor como se muestra en la siguiente figura.

**Figura 7**
*Transmisión y reflexión*

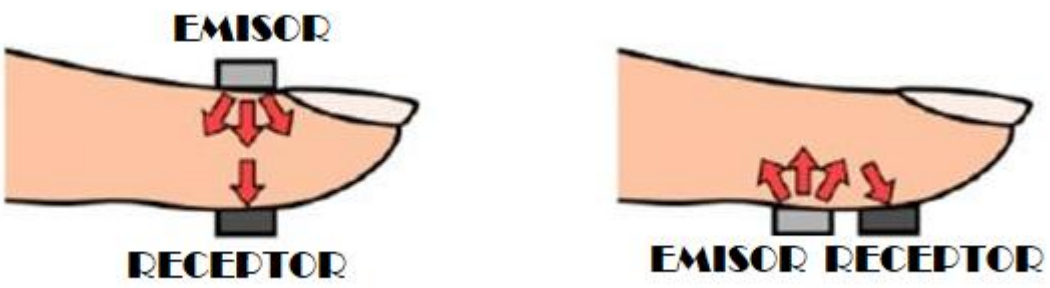

Nota. Adaptado de transmisión y reflexión, Cristian Camilo Velandia Cárdenas, 2016, https://www.researchgate.net/figure/Adquisicion-de-la-senal-de-pulso-oximetria-transmision-y-reflexion-Fuente-autores_fig1_319146237

Estos diodos emisores y receptores, son conocidos como sensores por transmisión y reflexión en fotopletismografía por su disposición

**El sensor de transmisión:** estos diodos se tienen que colocar enfrentados, en la parte del cuerpo que se medirá, las zonas más comunes y adecuadas para esta medición son el lóbulo de la oreja, el dedo y el puente de la nariz que son estrecha y periféricas.

**El sensor por reflexión**: estos diodos se colocan adyacentes de manera que capte la luz que se refleja de los tejidos, sería el más útil porque puede ser colocado sobre cualquier superficie vascular pulsátil, pero tiene como desventaja que la señal será muy débil debido a que existe más cantidad de señal transmitida que reflejada.

El resultado de la medición con un fotopletismógrafo es un fotopletismograma (PPG), el cual está compuesto por la superposición de varias señales que contienen una componente continua (DC) y una componente alterna (AC).

La componente DC es debido a la absorción normalmente constante de luz del sistema venoso periférico como los capilares, tejidos y huesos la cual es despreciada por no aportar información útil, la componente alterna es la causada por el flujo sanguíneo que es la de mayor importancia para nuestro estudio.

**Figura 8**
*Fotopletismograma*

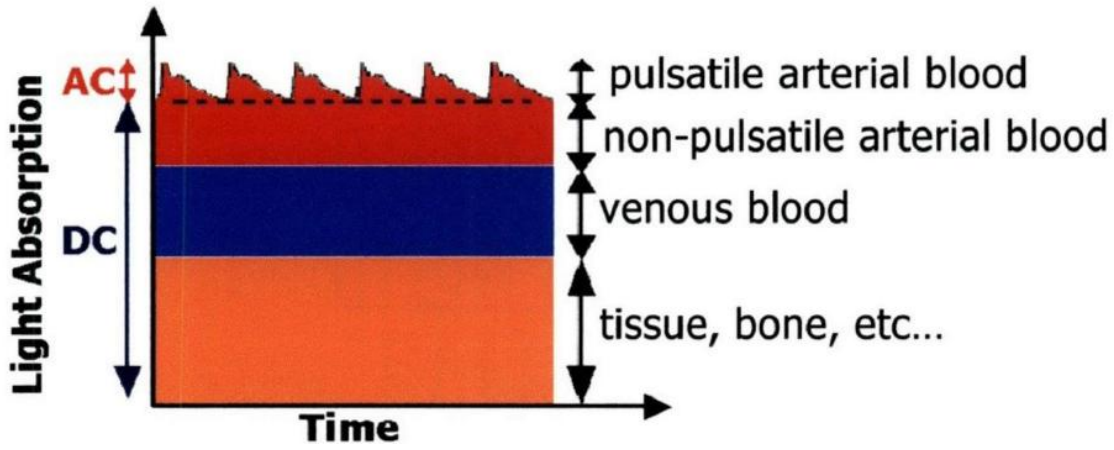


Nota. Adaptado de fotopletismografia, Carlos Eduardo Valencia Urbina, 2017, http://ricabib.cab.cnea.gov.ar/635/1/Valencia_Urbina.pdf

Esta señal AC es amplificada y se convertirá en un diferencial de voltaje de acuerdo a la luz recibida que es el registro de la variación del volumen de sangre. Esto dependerá de la cantidad de luz absorbida por los vasos subcutáneos y de la densidad de los glóbulos rojos en su interior que al oxigenarse y desoxigenarse (saturación de oxígeno) cambian de color debido a las propiedades ópticas de la hemoglobina. (Alzahrani, Hu, & Azorin-Peris, 2015)

Por definición la hemoglobina es una hetero-proteína de la sangre que da el color rojo característico de esta, transportando el oxígeno desde los órganos respiratorios hasta los tejidos. Cuando la hemoglobina esta oxigenada es de color rojo intenso y una vez perdida su oxigenación presenta un color rojo oscuro.

De esta forma la sangre se compone de dos absorbedores de luz distintos uno con la hemoglobina oxigenada y otro con la hemoglobina reducida o desoxigenada de las cuales se obtienen diferentes longitudes de onda del espectro luminoso de 660 nm y 940 nm que son leídas por el fotopletismógrafo.

Esta técnica óptica basada en las variaciones de la intensidad de luz se suministrada y refleja depende de las propiedades de absorción óptica de los tejidos como es el cambio de volumen de un lecho microvascular del tejido al cual se le está realizando la muestra.

Esta interacción opto-fisiológica entre iluminación y tejido biológico que relaciona la absorción de luz con las propiedades del material atravesado fue propuesta por la ley de Lambert beer con la siguiente ecuación: $I = I_0 e^{-(d*neff)}$.

Donde $I_0$ es la intensidad de luz que recorre un camino de longitud $d$ a través de un cuerpo por el cual circula un flujo pulsátil caracterizado por una absorción $neff$.(Hu et al., 2013)

De esta forma con la fotopletismografía se puede capturar a través de una señal que manifiesta la actividad del corazón con un dispositivo que se coloca en alguna parte del cuerpo donde se exponga el aparato circulatorio cerca de la piel y así con la captura de las variaciones de luz no absorbidas nos permite calcular la frecuencia cardíaca, el porcentaje de saturación de oxígeno de la sangre arterial, la viscosidad de la sangre y la presión arterial.

### 7.2 Estimar La Presión Arterial Con Fotopletismografía

La forma de onda PPG comprende una onda fisiológica pulsátil con dos componentes "AC" que se atribuye a los camios cardiacos sincrónicos en el volumen sanguíneo con

cada latido del corazón, y suele tener su frecuencia fundamental, normalmente alrededor de 1 Hz dependiendo de la frecuencia cardiaca. Pero a esta componente se le superpone otra componente “DC” que se relaciona con los tejidos y el volumen medio de la sangre que a su vez depende de otras características como la respiración, la actividad vasomotora, las ondas vasoconstrictoras, lugar del cuerpo y movimiento del dispositivo. (Dehghanojamahalleh & Kaya, 2019)

**Figura 9**
*Diagrama de bloques*

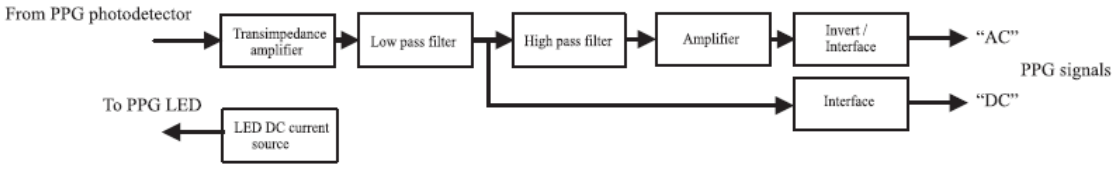


Nota. Adaptado de “Sex-Related Differences in Photoplethysmography Signals Measured from Finger and Toe”, por IEEE Journal of Translational Engineering in Health and Medicine, IEEE Journal of Translational Engineering in Health and Medicine.

El fotodetector se conecta a circuitos electrónicos de bajo ruido que incluyen un amplificador de transimpedancia y circuitos de filtrado. Un filtro de paso alto reduce el tamaño del componente DC dominante y permite que el componente AC pulsátil sea elevado a un nivel nominal de 1 V de pico a pico. También se necesita un circuito de filtrado cuidadosamente elegido para eliminar los ruidos no deseados de alta frecuencia, como la captación eléctrica de la interferencia de frecuencia de la red eléctrica (50 Hz). (Allen, 2007)

Con el filtrado y la amplificación electrónica adecuados se pueden extraer tanto la CA como la CC para el posterior análisis de las ondas de pulsos. Estas características

importantes las obtenemos de la componente “AC” de la PPG las cuales fueron descritas por Hertzman y Spealman (1937) donde la aparición de esta forma de onda se definió en dos fases: fase ***anacrotica*** que es el borde ascendente del pulso que depende de la aceleración del flujo arterial en la fase de sístole y la fase ***catacrotica*** el borde descendente del pulso que corresponde a la desaceleración provocada por la fase diástole. En esta fase puede aparecer una pequeña curva positiva menor estimulada por el cierre brusco de la válvula aórtica conocida como onda dicrota como se muestra en la figura.

**Figura 10**
*Forma de onda señal PPG*

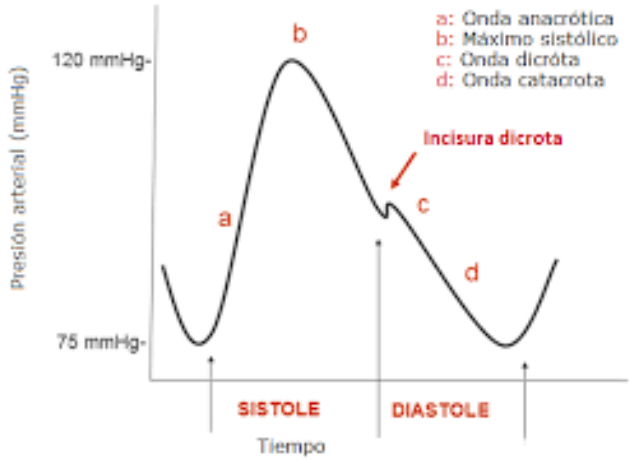


Nota. Adaptado de “Técnicas para la estimación precisa del HRV mediante un sensor fotopletismográfico” (p. 12), por Laura Álvarez Gómez, 2015.

la señal PPG tiene un equivalente como en la señal electrocardiográfica conocido como la serie temporal RR donde se determinan los instantes de ocurrencia de cada pulso cardíaco. En cambio, en la señal PPG su equivalente es la serie temporal PP que aún no está estandarizada.

Esto hace que sea muy difícil al momento de determinar información importante sobre las propiedades inherentes de una señal y así obtener una calibración precisa y completa para poder determinar los valores de la presión arterial sistólica y diastólica.

ha sido el interés de la comunidad de investigadores desarrollar métodos y aparatos para determinar la presión sanguínea a partir de señales biomédicas de forma continua, sin manguito y de manera no invasiva.

En la actualidad, los relojes inteligentes, las bandas fitness, saturación de oxígeno, gasto cardiaco, detector de enfermedades cardiovasculares han llevado a estudios e innovaciones que están relacionados con la fotopletismografía y sus posibilidades de obtener una medición de la presión arterial sistólica y diastólica que sea confiable y precisa**.**

En la siguiente tabla se resumen algunos métodos para estimar la presión arterial con fotopletismografía los cuales sientan una base para nuestra propuesta de investigación.

Métodos con dos sensores

**Tabla 2**

*Métodos para es timar presión arterial con dos sensores*

| Siglas | Nombre | sensores |
|---|---|---|
| PTT | Tiempo Transito pulso | ECG y PPG |
| VTT | Tiempo transito vascular | Fonocardiografia y PPG |
| PWV | Velocidad onda pulso | PPG y PPG |

**7.3 Método Propuesto**

La vigilancia continua de la presión sanguínea parece ser la opción más viable para pacientes con problemas cardiovasculares y en especial en unidades de cuidados intensivos, pero esto exige un proceso invasivo, que podría tener complejidades. Esto

nos motiva a desarrollar un método para predecir la forma de onda de la presión arterial continua a través de un enfoque no invasivo usando señales fotopletismográficas (PPG).

Se exploran técnicas de Aprendizaje Profundo (Deep Learning) mediante las cuales se analizan señales fotoplestimográficas reales (dejando de lado aquellas señales ideales conocidas como apropiadas) para estimar el valor de la presión a través de esta, haciendo irrelevante el cálculo de características o puntos fijos de la señal, que es una deficiencia de los enfoques existentes.

### 7.3.1 Inteligencia artificial (IA)

Ciencia que trata de comprender como los seres humanos podemos percibir, entender, predecir y manipular un entorno complejo, para luego aplicar estos modelos teóricos en una maquina o programas que debería ser capaz de reflejarlos. (Meya, 1986)

En el siguiente mapa mental se muestran los dos enfoques de la inteligencia artificial:

**Figura 11**
*Mapa de los enfoques de inteligencia artificial*

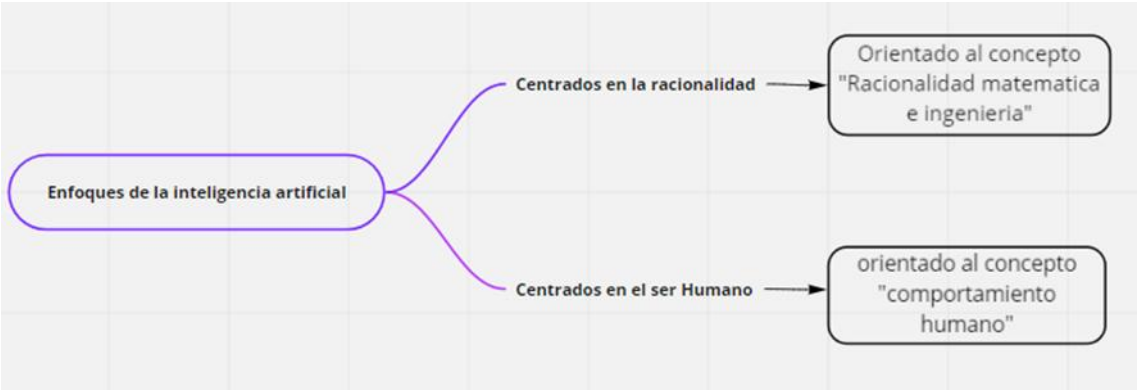


Nota. Adaptado de Inteligencia Artificial IA, por iainacap, https://sites.google.com/site/iainacap/home/-que-es-una-ia

Centrados en la racionalidad simulan directamente las características inteligentes que se pretenden conseguir o imitar del hombre; para los artífices de los sistemas expertos resulta fundamental la representación del conocimiento humano, donde estos avances han encontrado dos tipos de conocimiento: conocimiento acerca del problema particular y conocimiento acerca de cómo obtener más conocimiento a partir del que ya tenemos. Lo cual no es fácil porque se necesita transformar conocimiento informal y expresarlo en los términos formales que requieren de notación lógica. (Russell, 2004)

Centrados en el ser humano sus esfuerzos se orientan a la simulación de los elementos de más bajo nivel dentro de los procesos inteligentes del comportamiento humano, con la esperanza de que estos al combinarse permitan que espontáneamente surja el comportamiento inteligente. Como cuando se sugirió la prueba basada en la incapacidad de diferenciar entre entidades inteligentes indiscutibles y seres humanos (Test de Turing)

Los ejemplos más claros que trabajan con este tipo de orientación son las redes neuronales y los algoritmos genéticos donde estos sistemas trabajan bajo la autonomía, el aprendizaje y la adaptación, los cuales deben estar fuertemente relacionados.

La inteligencia artificial nació en los años 50 donde algunos pioneros de las ciencias de la computación se plantearon como lograr que las computadoras pensaran. Los primeros programas solo involucraban reglas rígidas creadas por programadores lo cual no se consideraba como aprendizaje automático.

Se creyó durante mucho tiempo que se podía crear un conjunto de reglas bastante grande para manipular conocimiento y de esta forma crear maquinas inteligentes. Lo que llevo a un paradigma conocido como a IA simbólica que pondero desde el año 1950 hasta finales de 1980.

Este paradigma de la IA simbólica probo ser adecuado para problemas lógicos y bien definidos, donde los humanos inyectaban reglas y datos que eran procesados para obtener una respuesta a la salida del programa, pero se se volvió intratable para manejar problemas más complejos como de clasificación y reconocimiento. Surgiendo un nuevo enfoque como el Machine Learning o aprendizaje automático.

El aprendizaje automático se busca alimentar con unos datos y respuestas a un proceso para obtener unas reglas que son las salidas, estas son aplicadas a nuevos datos y de esta forma producen repuestas originales que fueron generadas automáticamente o aprendidas por el sistema. Observándose que el aprendizaje automático es entrenado y no programado como la IA.

No obstante, el aprendizaje automático, que surgió desde los años 90 se ha convertido en el más popular de los sub-campos de la inteligencia artificial, además de una tendencia de mejor cantidad de recursos hardware para manejar una mayor cantidad de datos nos lleva a otro sub-campo del aprendizaje automático y es el aprendizaje profundo.

Sabemos que el aprendizaje automático engloba tres ingredientes fundamentales. Datos de entrada, las etiquetas o salidas esperadas y una forma de medir el algoritmo para saber si hay diferencia entre las salidas generadas por el algoritmo y las esperadas o etiquetas.

De esta forma un modelo de aprendizaje automático transforma los datos de entrada en respuesta con significado donde ocurre un proceso de aprendizaje, lo que nos lleva a entender un poco el enfoque del aprendizaje automático el cual trata de aprender representaciones útiles de los datos de entrada que lo lleven a la predicción de las salidas esperadas.

Como mencionábamos anteriormente esta representación de los datos será el núcleo del aprendizaje automático y por ende el del sub-campo de aprendizaje profundo, donde se trata de ver de una forma diferente los datos y convertir este aprendizaje en una búsqueda automática de mejores y más útiles representaciones para los datos.

El aprendizaje profundo se podría expresar como un nuevo intento en mejorar el aprendizaje de los datos utilizando representaciones de manera sucesiva y jerarquizada de los datos por medio de capas.

**Figura 12**
*Jerarquia de la inteligencia artificial*

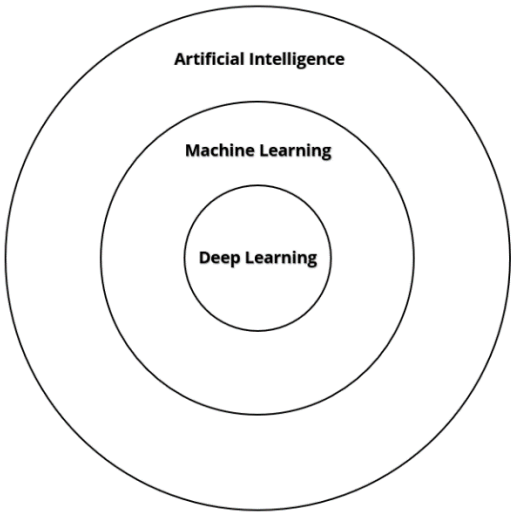


### 7.3.2 Aprendizaje Supervisado vs Aprendizaje No Supervisado

Los modelos de aprendizaje automático se pueden dividir en supervisado y no supervisado se diferencia por las etiquetas o salidas esperadas conocidas como los datos de entrenamiento.

El aprendizaje supervisado: Consiste en aprender una función que transforme los datos de entrada (o la observación del fenómeno) la cual pertenece a una etiqueta que es la obtenida por dicha observación. Esta función es ajustada por unos parámetros a partir de un entrenamiento, la cual calcula una correspondencia matemática entre los elementos de entrada y las salidas que son obtenidos estadísticamente tras una forma de probabilidad condicional, dadas las etiquetas y valore de entrada (likelihood).

El aprendizaje no supervisado: a diferencia del supervisado no es necesario disponer de una etiqueta en los datos de entrenamiento porque no buscamos la reproducción de un dato conocido si no descubrir patrones desconocidos.

De esta forma el aprendizaje puede ser clasificado de acuerdo a los datos que pueden o no tener identificadores conocidos como lo mencionamos anteriormente y es por esto, que en nuestro problema, los datos están etiquetados con dos valores, clasificándolo en un aprendizaje supervisado.

### 7.3.3 Algoritmos De Clasificación VS algoritmos de Regresión

Otras categorías del aprendizaje automático, derivados del tipo de problema, y no del entrenamiento, son la clasificación y predicción.

- El problema de clasificación se refiere a un análisis de discriminación donde el algoritmo debe entregar una respuesta discreta en base a un conjunto de categorías. El mínimo de categorías en los problemas de clasificación es dos y el número de posibles respuestas infinito

- El Problema de predicción se refiere a un análisis de regresión que es cuando las predicciones no son discretas, es decir, que los valores que se intentan reproducir son continuos, donde el conjunto de respuestas está definido por un conjunto infinito como por ejemplo estimar la presión arterial. En donde las características encontradas por el modelo serán nuestra variable independiente y la predicción nuestra variable dependiente

El análisis de regresión es uno de los problemas comunes que se presentan, pero en la literatura de redes neuronales lo común es solucionar problemas de clasificación.

En este caso para nuestro problema se realizará un análisis de regresión para encontrar tendencias en los datos que predecirán un valor continuo, en lugar de una etiqueta como es el valor de la presión arterial sistólica y diastólica. (Hussain et al., 2020)

El análisis de regresión nos proporcionará la conexión para que se pueda hacer predicciones sobre los datos de la señal fotopletismográfica.

Este último enfoque es que aplicaremos a nuestro proyecto.

### 7.3.4 Aprendizaje profundo

Las representaciones por capas son casi siempre aprendidas por modelos llamados redes neuronales, los cuales están estructurados por capas apiladas. Las redes neuronales hacen referencia a la neurobiología en donde no le decimos al ordenador cómo resolver nuestro problema. En lugar de ello, aprende de los datos de observación, averiguando su propia solución al problema en cuestión.

Hasta 2006 no sabíamos cómo entrenar a las redes neuronales para que superasen los enfoques más tradicionales, excepto para algunos problemas especializados. Lo que cambió en 2006 fue el descubrimiento de técnicas de aprendizaje en las llamadas redes neuronales profundas. Estas técnicas se conocen ahora como aprendizaje profundo. Se han desarrollado aún más, y hoy en día las redes neuronales profundas y el aprendizaje profundo logran un rendimiento extraordinario en muchos problemas importantes de visión por ordenador, reconocimiento del habla y procesamiento del lenguaje natural.

Lo que nos lleva a los diferentes tipos de redes neuronales de aprendizaje profundo

***7.3.4.1 Las redes neuronales artificiales (ANN).*** La red neuronal artificial, o RNA, es un grupo de múltiples perceptrones/ neuronas en cada capa. La RNA también se conoce como red neuronal de alimentación directa, ya que las entradas se procesan sólo en la dirección de avance.

Por lo tanto, en el caso de una red neuronal con un gran número de capas ocultas, el gradiente se desvanece o explota a medida que se propaga hacia atrás, lo que lleva a que el gradiente se desvanezca y explote.

**7.3.4.2** ***Las redes neuronales recurrentes (RNN)*** La cuales captan la información secuencial presente en los datos de entrada, es decir, la dependencia entre las palabras del texto, mientras realiza predicciones:

**Figura 13**
*Compartición de parámetros*

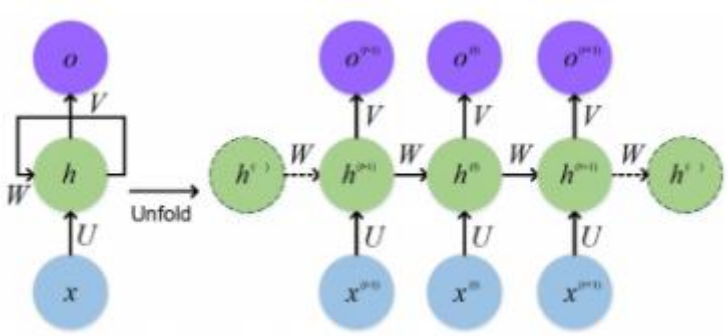


Nota. Adaptado de Redes Neuronales Recurrentes, por sensioai, 2020, https://sensioai.com/blog/034_rnn_intro.

Como se puede ver aquí, la salida (o1, o2, o3, o4) en cada paso de tiempo depende no sólo de la palabra actual sino también de las palabras anteriores.

Las RNN comparten los parámetros en diferentes pasos de tiempo. Esto se conoce popularmente como "Parameter Sharing". De este modo, hay menos parámetros que entrenar y se reduce el coste computacional. Pero también sufren el problema de la desaparición y la explosión del gradiente,

#### *7.3.4.3 Redes neuronales convolucionales (CNN)*

Las redes convolucionales (CN) incorporan restricciones y logran cierto grado de invariabilidad de desplazamiento y deformación utilizando tres ideas: campos receptivos locales, pesos compartidos, y espacio submuestreo además de tener cientos de millones de parámetros conformadas por 10 y 20 capas que nos lleva a una de las ramas del  machine learning que se conoce como aprendizaje profundo.(Rostami et al., 2017)

En la siguiente tabla se muestra las diferencias de las redes neuronales dando justificación a la escogencia de las redes neuronales convolucionales para este proyecto

**Figura 14**
*Diferencias entre Redes neuronales*

| | MLP | RNN | CNN |
|---|---|---|---|
| Data | Tabular data | Sequence data (Time Series,Text, Audio) | Image data |
| Recurrent connections | No | Yes | No |
| Parameter sharing | No | Yes | Yes |
| Spatial relationship | No | No | Yes |
| Vanishing & Exploding Gradient | Yes | Yes | Yes |

Nota. Adaptado de CNN vs. RNN vs. ANN – Analyzing 3 Types of Neural Networks in Deep Learning, por analyticsvidhya, 2020, https://www.analyticsvidhya.com/blog/2020/02/cnn-vs-rnn-vs-mlp-analyzing-3-types-of-neural-networks-in-deep-learning/

Para explicar mejor el funcionamiento de las redes neuronales convolucionales y el porqué de su escogencia, tenemos que adentrarnos en ellas diciendo que es una categoría que han demostrado ser muy eficaces como el reconocimiento y la clasificación para cuales hay que realizar seis operaciones principales:

- El paso convolucional

- Introducción de la no linealidad (ReLU)

- The Pooling Step

- Capa completamente conectada más paso de regresion

- Capa De Regularización

- Backpropagation

Estas operaciones se podrían decir que son los componentes básicos de toda red neuronal convolucional por lo que explicaremos cada uno de ellos y así obtener una mejor comprensión.

Antes de entrar en estas cinco operaciones cabe comenzar explicando que es una imagen. la cual es la materia prima y entrada de una red neuronal. Básicamente toda imagen puede representarse como un conjunto de valores conocidos como pixeles, donde interviene un termino llamado canal que es un componente de una imagen basado en tres colores (rojo, verde y azul) que se puede interpretar como una matriz apilada,

una para cada color en el rango de 0 a 255 en los pixeles. Aunque pueden ser de un solo canal y no tres como se mencionó anteriormente las imágenes en la escala de grises.

*7.4.3.3.1 El Paso Convolucional* su nombre deriva del operador matemático "convolución" cuyo objetivo es extrae las características de una imagen de entrada preservando la relación espacial de los pixeles al momento de realizar el aprendizaje utilizando pequeños paralelogramos de datos de entrada como se muestra en la siguiente figura:

**Figura 15**
*Convolución*

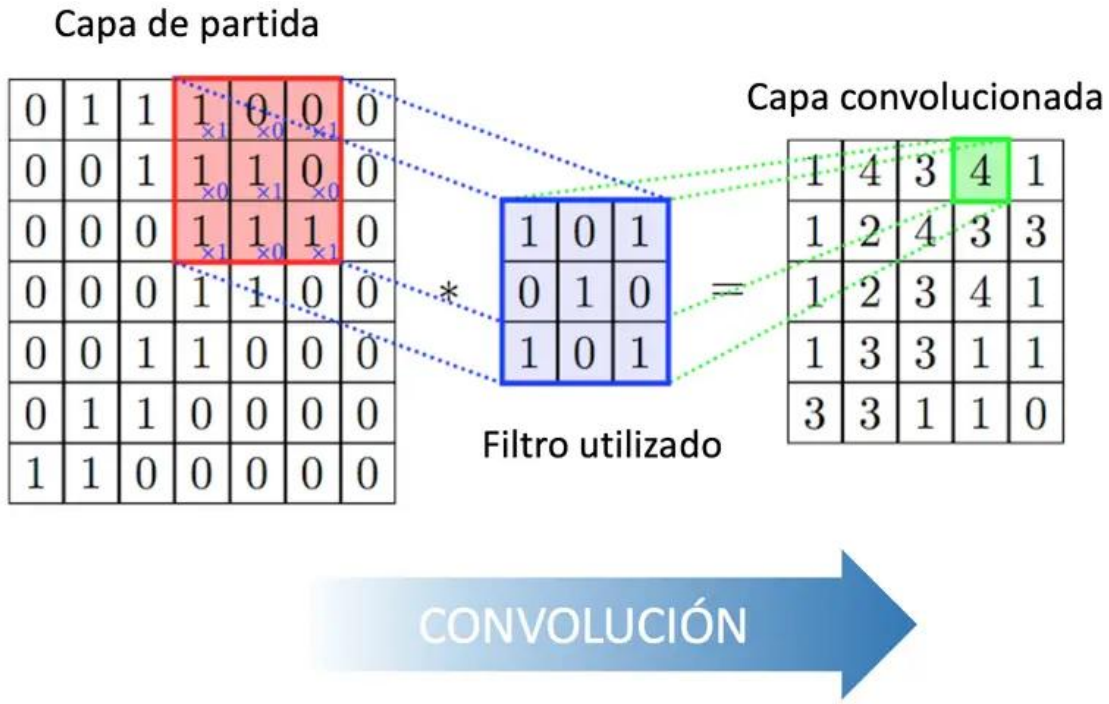


Nota. Adaptado de Red Neuronal Convolucional CNN, por diegocalvo, 2017, https://www.diegocalvo.es/red-neuronal-convolucional/

El cálculo se realiza de la siguiente forma desplazamos la matriz azul sobre nuestra imagen que está representada por pixeles en 0 y 1, esta matriz azul realizara zancadas de algunos pixeles hasta completar por completo las dimensiones de nuestra imagen de entrada, posteriormente se realizara una multiplicación entre marices obteniéndose un entero que es el que se observa en la matriz resultado.

Recordando que la matriz de tres por tres o filtro ve una sola parte de la imagen de entrada en cada paso y es la que nos ayuda a detectar características. Produciendo de esta manera diferentes matrices llamadas mapas de características para la misma imagen de entrada.

Las redes CNN aprenden de los valores obtenidos de estos filtros por si misma durante el proceso de entrenamiento, por esta razón entre mayor sea el número de filtros más

características de la imagen se extraerán y mejor será para reconocer patrones. (Méndez & Ibarra, 2014)

El mapa de características está controlado por tres parámetros:

- Stride: parámetro de desplazamiento es decir el número de pixeles por el que deslizamos nuestra matriz de filtros.
- Padding: parámetro para definir que las salidas de las capas tendrán las mismas dimensiones que las salidas utilizando o n rellenos con cero.
- Depth: corresponde al número de filtros que utilizamos para la operación de la convolución.

*7.4.3.3.2 Introducción de la no linealidad (ReLU)* es utilizada después de cada convolución realizando una operación de remplazo en ceros todos los valores negativos de los pixeles en el mapa de características debido a que los eventos del mundo real son no lineales haciendo más enriquecedor el aprendizaje.

También se pueden utilizar otras funciones no lineales, como tanh o sigmoide, en lugar de ReLU, pero se ha comprobado que ReLU funciona mejor en la mayoría de las situaciones.

*7.4.3.3.3 El Paso de pooling* también llamado submuestreo el cual reduce la dimensión de cada capa de características, pero conservando la información más importante y puede ser max, average, sum.

Se determina una ventana de la cual se hace una rectificación con la ventana y el mapa de características y se toma el elemento más grande, la media o la suma de los

elementos en esa ventana. Pero se ha demostrado que el max pooling es el de mejores resultados.

**Figura 16**
*Submuestreo*

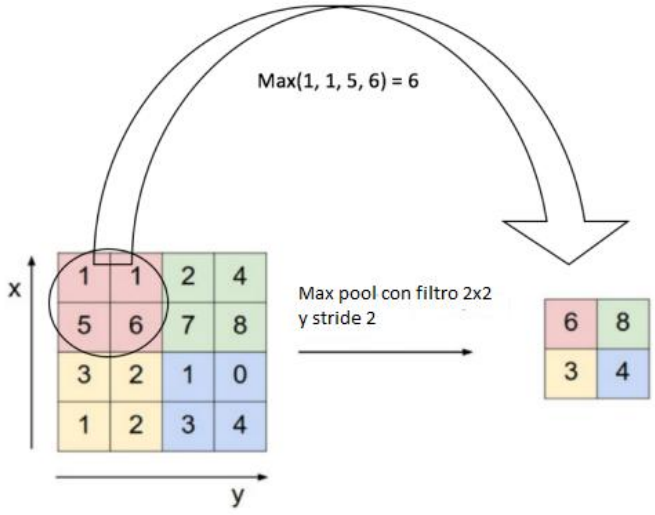


Nota. Adaptado de Redes Neuronales Convolucionales, por Consultores estratégicos en Ciencia de Datos, 2018, https://www.juanbarrios.com/redes-neurales-convolucionales/

En la figura anterior, se puede apreciar un filtro de 2x2 y un desplazamiento de dos pixeles al cual se le aplica un submuestreo max en cual la primera ventana comprende valores (1,1,5,6) formando una matriz de 2x2 en donde su primera fila y columna se coloca el valor máximo de esa rectificación.

Como se puede ver se hace una reducción progresiva de la imagen de entrada obteniéndose que:

- sean más pequeñas y manejables
- reduce el número de parámetros y cálculos en la red.
- la red es invariable a pequeñas transformaciones, distorsiones y traslaciones en la imagen de entrada

- podemos detectar objetos en una imagen sin importar dónde se encuentren

*7.4.3.3.4 Capa Totalmente Conectada más paso de regresión* es un perceptrón multicapa que utiliza una función de activación softmax en la capa de salida lo que implica que cada neurona de la capa anterior eta conectada a cada neurona de la capa siguiente, donde su propósito es utilizar las características extraídas de la capa de convolución y agrupación para obtener tendencias y as predecir valores continuos asado en los conjuntos de entrenamiento

*7.4.3.3.5 Capa De Regularización* En esta capa se permite el ajuste de los pesos de las neuronas activas aplicando o no, una técnica de regularización conocida como dropout, que es un apagado aleatorio de estas neuronas para que no sean ajustados sus pesos y dejando activas aquellas que se tengan que ajustar. Es muy simple y útil porque ayuda acelerando el aprendizaje y reduciendo el sobreajuste

*7.4.3.3.6 Backpropagation* se usa para calcular los gradientes de error con respecto a todos los valores iniciales de la red y de esta forma utilizar el descenso del gradiente para actualizar todos los valores de los filtros y pesos de conexión para minimizar el error de salida y acercarse más al valor objetivo.

**Figura 17**
*Etapas red convolucional*

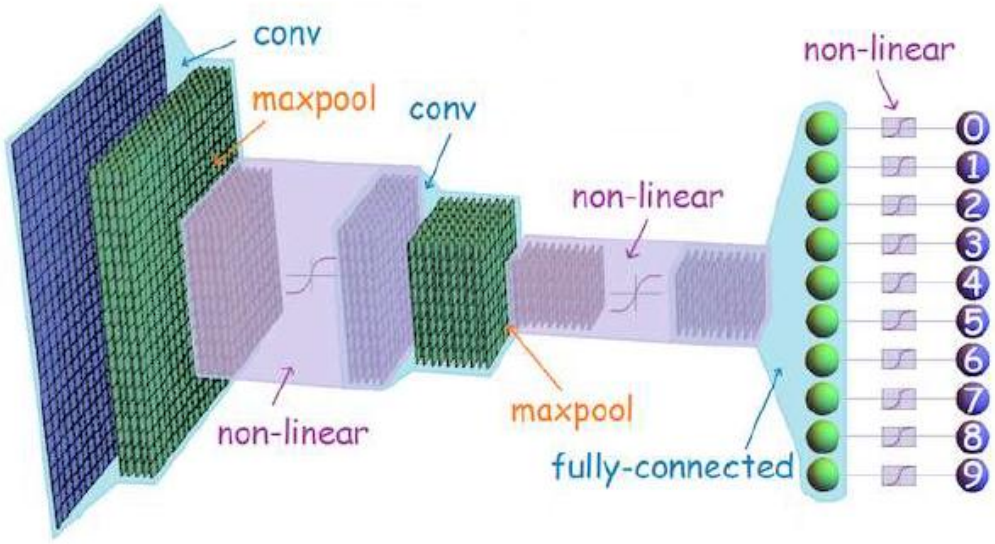


Nota. Adaptado de Red Neuronal Convolucional CNN, por diegocalvo, 2017, https://www.diegocalvo.es/red-neuronal-convolucional/

## 8. Capítulo 3: Las Relaciones Entre Los Elementos Y Componentes De La Estimación Continua Y No Invasiva De La Presión Arterial

En este capítulo se describe detalladamente el enfoque propuesto para esta investigación. Se utilizarán Redes Neuronales Convolucionales como técnica de Aprendizaje Profundo dentro del campo de la Inteligencia Artificial para acometer la tarea de realizar estimaciones de la presión arterial utilizando como **entrada** señales fotoplestimográficas (*PPG*) obtenidas de manera continua y no invasiva mediante un dispositivo físico de lectura adosado a un paciente. Realizar estimaciones implica que la **salida** son predicciones (*un problema de regresión en Inteligencia Artificial*) de los valores de presión arterial sistólica (*SBP: Sistolic Blood Pressure*) y presión arterial diastólica (*DBP: Diastolic Blood Pressure*), elementos que componen lo que se conoce como presión arterial.

Para realizar dichas estimaciones se requiere una profunda fase de entrenamiento en el que el Modelo Propuesto de Red Neuronal Convolucional aprenda de manera inteligente y supervisada los elementos y características que permiten relacionar los datos de entrada con los datos de salida.

Como insumo para esta tarea de Aprendizaje Profundo, se toma el conjunto de datos (*dataset*) de signos vitales de la Universidad de Queensland (Australia) que contiene una amplia gama de datos de monitorización de pacientes y signos vitales que se registraron durante 32 casos quirúrgicos en los que los pacientes se sometieron a anestesia en el Royal Adelaide Hospital (Liu D, Gorges M, Jenkins, 2012). Dentro de estos datos de monitorización están las lecturas *PPG*, *SBP* y *DBP* (entre otras).

Para la utilización efectiva de este dataset se aplican algoritmos de extracción, limpieza, preparación, transformación y carga de datos. Estos algoritmos son implementados como secuencia de instrucciones (*scripts*) utilizando el lenguaje de programación Python.

Como resultado del proceso anterior se obtienen un conjunto de datos con 5500 tuplas (registros estructurados con información *PPG*, *SBP*, *DBP*) de información depurada.

### 8.1 Bases de datos (*dataset* origen)

Los datos fueron obtenidos de cuatro quirófanos del "**Royal Adelaide Hospital**" usando una combinación de dos monitores *IntelliVue MP70* y *IntelliVue MP30* a lo cuales se conectó un ordenador portátil por interfaz serial RS-232 y software personalizado para recoger las formas de onda y los datos de alarma.

Se registró una sola corriente de datos en bruto con valores separados por comas (**csv**), resolución de muestreo de 10 milisegundos mediante una interpolación cúbica de los datos brutos de vigilancia de cada paciente.

Se registraron datos de vigilancia de 32 pacientes que oscilaban en duración de 13 minutos a 5 horas (mediana de 105 min.). Los 32 casos consistían en 25 casos generales anestésicos (20 con un tubo endotraqueal, 5 con un tubo laríngeo)

Las señales obtenidas fueron: **DBP** (*Diastolic Blood Pressure mmHg*), **SBP** (*Sistolic Blood Pressure mmHg*), ECG (*electrocardiogram*), SpO2 (*blood oxygen saturation %*), **Pleth** (*plethysmograph*) entre otras.

Entre los problemas presentados y que llevaron a una gran revisión de estos datos fue la línea de muestra del monitor *IntelliVue MP30*, se ocluyó (*obstruir*) por exceso de humedad en los casos de mayor tiempo de duración llevando a perdidas de los datos y otras perdidas temporales de 40 a 400 milisegundos por errores en configuración del software.

**Figura 18**
*Diagrama de macroprocesos*

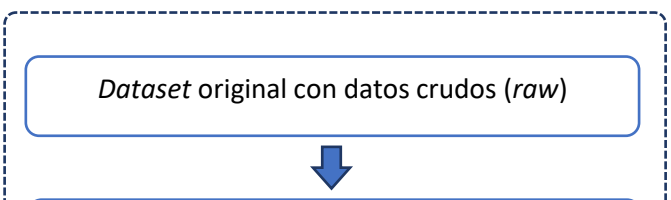

## 8.2 Preprocesamiento

Los datos brutos (*raw*), al no ser utilizables en su forma original, requerían un proceso previo de limpieza, mapeado y transformación. Para la consecución de esta tarea de manera automática se implementó una secuencia de comandos (script) de Python.

En este primer algoritmo se toma el dataset original con los datos de 32 (pacientes) casos registrados. Por cada caso existe un número de lecturas diferente que varía dependiendo de la duración en el monitoreo de cada paciente; registrando un archivo plano en formato **csv** (*comma separated values*) por cada 10 minutos de lectura continua. Así las cosas, el algoritmo lee jerárquicamente las lecturas de cada caso disponible, realiza un proceso de limpieza de datos nulos o vacíos, aplica filtros de selección de rangos de presión arterial, y genera archivos depurados limpios por cada

caso y paciente evaluado. Los datos resumen de este proceso se pueden apreciar en la Tabla 3.

Después de este primer pre-procesamiento de la base de datos original, se obtuvo un conjunto de registros de segmentos de lectura PPG de 10 segundos para un rango de 689 pares de presiones arteriales SBP - DBP para los distintos casos registrados en el *dataset*.

Con estos datos guardados en archivos planos con formato csv, se aplica un segundo algoritmo cuyo propósito es generar imágenes en blanco y negro por cada segmento de lectura PPG de 10 segundos. Es decir que por cada archivo **csv** se genera un archivo **jpg** con la imagen de la forma de onda de la señal PPG correspondiente a un valor de presión arterial dada (valores de presión sistólica *SBP* y diastólica *DBP*). Esta etapa de pre-procesamiento también es conocida como *Feature Engineering* o Ingeniería de Características y tiene como propósito enriquecer los datos para adaptarlos al tipo de técnica de aprendizaje profundo a utilizar mejorando de esta manera el rendimiento del modelo propuesto para la solución del problema.

**Tabla 3**

*Cantidad de datos según presión arterial*

| *Casos* | Total datos | Filtrados | Normal | Hipertensión | Hipotensión | Perdidos |
|---|---|---|---|---|---|---|
| *1* | 729600 | 690513 | 86314 | | 604199 | 39087 |
| *2* | 101376 | 69149 | | | 69149 | 32227 |
| *3* | 1498522 | 1280733 | 188690 | | 1092043 | 217789 |
| *4* | 876578 | 801804 | 445318 | 87069 | 269417 | 74774 |
| *5* | 600000 | 419556 | | 419556 | | 180444 |
| *6* | 632116 | 487194 | 96531 | 65278 | 325385 | 144922 |
| *7* | 322816 | 322816 | 31041 | | 291775 | 0 |
| *8* | 349389 | 323192 | 102938 | | 220254 | 26197 |
| *9* | 654832 | 602608 | 26139 | | 576469 | 52224 |
| *10* | 258487 | 241080 | 17812 | 33637 | 189631 | 17407 |
| *11* | 540660 | 503712 | 349427 | 34202 | 120083 | 36948 |
| *12* | 1771628 | 1653431 | 151541 | 100515 | 1401375 | 118197 |
| *13* | 594536 | 565089 | 136034 | 16779 | 412276 | 29447 |
| *14* | 533215 | 475493 | 177573 | 285353 | 12567 | 57722 |
| *15* | 158958 | 134924 | 62216 | | 72708 | 24034 |
| *16* | 1148642 | 976827 | | | 976827 | 171815 |
| *17* | 122266 | 107537 | 14666 | 16259 | 76612 | 14729 |
| *18* | 69427 | 61760 | | 17715 | 44045 | 7667 |
| *19* | 139674 | 123804 | 32604 | | 91200 | 15870 |
| *20* | 675123 | 605711 | 196470 | 18380 | 390861 | 69412 |
| *21* | 458547 | 346848 | 64787 | | 282061 | 111699 |
| *22* | 977954 | 891051 | 64308 | 776642 | 50101 | 86903 |
| *23* | 167733 | 160379 | 37434 | | 122945 | 7354 |
| *24* | 372308 | 354575 | | 57005 | 297570 | 17733 |
| *25* | 633856 | 521600 | 226083 | 94403 | 201114 | 112256 |
| *26* | 997822 | 858241 | 457631 | 31950 | 368660 | 139581 |
| *27* | 1538143 | 1000663 | 126148 | 37683 | 836832 | 537480 |
| *28* | 446111 | 413942 | 187561 | 34007 | 192374 | 32169 |
| *29* | 730761 | 675702 | 309465 | 34096 | 332141 | 55059 |
| *30* | 368272 | 316437 | 64278 | 46192 | 205967 | 51835 |
| *31* | 1264544 | 1237224 | 919194 | 55429 | 262601 | 27320 |
| *32* | 496022 | 451351 | 353047 | 65228 | 33076 | 44671 |

**Figura 19**

*Forma de onda típica PPG*

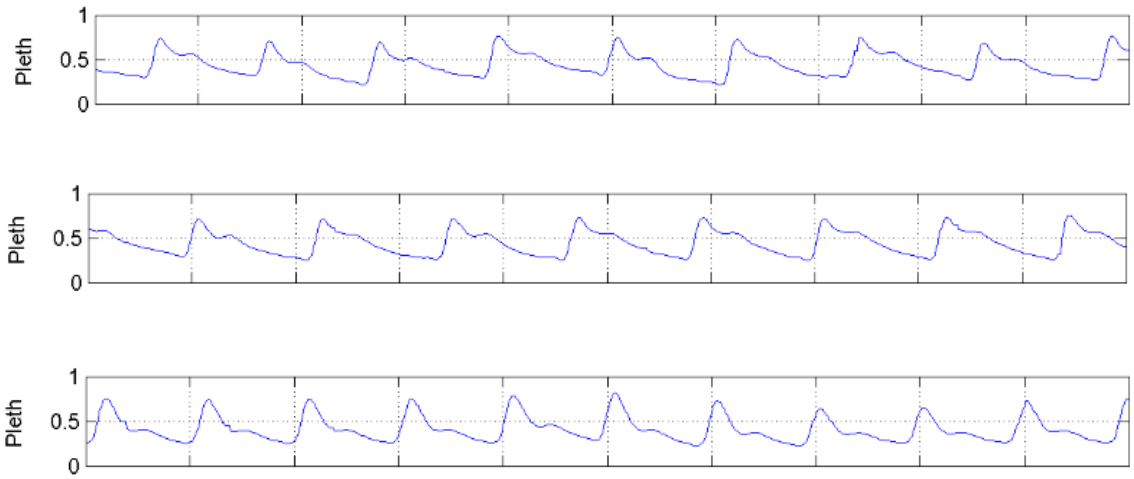


A continuación, se realiza una exhaustiva revisión visual (*uno a uno*) de todas las imágenes generadas para observar patrones o formas de onda atípicas de una señal PPG. Este conjunto de imágenes fuera de la forma de onda normal es retirado del dataset que se enviará a la fase de entrenamiento con el modelo de red neuronal convolucional propuesto para esta investigación. Finalmente fueron tomadas 5590 imágenes para la fase de entrenamiento y 500 imágenes para la fase de prueba.

**Figura 20**

*Forma de onda atípica*

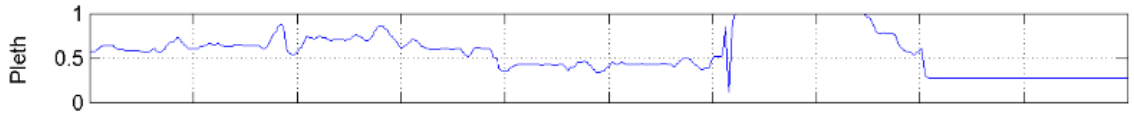


Así entonces, en la fase de preprocesamiento, se (1) validan los datos planos numéricos con valores correspondientes a las mediciones PPG, SBP, DBP continuas y sin procesar tomadas de 32 sujetos (*casos de pacientes*) eliminando posibles datos nulos (*NaN values*), para luego asignarlos aleatoriamente en segmentos de igual longitud (10s) sin aprovechar ninguna información de localización del pulso; (2) sobre estos datos se

aplican métodos de normalización y se generan igual número de imágenes correspondientes a la señal PPG tomando los datos numéricos de las distintas lecturas; (3) se examinan visualmente todas estas imágenes para descartar posibles patrones fuera del rasgo típico de una señal foptopletismográfica.

### 8.3 Procesamiento

En este punto, contamos entonces con un *dataset* de 5590 imágenes para el entrenamiento, lo suficientemente robusto para aplicar el modelamiento, análisis y entrenamiento con una red neuronal convolucional de 2 dimensiones. Se diseñó un 2D - CNN (*2 Dimension Convolutional Neural Network*) para aprender automáticamente las características intrínsecas de las imágenes producidas por los datos PPG, y realizar la predicción requerida. Es decir, se realizarán predicciones de los 2 valores de la presión arterial: diastólica (*DBP*) en (mmHg) y sistólica (*SBP*) en (mmHg) de acuerdo a los valores de entradao etiquetas que están en estas unidades, tomando como entrada una representación gráfica de la señal PPG obtenida de manera numérica con una lectura continua no invasiva de un paciente en un periodo de tiempo.

Dentro del Aprendizaje Profundo, han surgido una gran cantidad de arquitecturas y técnicas que pueden permitir numerosos casos de uso, siendo la principal de ellas las redes neuronales convolucionales. Las redes neuronales convolucionales se inspiraron en la investigación realizada en la corteza visual de los mamíferos y en cómo perciben el mundo utilizando una arquitectura de capas de neuronas en el cerebro. Imaginemos este modelo de corteza visual como grupos de neuronas diseñados específicamente para reconocer diferentes patrones, características y formas distintivas. Cada grupo de

neuronas se dispara al ver un objeto y se comunican entre sí para desarrollar una comprensión holística del objeto percibido.

El sistema puede explicarse como grupos jerárquicos de neuronas que detectan características de bajo nivel de un estímulo de entrada y se comunican entre sí en esa jerarquía para desarrollar una detección de alto nivel de los objetos.

En términos sencillos, dada la visión de un objeto, el sistema tiene diferentes grupos de neuronas que se disparan para diferentes aspectos del objeto y se comunican entre sí para formar la imagen global. Intuitivamente, las redes neuronales convolucionales toman imágenes como entrada e intentan descifrar diferentes características pequeñas (conexiones locales) sobre las imágenes, independientemente de su posición (invariabilidad espacial), utilizando una serie de operaciones matemáticas (estratificación, agrupación) con el fin de comprender la imagen completa de lo que está sucediendo. Estas operaciones matemáticas consisten en modelar una imagen como una serie de números en la que cada número representa la densidad de los píxeles.

En nuestro caso el objeto a percibir y analizar es la imagen correspondiente a la forma de onda de una señal PPG, para luego asociarla a un par de valores SBP y DBP por regresión lineal.

**Figura 21**

*Altura, ancho y profundidad de la imagen y el filtro*

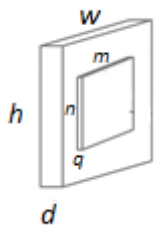


En nuestro modelo de una CNN para entrenamiento, utilizando Inteligencia Artificial, recibe entradas de dimensiones ***h*** × ***w*** × ***d***, donde ***h*** es la altura de la matriz de entrada, ***w*** es el ancho de la matriz de entrada y ***d*** es el número de canales diferentes de la matriz de entrada. En nuestro estudio, ***d*** es 3, ya que las matrices de entrada de corte temporal tienen tres canales (correspondiente a la representación de colores *RGB: Red Green Blue*).

Se utiliza un filtro local (*núcleo*) con un tamaño de ***n*** × ***m*** × ***q*** para extraer patrones de características satisfactorio y capturar las dependencias locales de la entrada dada. Aquí, ***n*** es la altura del número del filtro, ***m*** es el ancho del filtro, mientras que ***q*** es el número de filtros utilizados. Estos valores se dan como un parámetro durante el proceso de construcción de la red. El peso de estos filtros se inicializa al azar al principio y luego la *CNN* aprende estos pesos por su cuenta durante el proceso de formación mediante la optimización de los valores. En este estudio, la inicialización uniforme aleatoria se utiliza para inicializar los filtros y el descenso del gradiente estocástico es utilizado para optimizar los valores durante el entrenamiento.

La Unidad Lineal Rectificada (*ReLU*) se utiliza como función de activación. Luego se añade una capa de máxima acumulación, que es seguida por una capa totalmente conectada a la red.

Las *CNN* pueden contener uno o más pares convolucionales y de máximo intercambio de capas, donde las capas más altas usan filtros más amplios para procesar partes más complejas de la entrada. Las capas superiores de las *CNN* están apiladas por uno o más redes neuronales normales. Se espera que estas redes neuronales totalmente conectadas combinan diferentes estructuras locales en capas inferiores para su clasificación final.

En la etapa de entrenamiento, los parámetros de la *CNN* se estiman por medio de la norma de avance y algoritmos de propagación hacia atrás para minimizar la función del objetivo.

La estrategia implementada en este proyecto fue la de modificar la arquitectura de nuestra *CNN* aumentando el número de capas, además de los hiperparámetros de entrenamiento (tasa de aprendizaje inicial y umbral de gradiente) que varían para investigar su afectación en el rendimiento global de la red. A continuación, el modelo de red propuesto se somete a ciclos completos de entrenamiento y validación con los datos obtenidos en la fase de preprocesamiento; para finalmente aplicar predicciones de prueba.

Como hemos argumentado anteriormente la red neuronal convolucional es un análogo de la inteligencia artificial tradicional porque está formada por neuronas que se auto optimizan a través de aprendizaje. (Géron, n.d.)

### 8.3.1 Redes Neuronales Convolucionales

Las Redes Neuronales Convolucionales (CNN) son una clase de Red Neuronal que ha probado ser muy efectivas en técnicas de Aprendizaje Profundo en Inteligencia Artificial para el reconocimiento de imágenes y su clasificación. En nuestro estudio de

investigación se modificará la arquitectura típica de capas de un modelo CNN que es utilizado para clasificar imágenes; para ello se cambia la última capa del modelo por una regresión lineal que realizará la predicción de 2 valores continuos: SBP y DBP.

Esto se logrará mediante una regresión lineal multivariada donde se considera más de una variable dependiente o resultado aplicándose una red neuronal con más de una neurona de entrada y de salida

La ecuación funcional será expresada como $Y_j = w_i x_i + b$. Donde Y representa la variable dependiente, $x_i$ la variable independiente, b el sesgo de la capa de salida y $w_i$ son los pesos de las entradas i para las salidas j

### 8.3.2 Arquitecturas redes neuronales convolucionales

Actualmente existen muchas arquitecturas de redes neuronales convolucionales como *Alexnet*, *ZFnet*, *GoogleNet* y *VGG Net*. Se escoge la arquitectura de red neuronal convolucional basada en *VGG Net* debido a que es una de las que ofrece mejores resultados en los diferentes estudios que se analizaron para el desarrollo de nuestra investigación. (Liu et al., 2020)

### *8.3.1.1 Red Neuronal Convolucional Propuesta.*

**Figura 22**

*Arquitectura Propuesta*

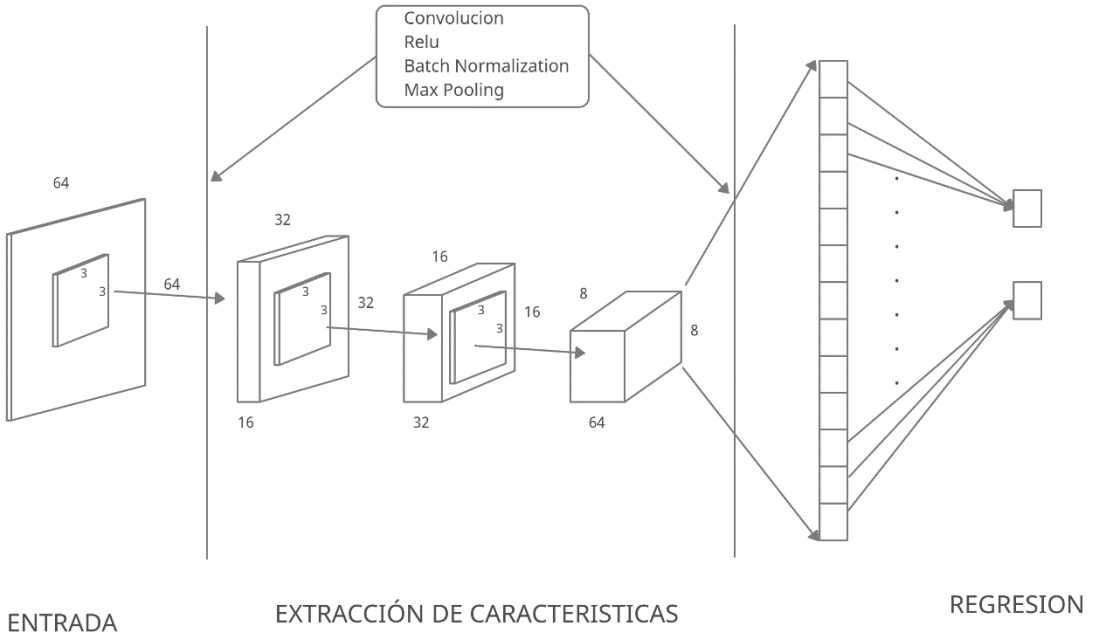


Nota. *Arquitectura red neuronal convolucional propuesta en la cual se aplican tres capas convolucionales con filtros de 16,32 y 64*

Para nuestro problema de regresión, nuestra red neuronal convolucional toma como entrada una imagen de 64x64 pixeles. Donde nuestro primer filtro aplicado con dimensiones de 3x3 tendrán un desplazamiento o Stride de uno sobre nuestras imágenes a lo largo del eje X y el eje Y, realizando la operación de convolución obteniendo un producto escalar formando una matriz de resultados o mapa de características de esa imagen de entrada con una profundidad (Depth) de 16 y dimensiones de 16x16 luego de aplicar un Maxpooling con filtros de 2x2. Seguido de una función no lineal de activación (Relu) la cual ofrece un mejor rendimiento sobre otras funciones de activación.

A esta matriz de 16x16 se le aplicara nuevamente un filtro de 3x3 realizarán la operación de convolución (Conv) dos veces más con profundidades de 32 y 64, llegando a una matriz que fue reducida por el proceso de maxpooling de 8x8 pixeles. De estas operaciones en cada uno de los filtros se puede encontrar diferentes características como bordes, desenfoques, nitidez que serán obtenidas y aprendidas en el aprendizaje por si mismas en el entrenamiento.

Se aplica en cada una de las tres convoluciones como se muestra en la figura una capa de Batch Normalization (BN) que nos ayudara a coordinar la actualización de los pesos a través de muchas capas, se reducirá el número de parámetros utilizando pooling layer (Pool), que en nuestra arquitectura utilizamos el que toma el valor máximo tomando las características más importantes de la matriz de entrada al dividirla en segmentos del mismo tamaño.

Una vez terminado este proceso se aplica un aplanamiento es decir nuestra matriz la convertimos en un vector y la aplicamos a una capa Full conected (FC) y finalmente nos dará unos parámetros de salida que lo aplicaremos a dos neuronas que serán nuestras salidas de regresión que nos mostrarán la presión diastólica y sistólica obtenida con el modelo.

#### *8.3.1.2 Conceptos aplicados a nuestra arquitectura.*

- Filtros: Es uno de los primeros parámetros requeridos cuyo propósito es indicar al modelo el número especifico de filtros (*kernels*) que se aplicará en cada capa convolucional para que esta aprenda.
- *Kernel size*: Parámetro que proporciona el tamaño del núcleo. Consta de una tupla de 2 valores que especifica la altura (*width*) y el ancho (*height*) de la ventana de

convolución. La red CNN-2D *VGG Net* utiliza exclusivamente un *kernel size* de (3,3) a traves de toda la red.

- Activación: parámetro de conveniencia que le permite suministrar una cadena que es especifica de la función que se desea aplicar después de realizar la convolución.
- *Dropout*: parámetro que ayuda a la red a obtener una mejor generalización y no sobrepase los datos de entrenamiento.
- *Batch Normalization*: una técnica para ayudar a coordinar la actualización de múltiples capas en el modelo, proporcionando una forma de reparametrizar cualquier red profunda reduciendo el problema de actualizaciones de pesos a través de muchas capas.
- Optimizador: Manera de encontrar el conjunto óptimo de parámetros para el modelo.
- Tasa de Aprendizaje (*Learning Rate*): Define el tamaño del paso para el cual se actualizan los pesos de un modelo con respecto al descenso del gradiente estocástico.
- Épocas (*Epochs*): Mide cuantas veces se ha visto cada imagen durante el entrenamiento.

### 8.4 Lenguaje de programación y *framework* de desarrollo

Para el desarrollo de este proyecto, se utilizó el lenguaje de programación Python (2.4.0), es de código abierto y nos permite crear aplicaciones e involucrarnos en su desarrollo.

Python cuenta con el framework *Keras* el cual es una biblioteca de Red Neural de código abierto escrita en Python que funciona sobre *Tensorflow* (2.0.0). Está diseñada para ser modular, rápida y fácil de usar. Fue desarrollada por François Chollet, un ingeniero de Google.

*Keras* no maneja computación de bajo nivel. En su lugar, utiliza otra biblioteca para hacerlo, llamada "*Backend*". Así que *Keras* es un envoltorio de definiciones y protocolos que se utilizan para desarrollar e integrar productos y servicios que se comuniquen unos con otros brindando simplicidad, ahorrando tiempo y dinero conocido como API (*application programming interface*).
Estas API de alto nivel envuelven las API de bajo nivel, capaces de funcionar sobre *TensorFlow*.

### 8.5 Métricas

Al considerar el contexto del problema de investigación, objeto de este estudio, entendemos que se deben escoger métricas que permitan evaluar el rendimiento del modelo propuesto. Para ello se debe considerar que se trata de un problema de regresión (*estimar la presión arterial de manera continua y no invasiva tomando una medición PPG como dato de entrada*), que existe una relación de dependencia entre los valores *PPG* y las variables de presión arterial *BP: SBP y DBP*. Así entonces se consideran las métricas MAE y R2 para evaluar el rendimiento del modelo.

- **MAE** (*Mean Absolute Error* - Error Absoluto Medio)

  Esta métrica de error calcula el promedio de diferencias absolutas entre los valores objetivo (*reales*) y los valores estimados en la regresión (*predicciones*). (Ciurlizza &

Castaneda, 1986). El MAE es una puntuación lineal, lo que significa que todas las diferencias individuales se ponderan por igual en el promedio.

La predicción y el valor verdadero utilizan la misma escala en que se miden los datos y se observa como una medida de precisión entre estos dos valores. Por ejemplo, si el MAE es 5, en promedio, la precisión está errada en un 5%.

- **$R^2$** (R al cuadrado)

  La métrica Coeficiente de Determinación $R^2$, permite evaluar un modelo y está estrechamente relacionada con la **MSE** (Error cuadrático Medio). Tiene la ventaja de estar libre de escala, no importa si los valores de salida son muy grandes o pequeños, el $R^2$ siempre estará entre $-\infty$ y 1. (Ciurlizza & Castaneda, 1986)

  Al tener una métrica entre $-\infty$ y 1; los valores negativos hasta 0, indicarían que el modelo no explica ninguna porción de la variabilidad de los datos de respuesta en torno a su media; en cambio, si el error se aproxima a 1 indica que el modelo explica toda la variabilidad de los datos de respuesta en torno a su media.

### 8.6 Resultados

Tomando como referencia la arquitectura *VGGNet* para una Red Neuronal Convolucional, se implementan 3 modelos que difieren en el número de capas convolucionales, el número de filtros (*kernels*) a aplicar, y la tasa de aprendizaje (l*earning rate*) como hiper-parámetro en la etapa de entrenamiento del modelo.

**Modelo 2D-CNN número 1**

Red Neuronal Convolucional basada en arquitectura *VGGNet*, 3 capas convolucionales con filtros de 16, 32 y 64 *kernels* respectivamente. Este modelo 2D-CNN 1 se entrena sobre 3 tasas de aprendizaje distintas de: 0,1 / 0,01 / 0,001

**Figura 23**
*Resultados de la primera arquitectura de red propuesta aplicando tres tasas de aprendizaje, con el dataset de entrenamiento*

| CNN1 |
|---|
| Entrada |
| Convolucion (3x3x16) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x32) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x64) |
| Batch Normalization |
| Max poling (2x2) |
| Fully connected |
| Batch normalizarion |
| Dropout |

| LR:1e-1 | CNN1 | SBP | DBP |
|---|---|---|---|
| | MAE | 19,1 | 115,3 |
| | R2 | -563 | -244 |

| LR:1e-2 | CNN1 | SBP | DBP |
|---|---|---|---|
| | MAE | 9,3 | 14,25 |
| | R2 | 0,3 | 0,49 |

| LR:1e-3 | CNN1 | SBP | DBP |
|---|---|---|---|
| | MAE | 10,66 | 14,55 |
| | R2 | 0,05 | 0,37 |

El *MAE* (Error Absoluto Medio) de este primer modelo (2D-CNN1) nos muestra un valor significativamente alto al iniciar con una *LR* (Tasa de Aprendizaje) estándar. Esta métrica indica una diferencia importante entre el valor real (objetivo) y el valor predicho, que baja un poco cuando se disminuye la tasa de aprendizaje (*LR*). El valor de $R^2$ o coeficiente de determinación nos muestra, con valores negativos altos, que no existe un ajuste de nuestro modelo entre la variable dependiente e independiente a una *LR* estándar y al igual que la métrica *MAE* mejora con la disminución de esta tasa de aprendizaje.

**Modelo 2D-CNN número 2**

Red Neuronal Convolucional basada en arquitectura VGGNet, 4 capas convolucionales con filtros de 16, 32, 64 y 128 *kernels* respectivamente. Este modelo 2D-CNN 2 se entrena sobre 3 tasas de aprendizaje distintas de: 0,1 / 0,01 / 0,001

**Figura 24**

*Resultados de la segunda arquitectura de red propuesta aplicando tres tasas de aprendizaje, con el dataset de entrenamiento*

| CNN2 |
|---|
| Entrada |
| Convolucion (3x3x16) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x32) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x64) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x128) |
| Batch Normalization |
| Max poling (2x2) |
| Fully connected |
| Batch normalizarion |
| Dropout |

| LR:1e-1 | CNN2 | SBP | DBP |
|---|---|---|---|
| | MAE | 8,98 | 13,9 |
| | R2 | 0,30 | 0,54 |
| | | | |
| LR:1e-2 | CNN2 | SBP | DBP |
| | MAE | 9,27 | 13,6 |
| | R2 | 0,19 | 0,4 |
| | | | |
| LR:1e-3 | CNN2 | SBP | DBP |
| | MAE | 9,46 | 12,11 |
| | R2 | 0,34 | 0,59 |

En este segundo modelo (2D-CNN2) se evidencia una mejora sustancial en los valores de las métricas al entrenar dicho modelo sobre las 3 tasas de entrenamiento (*LR*) propuestas. El *MAE* obtenido en los 3 escenarios de *LR* muestra un valor promedio de 9 puntos entre los valores reales (objetivos) y los predichos en la estimación de la variable de presión sistólica (SBP); y muestra un valor promedio de 13 puntos entre los valores reales (objetivos) y los predichos en la estimación de la variable de presión diastólica (DBP). El coeficiente de determinación $R^2$ muestra valores que indican una ajuste considerable entre el modelo propuesto 2D-CNN1 y el 2D-CNN2.

**Modelo 2D-CNN número 3**

Red Neuronal Convolucional basada en arquitectura VGGNet, 5 capas convolucionales con filtros de 16, 32, 64, 128 y 256 *kernels* respectivamente. Este modelo 2D-CNN 3 se entrena sobre 3 tasas de aprendizaje distintas de: 0,1 / 0,01 / 0,001

**Figura 25**

*Resultados de la tercera arquitectura de red propuesta aplicando tres tasas de aprendizaje, con el dataset de entrenamiento*

| CNN3 |
|---|
| Entrada |
| Convolucion (3x3x16) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x32) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x64) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x128) |
| Batch Normalization |
| Max poling (2x2) |
| Convolucion (3x3x256) |
| Batch Normalization |
| Max poling (2x2) |
| Fully connected |
| Batch normalizarion |
| Dropout |

| LR:1e-1 | CNN3 | SBP | DBP |
|---|---|---|---|
| | MAE | 9,79 | 12,38 |
| | R2 | 0,34 | 0,59 |
| | | | |
| LR:1e-2 | CNN3 | SBP | DBP |
| | MAE | 8,82 | 12,41 |
| | R2 | 0,36 | 0,54 |
| | | | |
| LR:1e-3 | CNN3 | SBP | DBP |
| | MAE | 8,31 | 12,63 |
| | R2 | 0,34 | 0,56 |

Para nuestro tercer modelo (2D-CNN3) se obtuvieron valores de la métrica *MAE* con diferencias absolutas de 8 puntos entre el valor objetivo y el predicho para la variable de presión sistólica (SBP); y valores de *MAE* con diferencias absolutas de 12 puntos entre el valor objetivo y el predicho para la variable de presión diastólica (DBP). La diferencia de resultados obtenidos en el *MAE* entre los 3 modelos aplicados indica que es posible mejorar esta métrica.

Respecto al coeficiente de determinación $R^2$, el tercer modelo (2D-CNN3) muestra una mejora con valores positivos todos mayores a 0,3 indicando una variabilidad superior entre las variables dependientes e independientes y un mejor ajuste del comportamiento de este último modelo.

Sobre los modelos 2D-CNN1, 2D-CNN2 y 2D-CNN3 se realiza un ciclo de predicciones con 500 muestras – no utilizadas en los ciclos de entrenamiento previos - para validar cómo se comporta cada modelo. El modelo que obtuvo los mejores resultados fue el modelo 2D-CNN3 con una tasa de aprendizaje (*Learning Rate*) de 0,001. El modelo **2D-CNN3 *LR* 1e$^{-3}$** logró métricas *MAE* de 8,31 para predecir la presión sistólica y de 12,63 para predecir la presión diastólica; y coeficientes de determinación $R^2$ de 0,34 y de 0,56 para la predicción diastólica y sistólica respectivamente.

**Figura 26**
*Métricas obtenidas con 500 muestras no empleadas en el entrenamiento*

| | |
|---|---|
| MAE_SBP | 17.60 |
| MAE_DBP | 11.51 |
| R2_SBP | 0.79 |
| R2_DBP | 0.93 |

Resultados obtenidos con el modelo 2D-CNN3, con *lr*: 0,001 y 500 muestras de prueba

La Figura anterior muestra los resultados obtenidos al aplicar el modelo **2D-CNN3 *LR* 1e$^{-3}$** sobre un conjunto de 500 muestras origen, no empleadas durante la fase de entrenamiento. En este ejercicio se obtienen métricas *MAE* de 17,62 y 11,51 puntos para la estimación correcta de la presión sistólica y diastólica respectivamente. De igual manera logra valores de coeficiente de determinación $R^2$ cercanos a 1 de 0,79 y 0,93 para la estimación de los 2 valores que hacen parte de la presión sanguínea.

## 9. Conclusiones

La evaluación de los distintos modelos aplicados para resolver el problema de predicción de la presión sistólica y diastólica a partir de señales fotopletismográficas, nos permite determinar que la utilización de una red neuronal convolucional de dos dimensiones con un enfoque de aprendizaje automático supervisado basado en inteligencia artificial es un método valido para abordar la solución de este tipo de problemas.

En la implementación del algoritmo para la definición de los distintos modelos, se estableció que existe una relación funcional entre la representación gráfica (imagen con forma de onda) de una serie de valores numéricos de lecturas PPG y los valores de presión arterial sistólica (SBP) y diastólica (DBP). Los 3 modelos de red 2D-CNN evaluados muestran en la métrica $R^2$ valores positivos entre 0 y 1, lo que significa que existe un ajuste con mínimos errores entre los valores observados (reales) y los valores predichos.

Esta investigación desarrolla un estudio, por medio del cual se observa que es posible la medición de la presión arterial de manera continua y no invasiva en condiciones favorables para la salud del paciente y útiles para la interpretación diagnóstica.

### 9.1 Alcances y limitaciones

Una de las limitaciones que hemos observado y podría ayudar a mejorar el error en la predicción de la presión arterial son los dataset disponibles. El modelo tiene el potencial de predecir con porcentajes de error mucho más pequeños, pero deberíamos tener

acceso a otros datasets que enriquezcan mucho más y poder extraer muchas más características.

### 9.2 Recomendaciones y trabajos futuros

Se podría ampliar esta investigación recogiendo más señales PPG en las unidades de cuidados intensivos con sus respectivas presiones arteriales, lo que nos proporcionaría más datos y más variedad dentro de los datos recogidos de BP. Una vez que hayamos recogido suficientes datos, mejorar la parte de aprendizaje profundo de nuestro modelo utilizando hardware más robusto y con las GPU necesarias para poder utilizar más capas. Estos algoritmos son muy adecuados para los problemas relacionados con el análisis de señales y representan el enfoque más avanzado en el procesamiento de señales en los últimos años, lo que los convierte en un candidato adecuado para este tipo de problemas.

**Referencias Bibliográficas**


Allen, J. (2007). Photoplethysmography and its application in clinical physiological measurement. *Physiological Measurement*, *28*(3). https://doi.org/10.1088/0967-3334/28/3/R01

Arangure, L. (2013). Actualización , implementación y evaluación de guía de manejo de inserción de línea arterial para enfermeras, con la utilización de dispositivo trayecto largo, bajo monitorización ecográfica en la unidad de cuidado intensivo médico de la fundación cardio . *Tesis*, 103. http://intellectum.unisabana.edu.co:8080/jspui/bitstream/10818/10409/1/Lina María Arangure Burgos(TESIS).pdf

Bedford, R. F., & Wollman, H. (1973). Complications of percutaneous radial-artery cannulation: an objective prospective study in man. In *Anesthesiology* (Vol. 38, Issue 3, pp. 228–236). https://doi.org/10.1097/00000542-197303000-00006

Blasco, S., Blasco, N., Blasco, B., Recuenco, N., Aranda, T., & Carralero, R. (2011). Estudio comparativo de la presión arterial invasiva frente a la presión arterial no invasiva . Valoración de la diferencia . Comparative study of invasive blood pressure versus non-invasive blood pressure. *Enfermeria Global*, *24*(December 2008), 85–93.

Dehghanojamahalleh, S., & Kaya, M. (2019). Sex-Related Differences in Photoplethysmography Signals Measured from Finger and Toe. *IEEE Journal of Translational Engineering in Health and Medicine*, *7*(September). https://doi.org/10.1109/JTEHM.2019.2938506

Gaurav, A., Maheedhar, M., Tiwari, V. N., & Narayanan, R. (2016). Cuff-less PPG based continuous blood pressure monitoring - A smartphone based approach. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2016-Octob*(August), 607–610. https://doi.org/10.1109/EMBC.2016.7590775

Geddes LA. (1991). *Handbook of blood pressure measurement*.

Géron, A. (n.d.). *Hands-On Machine Learning with Scikit-Learn and TensorFlow*. O'Reilly Media.

Gupta, B. (n.d.). *Monitoring in the ICU Anaesthesia Update in*. 37–42.

Hebal, F., Sparks, H. T., Rychlik, K. L., Bone, M., Tran, S., & Barsness, K. A. (2018). Pediatric arterial catheters : Complications and associated risk factors. *Journal of Pediatric Surgery*, *53*(4), 794–797. https://doi.org/10.1016/j.jpedsurg.2017.08.057

Hermida Amejeiras, D. A., Enrique Lopez Paz, D. J., & Calvo Gómez, D. C. (2012). Medida no invasiva de la presión arterial central mediante tonometría por aplanamiento. Análisis de la onda de pulso. *Galicia Clínica*, *73*(4), 161. https://doi.org/10.22546/21/389

Hernández Gárciga, F. F., & González Chacón, Y. (2015). Presión del pulso y su relación con el riesgo cardiovascular incrementado. *Revista Cubana de Investigaciones Biomedicas*, *34*(3), 245–253.

Hu, S., Azorin-Peris, V., & Zheng, J. (2013). Opto-physiological modeling applied to photoplethysmographic cardiovascular assessment. *Journal of Healthcare Engineering*, *4*(4), 505–528. https://doi.org/10.1260/2040-2295.4.4.505

Hussain, S., Gaftandzhieva, S., Maniruzzaman, M., Doneva, R., & Muhsin, Z. F.

(2020). Regression analysis of student academic performance using deep learning. *Education and Information Technologies*. https://doi.org/10.1007/s10639-020-10241-0

Island, M. (1993). *Mejdsla*. *19*.

Kaur, B., Kaur, S., Yaddanapudi, L. N., & Singh, N. V. (2019). Comparison between invasive and noninvasive blood pressure measurements in critically ill patients receiving inotropes. *Blood Pressure Monitoring*, *24*(1), 24–29. https://doi.org/10.1097/MBP.0000000000000358

Khalid, S. G., Zhang, J., Chen, F., & Zheng, D. (2018). Blood Pressure Estimation Using Photoplethysmography Only : Comparison between Different Machine Learning Approaches. *Healthcare Engineering*, *2018*.

Kurylyak, Y., Barbe, K., Lamonaca, F., Grimaldi, D., & Van Moer, W. (2013). Photoplethysmogram-based Blood pressure evaluation using Kalman filtering and Neural Networks. *MeMeA 2013 - IEEE International Symposium on Medical Measurements and Applications, Proceedings*, *May 2014*, 170–174. https://doi.org/10.1109/MeMeA.2013.6549729

Labrosse, M. R. (2018). *Cardiovascular Mechanics* (CRC Press).

Lakhal, K., Ehrmann, S., & Boulain, T. (2018). Noninvasive BP Monitoring in the Critically Ill: Time to Abandon the Arterial Catheter? *Chest*, *153*(4), 1023–1039. https://doi.org/10.1016/j.chest.2017.10.030

Lakhal, K., Martin, M., Ehrmann, S., Faiz, S., Rozec, B., & Boulain, T. (2018). Non-invasive blood pressure monitoring with an oscillometric brachial cuff: impact of arrhythmia. *Journal of Clinical Monitoring and Computing*, *32*(4), 707–715.

https://doi.org/10.1007/s10877-017-0067-2

Lehman, L. H., Saeed, M., Gad, A., Colleges, I., Health, F., Talmor, D., Israel, B., Medical, D., Malhotra, A., & Diego, S. (2013). *Methods of Blood Pressure Measurement in the ICU. January 2018*. https://doi.org/10.1097/CCM.0b013e318265ea46

Liévano Martínez, F., & Londoño, J. E. (2012). El pensamiento sistémico como herramienta metodológica para la resolución de problemas. *Revista Soluciones de Postgrado EIA*, *8*, 43–65.

Liu D, Gorges M, Jenkins, S. (2012). The University of Queensland Vital Signs Dataset: Development of an Accessible Repository of Anesthesia Patient Monitoring Data for ResearchNo Title. *Anesth Analg*, 584–589. https://doi.org/doi:10.1213/ANE.0b013e318241f7c0

Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., & Pietikäinen, M. (2020). Deep Learning for Generic Object Detection: A Survey. *International Journal of Computer Vision*, *128*(2), 261–318. https://doi.org/10.1007/s11263-019-01247-4

Martínez, G., Howard, N., Abbott, D., Lim, K., & Ward, R. (2018). Can Photoplethysmography Replace Arterial Blood Pressure in the Assessment of Blood Pressure ? *Clinical Medicine*, *Cvd*, 1–13. https://doi.org/10.3390/jcm7100316

Méndez, P., & Ibarra, J. (2014). Implementación de una red neuronal de convolución para el reconocimiento de poses en imágenes de rostros. *ACI Avances En Ciencias e Ingenierías*, *6*(2), 1–6. https://doi.org/10.18272/aci.v6i2.167

Mendoza, K. C. (2012). Radial artery catheterism for invasive monitoring: Preventing

complications, a challenge in anesthesia. *Revista Colombiana de Anestesiologia*, *40*(4), 262–265. https://doi.org/10.1016/j.rca.2012.05.014

Mousavi, S. S., Firouzmand, M., Charmi, M., Hemmati, M., Moghadam, M., & Ghorbani, Y. (2019). Blood pressure estimation from appropriate and inappropriate PPG signals using A whole-based method. *Biomedical Signal Processing and Control*, *47*, 196–206. https://doi.org/10.1016/j.bspc.2018.08.022

Penáz, J. (1992). Criteria for set point estimation in the volume clamp method of blood pressure measurement. *Physiological Research / Academia Scientiarum Bohemoslovaca*, *41*(1), 5–10.

Perloff, D., Grim, C., Flack, J., & Frohlich, E. D. (2012). AHA Medical / Scientific Statement Human Blood Pressure Determination by Sphygmomanometry. *Library*, 2460–2470. https://doi.org/10.1161/01.CIR.88.5.2460

Peterson, L. H., Dripps, R. D., & Risman, G. C. (1949). A method for recording the arterial pressure pulse and blood pressure in man. *American Heart Journal*, *37*(5), 771–782. https://doi.org/10.1016/0002-8703(49)90175-1

Ray, S., Rogers, L., Noren, D. P., Dhar, R., Nadel, S., Peters, M. J., & Inwald, D. P. (2017). Risk of over-diagnosis of hypotension in children: a comparative analysis of over 50,000 blood pressure measurements. *Intensive Care Medicine*, *43*(10), 1540–1541. https://doi.org/10.1007/s00134-017-4843-8

Rostami, G., Hamid, M., & Jalaeikhoo, H. (2017). Impact of the BCR-ABL1 fusion transcripts on different responses to Imatinib and disease recurrence in Iranian patients with Chronic Myeloid Leukemia. *Gene*, *627*(1), 202–206. https://doi.org/10.1016/j.gene.2017.06.018

Sato, T., Nishinaga, M., Kawamoto, A., Ozawa, T., & Takatsuji, H. (1993). Accuracy of a continuous blood pressure monitor based on arterial tonometry. *Hypertension*, *21*(6 I), 866–874. https://doi.org/10.1161/01.hyp.21.6.866

Scheer, B. V., Perel, A., & Pfeiffer, U. J. (2002). Clinical review: Complications and risk factors of peripheral arterial catheters used for haemodynamic monitoring in anaesthesia and intensive care medicine. *Critical Care*, *6*(3), 198–204. https://doi.org/10.1186/cc1489

Suárez, O. V. (2017). Revista Cubana de medicina intensiva y emergencias. *Revista Cubana de Medicina Intensiva y Emergencias*, *17*(1), 99–106. http://www.revmie.sld.cu/index.php/mie/article/view/408/pdf_82

Yoo, S.-Y. (2019). *Reliability and Validity of Non-invasive Blood*.