

UNIVERSIDADE FEDERAL DO AMAZONAS
INSTITUTO DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

ESTIMATIVA DOS PONTOS DE SÍSTOLE E DIÁSTOLE PARA IDENTIFICAÇÃO DE
HIPERTENSÃO A PARTIR DE SINAIS DE FOTOPLETISMOGRAFIA

Manaus-AM

Agosto de 2022

HYGO SOUSA DE OLIVEIRA

ESTIMATIVA DOS PONTOS DE SÍSTOLE E DIÁSTOLE PARA IDENTIFICAÇÃO DE
HIPERTENSÃO A PARTIR DE SINAIS DE FOTOPLETISMOGRAFIA

Dissertação apresentada ao Programa de Pós-Graduação em Informática do Instituto de Computação da Universidade Federal do Amazonas como requisito para a obtenção do grau de Mestre em informática.

ORIENTADOR: PROF. DR. EDUARDO JAMES PEREIRA SOUTO

Manaus-AM

Agosto de 2022

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Oliveira, Hygo Sousa De
O48e Estimativa dos pontos de sístole e diástole para identificação de hipertensão a partir de sinais de fotopletismografia / Hygo Sousa De Oliveira . 2022
65 f.: il. color; 31 cm.

Orientador: Eduardo James Pereira Souto
Dissertação (Mestrado em Informática) - Universidade Federal do Amazonas.

1. Fotopletismografia. 2. Pressão Sanguínea Arterial. 3. Hipertensão. 4. Convolução Dilatada. 5. Monitoramento Contínuo. I. Souto, Eduardo James Pereira. II. Universidade Federal do Amazonas III. Título



PODER EXECUTIVO
MINISTÉRIO DA EDUCAÇÃO
INSTITUTO DE COMPUTAÇÃO



UFAM

PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

FOLHA DE APROVAÇÃO

"ESTIMATIVA DOS PONTOS DE SÍSTOLE E DIÁSTOLE PARA IDENTIFICAÇÃO DE HIPERTENSÃO A PARTIR DE SINAIS DE FOTOPLETISMOGRAFIA"

HYGO SOUSA DE OLIVEIRA

Dissertação de Mestrado defendida e aprovada pela banca examinadora constituída pelos Professores:

Prof. Eduardo James Pereira Souto - PRESIDENTE

Prof. Rafael Giusti - MEMBRO INTERNO

Prof. Moisés Gomes de Carvalho - MEMBRO EXTERNO

Manaus, 22 de Agosto de 2022

Agradecimentos

Ao lembrar a jornada que trilhei para chegar a este momento sinto-me agradecido ao Senhor pelos obstáculos superados, bem como as aflições e experiências que forjaram meu caráter.

Sou grato aos meus pais, José Alves de Oliveira e Cleidianes Vieira Sousa, tal como meus irmãos, Gabriel e Maryana, pois o amor fraternal que compartilhamos permitiu que eu mantivesse meus pés no chão enquanto perseguia meus sonhos. Serei eternamente grato a segunda mãe que a vida me deu, minha sogra Marinalva Santos de Oliveira, por todo seu amor, acolhimento e encorajamento que recebi.

Gostaria de agradecer a pessoa que está sempre ao meu lado, enfrentando comigo todos os intemperes da vida, minha amada esposa Marina Oliveira, nossa comunhão, cumplicidade e temor a Deus é o pilar que nos mantém fortes e unidos.

Não poderia esquecer meu amigo e irmão Rafael Albuquerque, que por mais de uma década trilhou comigo essa incrível jornada acadêmica cheia de altos e baixos.

Sou grato ao meu professor Orientador Eduardo James Souto, por ter sido um verdadeiro tutor durante todo o percurso da minha pós-graduação, acreditando no meu potencial e por muitas vezes ter segurado minha mão durante os percalços da pesquisa, me encorajando a seguir em frente.

Gostaria de agradecer ao meu amigo de laboratório Paulo Nellesen, um acadêmico extraordinário que nunca me abandonou nos momentos turbulentos da pesquisa, demonstrando além de um admirável intelecto, um grande coração. As pessoas que tive a oportunidade de me aproximar por meio de projetos, cursar disciplinas e que enriqueceram meus conhecimentos, em especial Kevin Quispe, Hendrio Bragança, Igor Carneiro, Leonardo e Ronem Lavareda.

Agradeço a CAPES pelo suporte financeiro essencial, à UFAM pelo por proporcionar um ambiente bem equipado para o desenvolvimento desta pesquisa e a todos os professores que contribuíram para minha formação acadêmica.

Resumo

As doenças cardiovasculares têm sido uma das principais causas de mortalidade e comorbidade dos últimos anos. O principal fator de risco para o desenvolvimento de doenças cardiovasculares é a hipertensão, caracterizada pela elevação da pressão sanguínea arterial (ABP – *Arterial Blood Pressure*), definida pelos movimentos cardíacos sistólico e diastólico. O seu diagnóstico pode ser obtido por meio de monitoramento contínuo, o qual está relacionado a métodos invasivos e não invasivos. A maneira mais precisa (padrão ouro) para se obter a ABP advém da técnica de canulação, uma forma incômoda e invasiva, submetendo o indivíduo a uma perfuração arterial. Em contrapartida, a pressão sanguínea pode ser obtida pela técnica não invasiva de Fotopletismografia (PPG – *Photoplethysmography*). Esse sinal é obtido pelo processo de reflexão ou refração da luz, com a vantagem de permitir o monitoramento contínuo da pressão sanguínea fora de ambiente hospitalar e ser implementado em dispositivos vestíveis de baixo custo. Embora exista correlação nas formas de onda entre os sinais PPG e ABP, ambos se diferenciam pelos seus valores de escala, proporcionando uma relação não linear desses sinais. No entanto, essa correlação permite que, a partir do sinal PPG seja possível realizar a estimativa da pressão sanguínea por meio de algoritmos que encontrem correlações não lineares entre esses dois sinais. O método proposto, denominado Modelo Neural da Pressão Sanguínea (MoNePS), tem como objetivo realizar a estimativa da sístole e diástole a partir do sinal PPG e avaliar as suas previsões conforme o estado da pressão sanguínea por um determinado período. Portanto, com as estimativas de sístole e diástole obtidas, o problema é tratado como uma tarefa de classificação binária considerando as classes Normotenso e Hipertenso. Além disso, este trabalho também investiga o desempenho do método em classificar diferentes tipos de pressão sanguínea (Normotenso, Pré-hipertenso, Hipertenso de grau 1, Hipertenso de grau 2). Para isso, MoNePS consiste em uma rede neural convolucional com blocos de dilatação para obter escalabilidade na extração das características do PPG e correlacionar os valores correspondentes à pressão sanguínea de uma determinada janela temporal. A avaliação do método proposto foi realizada usando dados da base de dados pública MIMIC-III. Os resultados experimentais mostram que o método proposto consegue atingir resultados comparáveis a modelos mais complexos com menor número de parâmetros. Com o método proposto, foi possível obter um erro médio absoluto para sístole e diástole de 5.02mmHg e 3.11mmHg, respectivamente. Além disso, os resultados preditos submetidos à classificação de múltiplas classes retornaram valores de F1-Score de até 94% para classe Normotenso. Quando submetido a classificação binária, o modelo apresentou respectivos 94% e 80% para as classes de Hipertenso e Normotenso.

Palavras-chave: Fotopletismografia, Pressão Sanguínea Arterial, Hipertensão, Convolução Dilatada, Monitoramento Contínuo.

Abstract

Cardiovascular diseases have been among the main causes of mortality and comorbidity in recent years. The main risk factor for the development of cardiovascular diseases is hypertension, characterized by the elevation of Arterial Blood Pressure (ABP), defined by systolic and diastolic heart movements. The diagnosis can be obtained through continuous monitoring by invasive and non-invasive methods. The most accurate way (gold standard) to obtain ABP comes from the cannulation technique, an uncomfortable and invasive way, subjecting the individual to an arterial perforation. On the other hand, blood pressure can be obtained by the non-invasive technique of Photoplethysmography (PPG). This signal is obtained by the process of reflection or refraction of light, with the advantage of allowing continuous monitoring of blood pressure outside the hospital environment and being implemented in low-cost wearable devices. Although there is a correlation in the waveforms among the PPG and ABP signals, both differ by their scale values providing a non-linear relationship of these signals. However, this correlation makes it possible to estimate blood pressure from the PPG signal using algorithms that find non-linear correlations between these two signals. The proposed Neural Model of Blood Pressure (MoNePS) method aims to estimate systole and diastole from the PPG signal and evaluate its predictions according to the state of blood pressure. Therefore, with the systole and diastole estimates obtained, the problem is treated as a binary classification task considering the Normotensive and Hypertensive classes. In addition, this work also investigates the performance of the method in classifying different types of blood pressure (Normotensive, Prehypertensive, Grade 1 Hypertensive, Grade 2 Hypertensive). For this, MoNePS consists of a convolutional neural network with dilatation blocks to obtain scalability in extracting PPG features and correlating the values corresponding to blood pressure in a given time window. The evaluation of the proposed method was performed using data from the public database MIMIC-III. The experimental results show that the proposed method can achieve results comparable to more complex models with fewer parameters. With the proposed method, it was possible to obtain a mean absolute error for systole and diastole of 5.02mmHg and 3.11mmHg, respectively. Furthermore, predicted outcomes subjected to multiple-class classification returned F1-Score values of up to 94% for Normotensive class. When submitted to binary classification, the model presented respective 94% and 80% for the classes of Hypertensive and Normotensive.

Keywords: Photoplethysmograph, Arterial Blood Pressure, Dilated Convolution, Hypertension, Continuous Monitoring.

Lista de Figuras

Figura 2.1 Movimento de contração (sístole) e de expansão (diástole) dos ventrículos	17
Figura 2.2 Modo de transmissão de luz e método de reflexão.....	20
Figura 2.3 Lugares de coleta do sinal PPG, com destaque para amostras de sinais coletados nas regiões da testa e antebraço	20
Figura 2.4 Amostras de sinal ideal e ruidoso de SpO_2	22
Figura 2.5 Aplicação dos filtros de Butterworth e Chebyshev II, sobre o sinal PPG	23
Figura 3.1 Características do sinal PPG	25
Figura 3.2 Características de um ciclo do sinal PPG	26
Figura 3.3 Metodologia utilizada	30
Figura 3.4 Camadas de entrada do modelo proposto pelos autores	30
Figura 4.1 Visão geral sobre o método proposto.....	35
Figura 4.2 Segmentação com janela deslizante e sobreposição de 50%.....	37
Figura 4.3 Arquitetura do modelo neural proposto.....	39
Figura 5.1 Amostras de um segmento de 7 segundos do sinal PPG.....	41
Figura 5.2 Amostras do sinal PPG com as respectivas derivativas de velocidade (PPG') e aceleração (PPG'')	42
Figura 5.3 Esquema de separação da base para os modelos generalistas e especialistas	43
Figura 5.4 Amostras do sinal PPG com as respectivas derivativas de velocidade (PPG') e aceleração (PPG'')	44
Figura 5.5 Exemplo de gráfico Boxplot	45
Figura 5.6 Análise dos valores preditos pelo experimento MG em relação aos valores reais.....	47
Figura 5.7 Análise das classes relacionadas aos valores preditos pelo experimento MG em relação às classes relacionadas aos valores reais.....	48
Figura 5.8 Análise dos valores preditos pelo experimento MG em relação aos valores reais em classes binárias	48
Figura 5.9 Análise dos valores preditos pelo experimento MG em relação aos valores reais em classes binárias	49

Figura 5.10 Análise das classes relacionadas aos valores preditos pelo experimento MEMG em relação às classes relacionadas aos valores reais	50
Figura 5.11 Análise dos valores preditos pelo experimento MEMG em relação aos valores reais em classes binárias	51
Figura 5.12 Análise dos valores preditos pelo experimento ME em relação aos valores reais em classes binárias	52
Figura 5.13 Análise das classes relacionadas aos valores preditos pelo experimento ME em relação às classes relacionadas aos valores reais.....	53
Figura 5.14 Análise dos valores preditos pelo experimento MEMG em relação aos valores reais em classes binárias	53

Lista de Tabelas

Tabela 2.1 Categorias de pressão arterial e seus parâmetros de referência.....	16
Tabela 2.2 Principais características que podem ser extraídas de um sinal PPG.	19
Tabela 3.1 Sumarização dos resultados encontrados pelos trabalhos relacionados.	31
Tabela 5.1 Matriz de confusão para um problema binário.	45
Tabela 5.2 Tabela de Métricas e acurácia.	46
Tabela 5.3 Média, Desvio Padrão e Erro Médio Absoluto do experimento MG.....	47
Tabela 5.4 Média, Desvio Padrão e Erro Médio Absoluto do Experimento MEMG.	50
Tabela 5.5 Média, Desvio Padrão e Erro Médio Absoluto do Experimento ME.	52
Tabela 5.6 Sumarização dos resultados dos experimentos de acordo com as regressões.....	54

Sumário

Resumo	v
Abstract	vi
Lista de Figuras	vii
Lista de Tabelas	vii
1 Introdução.....	11
1.1 Problema.....	13
1.2 Objetivo Geral.....	13
1.3 Objetivos Específicos.....	13
1.4 Organização do Trabalho.....	14
2 Fundamentação Teórica.....	15
2.1 Pressão Sanguínea e Hipertensão	16
2.2 Métodos de Aferição	18
2.3 Biossensores Fotoelétricos para o Monitoramento da Pressão Sanguínea	19
2.3.1 Sensoriamento por Fotopletismografia.....	19
2.3.2 Artefatos de Movimentos	21
2.4 Técnicas de Processamento do Sinal PPG	22
3 Trabalhos Relacionados.....	24
3.1 Estimativa da Pressão Sanguínea com Modelos Clássicos de Aprendizagem de Máquina	24
3.2 Estimativa da Pressão Sanguínea com Modelos Profundos de Aprendizagem de Máquina	27
3.3 Discussão.....	31
4 MoNePS.....	34
4.1 Visão Geral.....	34
4.2 Aquisição dos dados	35
4.3 Pré-processamento	36
4.4 Modelo.....	37
5 Experimentos e resultados.....	40
5.1 Protocolo Experimental	40
5.1.1 Conjunto de Dados	41
5.1.2 Método Baseline.....	41
5.1.3 Estratégia de Validação	42

5.1.4 Métrica de Avaliação	43
5.2 Resultados	46
5.2.1 Resultados com Modelos Generalistas (MG)	46
5.2.2 Resultados com Modelo Especialista-Modelo Generalista (MEMG).....	49
5.2.3 Resultados do Modelo Especialista (ME).....	51
5.3 Discussão.....	54
6 Conclusões Parciais	55
6.1 Trabalhos Futuros	56
Referências.....	57

Introdução

As doenças cardiovasculares representam uma das principais causas a afetar o bem-estar e qualidade de vida das pessoas. Em média, anualmente cerca de 17,8 milhões de pessoas vão a óbito ao redor do mundo em sua decorrência (KAPTOGE, 2019). Tais doenças são acometidas por frequentes instabilidades da pressão sanguínea arterial provocadas pela pressão alta, denominada hipertensão, tendo como principais consequências os acidentes vasculares cerebrais e o infarto do miocárdio (FARSANG et al., 2009). O estado de hipertensão é consequência de valores atrelados à pressão sanguínea pela sístole e diástole, sendo diagnosticada quando a pressão sanguínea sistólica é $\geq 140 \text{ mmHg}$ e a pressão sanguínea diastólica é $\geq 90 \text{ mmHg}$ (Unger et al., 2020).

Detectar de maneira precoce a hipertensão é um desafio devido à falta de sintomas agudos. Na maioria dos casos, ela pode levar a indícios como dor de cabeça, dificuldade respiratória e dores no peito (Liang et al., 2018a). Entretanto, devido à alta instabilidade da pressão sanguínea seus sintomas se apresentam de forma intermitentes, sendo considerada pelos médicos uma doença assassina silenciosa (KATARZYNA et al., 2011; WHO, 2021). Por essa razão, o monitoramento contínuo da pressão sanguínea é visto como a maneira mais efetiva para combater essa (ELGENDI et al., 2019).

A aferição de pressão sanguínea pode ser realizada de duas formas: de maneira invasiva e não invasiva. Os métodos invasivos são perfurativos arteriais com alta precisão, porém, tecnicamente custosos e oferecem riscos de complicações como traumas, sangramento, infecção e trombose (BOWDLE, 2002). Por outro lado, os métodos não invasivos consistem em coletas da variação do fluxo sanguíneo arterial por meio da técnica de esfigmomanômetro, normalmente aferido por equipamentos oscilométricos e auscultatórios (OGEGEBE; PICKERING, 2010).

Quando se trata de monitoramento de atividades cardiovasculares existem dois métodos comumente empregados pelos fabricantes de dispositivos para detectar alterações nas atividades elétricas do coração e no fluxo sanguíneo no leito microvascular do tecido: eletrocardiograma (ECG - *electrocardiogram*) e fotopletismografia (PPG - *photoplethysmograph*). O sinal de ECG é percebido por meio de dispositivos de eletrodos descartáveis, ligados ao tronco ou por eletrodos têxteis usados no peito como nos monitores tradicionais de frequência cardíaca (JEYHANI et al., 2015), sendo fundamental

para o diagnóstico de um amplo espectro de anormalidades de arritmias cardíacas (HANNUN et al., 2019). Por outro lado, o PPG é obtido por uma técnica não invasiva, de baixo custo, com o objetivo de medir as mudanças do fluxo sanguíneo no processo de absorção/refração da luz através da pele (RUNDO et al., 2018). Em ambientes clínicos, o sinal PPG é encontrado em dispositivos de oximetria de pulso (SpO_2) – também utilizados para medir a saturação de oxigênio, o qual produzem sinais de ondas PPG. Os dados providos por esses dispositivos possibilitam a extração de parâmetros fisiológicos tais como: pulso cardíaco, taxa respiratória, perfusão tecidual/vascular e desordens cardíacas em detrimento de inconstâncias da pressão sanguínea (RIAZ et al., 2019).

Os recentes avanços tecnológicos tornaram possível o desenvolvimento de dispositivos vestíveis, com predominância no emprego de sensores PPG capazes de capturar e processar biossinais gerados pelo corpo humano por meio de pulseiras, relógios, óculos, fones de ouvido, cintas e joias inteligentes (JOHN DIAN; VAHIDNIA; RAHMATI, 2020). Usualmente, os sistemas de monitoramento de saúde vestíveis são equipados com uma variedade de sensores eletrônicos, atuadores e módulos de comunicação sem fio que permitem o monitoramento de sinais fisiológicos, tais como os níveis de glicose no sangue (HABBU; DALE; GHONGADE, 2019), taxa de respiração (Pernice et al., 2019), saturação de oxigênio (AGHAM; CHASKAR, 2019), nível de álcool no sangue (WANG; YANG; WU, 2018) e atividades eletrodérmicas (CAN et al., 2019).

Além dos monitoramentos supracitados, existe a possibilidade de utilizar o sinal PPG para realizar a estimativa da pressão sanguínea arterial (ABP - *Arterial Blood Pressure*), a qual geralmente é atribuída às técnicas invasivas. O sinal PPG possui uma intrínseca relação com o sinal ABP pela variação do fluxo sanguíneo, sendo possível a estimativa relacional entre os sinais (LIANG et al., 2018b). Existem características intrínsecas do sinal PPG para estimar o sinal ABP, as quais podem ser obtidas com o uso de técnicas estatísticas ou algoritmos de aprendizagem de máquina (SLAPNIČAR; MLAKAR; LUŠTREK, 2019).

Na literatura, a estimativa da pressão sanguínea definida pelos movimentos sistólicos e diastólicos via PPG tem sido explorada por técnicas que alcançaram valores de acordo com os critérios adotados pela Associação para Avanços de Instrumentação Médica (AAMI), como: cálculo do tempo de trânsito do pulso (PTT - *Pulse Transit Time*), que consiste no intervalo entre dois pontos percorridos pelo sangue no momento do batimento cardíaco até sua chegada nas terminações venosas (PETER; NOURY; CERNY, 2014); e cálculo da velocidade de onda do pulso (PWV, acrônimo para *Pulse Wave Velocity*) relacionada a velocidade do sangue nos vasos sanguíneos (NABEEL, 2016).

Além dessas técnicas, também são utilizados métodos de aprendizagem de máquina, como: algoritmos de regressão (e.g. árvore de decisão, máquina de vetor de suporte, Adaptive Boosting, e floresta aleatória) a partir de características manuais extraídas do sinal ECG e PPG (KACHUEE et al., 2017, LIANG et al., 2018b); e algoritmos de aprendizagem profunda para classificação e avaliação de hipertensão baseada em transformadas contínuas de *wavelets* e transferência de aprendizado (LIANG et al., 2018b; SLAPNIČAR; MLAKAR; LUŠTREK, 2019). Em geral, a maioria desses métodos

utiliza base de dados coletadas de dispositivos clínicos e/ou dispositivos vestíveis, e os dados rotulados por especialistas são utilizados para construir modelos preditivos.

1.1 Problema

A literatura relacionada evidencia que existem diversas propostas com módulos de estimativa da pressão sanguínea via sinal PPG e ECG. Desses trabalhos, a maioria aplica métodos que envolvem algoritmos de aprendizagens de máquina no qual recebem como valores de entrada características extraídas manualmente de frequência e tempo, ou aplicam transformação do sinal através de métodos tais como *wavelet* e espectrogramas temporais. Além disso, esses algoritmos estão relacionados a formas de aprendizagem supervisionada, onde há a necessidade de rotulagem dos dados. Um problema dos métodos que empregam extração manual de características junto a algoritmos de aprendizagem supervisionada está na necessidade de ter um especialista para analisar características extraídas de forma estatísticas, o que pode ocasionar em maior tempo para se alcançar resultados.

O presente trabalho apresenta um modelo preditivo das estimativas de sístole e diástole composto por camadas que permitem a extração automática de características advindas de sinais PPG e por blocos convolucionais dilatados que permitem capturar a relação dessas características através de seus filtros com propriedade de dilatação. O método proposto recebe o sinal PPG normalizado como entrada, eliminando a necessidade de informações adicionais ou transformações de dados, permitindo estimar os pontos de sístole e diástole da ABP para detectar a presença de hipertensão.

1.2 Objetivo Geral

Desenvolver e avaliar um método preditivo baseado em redes neurais artificiais profundas para determinar os níveis da pressão sanguínea arterial (Normotenso, Pré-Hipertenso, Hipertenso Grau 1 e Hipertenso Grau 2) pelos pontos preditos de sístole e diástole relacionados ao sinal ABP, de dados captados via sensoriamento fotoelétrico PPG. O objetivo geral desta pesquisa será norteado por objetivos específicos essenciais para a seu desenvolvimento e conclusão, com destaque para os itens apresentados a seguir.

1.3 Objetivos Específicos

- Detectar e remover potenciais ruídos nos sinais PPG e ABP pela aplicação de filtros de pré-processamento;
- Avaliar a sincronização dos dados PPG e ABP e detectar os rótulos da pressão sanguínea contidos nos segmentos ABP.
- Desenvolver um mecanismo de extração de característica automática, baseada em algoritmos de redes neurais convolucionais;

- Desenvolver e avaliar um método que identifique as mudanças do sinal nas características extraídas ao longo do tempo para estimativa dos pontos de sístole e diástole relacionados ao sinal ABP;

1.4 Organização do Trabalho

O restante deste documento está organizado como segue:

No Capítulo 2 são fornecidas informações necessárias para encaminhar o entendimento desta pesquisa. São apresentados conceitos de pressão sanguínea, métodos de aferição, biossensores fotoelétricos de sinais PPG e seus desafios, técnicas de pré-processamento do sinal PPG, os filtros aplicados para atenuação de ruídos e técnicas de aprendizagem de máquina.

No Capítulo 3 são descritos os principais trabalhos relacionados a esta pesquisa. Estes trabalhos são divididos em grupos de abordagem de aplicação de algoritmos de aprendizagem de máquina, desde implementações com algoritmos de aprendizagens de máquina clássicos a algoritmos modernos profundos. Também são abordados os estudos sobre modelos que aprendem com viés personalizado, onde parte dos dados de um paciente que compõe o conjunto de dados de treino é utilizado também no conjunto de validação.

No Capítulo 4 é apresentada a proposta para resolução do problema apresentado nesta pesquisa, fornecendo uma descrição de forma detalhada das etapas que propiciam a estruturação lógica para a realização apurada da estimativa dos pontos que definem a pressão sanguínea arterial.

No Capítulo 5 são descritos os resultados obtidos das experimentações realizadas. Neste capítulo é descrito o comparativo dos resultados gerados entre o modelo proposto e *baseline* com base em seus desempenhos em relação a base de dados de MIMIC-III.

Por fim, no Capítulo 6 são apresentadas as considerações finais sobre esta pesquisa, bem como apresentar quais as próximas etapas a serem exploradas.

CAPÍTULO

2

Fundamentação Teórica

A pressão sanguínea, em particular o estado de pressão elevada (hipertensão), está diretamente relacionada a doenças cardiovasculares, que podem se potencializar durante a vida adulta. O desenvolvimento de doenças cardiovasculares em sua maioria comporta-se como um vetor para outras doenças coronárias (obstrução das artérias coronárias situadas no coração), que acentuam as chances de o indivíduo desenvolver hipertensão arterial (FRANKLIN et al., 2001). Infelizmente, a maioria dos indivíduos hipertensos não têm consciência que portam essa condição clínica, mesmo tendo seus órgãos internos afetados (WHO, 2013). Tal fato mostra a importância do monitoramento e diagnóstico preventivo para tratamento e controle da hipertensão.

O monitoramento da pressão sanguínea para avaliação e diagnósticos de prevenção de doenças cardiovasculares é frequentemente realizado com métodos tradicionais como auscultação (MCCUTCHEON; RUSHMER, 1967), esfigmomanometria (FERREIRA et al., 2010) e oscilometria (VIGATO; LAMAS, 2019). Uma alternativa a essas técnicas que tem apresentado resultados promissores é a utilização de dispositivos que utilizam apenas o sensoriamento de oximetria de pulso pelo método fotoelétrico PPG (JOHN DIAN; VAHIDNIA; RAHMATI, 2020).

Alinhados aos dispositivos portadores dos sensores PPG, existem técnicas estatísticas que auxiliam na estimativa dos valores principais da pressão sanguínea, sendo esta determinada pela contração (conhecida como sístole) e relaxamento (conhecido como diástole) ventricular. Segundo Khalid et al. (2018), várias técnicas de estimativa da pressão sanguínea de maneira não invasiva já foram aplicadas, tais como cálculo de tempo decorrido do pulso (PTT - pulse transit time) (PARRY FUNG et al., 2004; Gesche, 2011), passando por pesquisas em métodos de cálculo de velocidade de ondas (PETER; NOURY; CERNY, 2014), a métodos mais robustos em aprendizagem de máquina e aprendizado profundo (KHALID ET AL., 2018; SLAPNIČAR; MLAKAR; LUŠTREK, 2019).

De modo a relacionar os conceitos resultantes do problema de estimar a pressão sanguínea apenas com o sensoriamento PPG, os conceitos a seguir irão contribuir para elucidação do problema investigado desta pesquisa. A Seção 2.2 aborda o assunto sobre pressão sanguínea. A Seção 2.3 aborda os assuntos de biossensores. A Seção 2.4

complementa o tema, com abordagens das técnicas de processamento de biossinal que encaminharam a presente pesquisa.

2.1 Pressão Sanguínea e Hipertensão

A pressão sanguínea é um dos parâmetros clínicos comuns, influenciada pelos pontos de sístole e diástole, pontos estes coletados pelo volume sanguíneo arterial, conforme apresentado na Figura 2.1. Segundo Peter (2014), a cada movimento cardíaco o sangue é pressionado da câmara ventricular para a aorta, num movimento chamado sístole (movimento ao qual se destaca o valor máximo da pressão sanguínea). Esse comportamento do coração exerce uma pressão que pode ser sentida através de toda a árvore arterial com uma pressão interna tipicamente da ordem de 100 mmHg (BLANCHARD; BRONZINO, 2012). De acordo com Unger et. al (2020), a Hipertensão arterial é uma condição clínica por elevação mantida nos níveis ≥ 140 e/ou ≥ 90 mmHg em seus valores de sístole e diástole, respectivamente.

Os cuidados com pacientes hipertensos são vitais e se norteiam com base em quatro tipos de recomendações internacionais sobre o controle da alta da pressão sanguínea. Em 2017 foram publicadas as recomendações Canadenses (LEUNG et al., 2017) e Norte Americanas (WHELTON et al., 2017), seguidas pelas recomendações Europeias em 2018 (Williams et al., 2018) e as recomendações da Sociedade Internacional de Hipertensão (ISH) em 2020 (UNGER et al., 2020). Como forma de padronizar nossas análises, neste trabalho foi adotado o guia internacional estabelecido por (UNGER et. al, 2020). Suas definições sobre pressão sanguínea para uma pessoa adulta podem ser vistas na Tabela 2.1.

Tabela 2.1 Categorias de pressão arterial e seus parâmetros de referência. Fonte: Adaptada de (UNGER et al., 2020).

Categoria	Sistólica [mmHg]	Diastólica [mmHg]
Normotenso	< 130	< 85
Normotenso Elevado	130 - 139	85 - 89
Hipertenso	≥ 140	≥ 90
Hipertensão (estágio 1)	140 - 159	90 - 99
Hipertensão (estágio 2)	≥ 160	≥ 100
Nível Diabético	< 130	< 80

A pressão sanguínea e suas propriedades são comumente usadas como indicadores de saúde do sistema cardiovascular. Por exemplo, algumas doenças cardiovasculares estão associadas à criação de aterosclerose (quando a distensão arterial diminui drasticamente pelo aumento da rigidez das paredes arteriais). Esse comportamento arterial pode levar a um aumento de sua pressão, sendo esta uma das razões pelas quais as doenças cardiovasculares aumentam o risco do paciente e são uma das principais causas de morte (PETER, 2014).




Figura 2.1 Movimento de contração (sístole) e de expansão (diástole) dos ventrículos. Fonte: (MANUAL MSD, 2019).

Segundo Barroso (2020), a hipertensão continuamente está associada a distúrbios metabólicos, alterações funcionais de órgãos, sendo agravada por fatores de risco como dislipidemia, obesidade visceral, intolerância à glicose e diabetes melito, além de manter associações independente com eventos tais como morte súbita, acidente vascular encefálico, infarto agudo do miocárdio, insuficiência cardíaca, doença arterial periférica e doença renal crônica.

A hipertensão apresenta um caso clínico mais delicado, devido suas inúmeras consequências negativas e pode ser agravada a fatores de risco como dislipidemia, obesidade abdominal, intolerância à glicose e diabetes mellitus (WEBER et al., 2013). A hipertensão é uma condição clínica multifatorial em decorrência dos elevados níveis de pressão sistólica e diastólica (≥ 140 e ≥ 90 mmHg) (MANCIA, 2013). Esses valores podem mudar conforme a idade, tal como acontece em crianças e adolescentes (LURBE, 2009).

A pré-hipertensão caracteriza-se pelos valores de sístole no intervalo de 121-139 mmHg e diástole no intervalo de 81-89 mmHg (MALACHIAS, 2016). Como consequência do estado anterior à hipertensão, indivíduos classificados nesta categoria têm maior probabilidade de se tornarem hipertensos e desenvolverem complicações cardiovasculares comparados a indivíduos com pressão arterial normal ($\leq 120/80$ mmHg), necessitando de acompanhamento periódico (ALESSI et al., 2014).

2.2 Métodos de Aferição

Existem dois tipos de métodos para aferição da pressão sanguínea arterial: o método invasivo (direto) e o método não invasivo (indireto). O método invasivo alcança valores mais precisos por normalmente envolver a inserção de um cateter ou agulha acoplado a um sensor de pressão em uma artéria, procedimento conhecido como canulação arterial (KRAUSMAN 1975), no qual a cânula precisa ser conectada a um sistema de fluido interligado a um transdutor eletrônico de pressão.

O método invasivo é preferível em quando é necessário realizar o monitoramento pulso-a-pulso da pressão arterial, por apresentar valores mais precisos em relação ao método não invasivo. Contudo, acompanham desvantagens como a possibilidade de infecção da linha arterial e custo mais elevado devido aos procedimentos de calibração e à necessidade do acompanhamento por um médico ou enfermeira (LAIZZO, 2009). Assim, em exames clínicos, quando se deseja apenas determinar a pressão arterial (sistólica, diastólica e média), o método direto apresenta uma solução mais precisa.

Embora o método invasivo seja utilizado clinicamente para medição contínua pulso-a-pulso da pressão sanguínea arterial, tecnologias que permitem o método não invasivo são aplicadas como técnica de rotina em práticas clínicas. Dentre estas tecnologias destaca-se o esfigmomanômetro de mercúrio considerado como padrão ouro pela Organização Mundial da Saúde. No entanto, com o banimento do mercúrio devido sua contaminação e toxicidade, as técnicas auscultatórias (denominada também como técnica de Korotkoff) e oscilométricas têm sido utilizadas (MUNTNER, 2019).

A técnica auscultatória consiste na utilização de um estetoscópio para auscultar a artéria braquial a fim de detectar o aparecimento e abafamento ou desaparecimento dos sons de Korotkoff, no qual também representam a sístole e a diástole (O'BRIEN; FITZGERALD, 1994). Por outro lado, a técnica oscilométrica utiliza as fases de inflação e deflação do manguito para estimar a pressão sanguínea arterial. A maioria dos dispositivos que compõem a técnica oscilométrica estima a pressão arterial quando o manguito está sendo esvaziado (deflação). A pressão arterial média, comumente realizada por meio de razões fixas da amplitude máxima de oscilação, é estimada como a pressão do manguito quando a amplitude de oscilação é máxima e os pontos de sístole e diástole são calculados (ALPERT; QUINN; GALLICK, 2014).

Outra forma de medição da pressão sanguínea é por meio do sinal de baixa frequência denominado PPG, que permite relacionar suas ondas ao sinal ABP por maior tempo de observação (HSIU; HSU; WU, 2009). Em indivíduos que acusam sintomas de

hipertensão, a utilização de métodos contínuos para monitoramento das variações da pressão sanguínea torna-se imprescindível.

2.3 Biossensores Fotoelétricos para o Monitoramento da Pressão Sanguínea

Os sensores *biológicos* ou biossensores são dispositivos analíticos que convertem uma resposta biológica em sinais elétricos de modo a ser bastante específico e reutilizável, independente de parâmetros físicos como pH e temperatura (MEHROTRA, 2016). Os biossensores foram introduzidos às pesquisas em 1960 pelos pioneiros Clark e Lyons e são divididos em tipos baseados em enzima, tecido, imunidade, DNA, térmico, piezoelétrico e ótico. Neste trabalho, daremos atenção ao sensor fotoelétrico denominado fotoplethysmografia (do inglês, Photoplethysmograph - PPG, no qual plethysmos = ampliar, em Grego), introduzido na década de 1930' (ALIAN E SHELLEY, 2014).

Os sensores fotoelétricos se distinguem de outros tipos de sensores devido à sua natureza auxiliativa na detecção do volume sanguíneo da artéria radial. Por meio dos sinais coletados por técnica de refração ou reflexão infravermelha é possível adquirir informações sobre a frequência cardíaca, pressão sanguínea, volume sanguíneo e resistência dos vasos sanguíneos (THANACHARTWET, 2016). Os sensores fotoelétricos são pequenos, possuem alta sensibilidade, sofrem baixa influência da temperatura corpórea e aliados aos sensores de pressão são utilizados para medir a Oximetria de Pulso (SpO₂) pelas hemoglobinas, proteína presente na corrente sanguínea (ZHANG; ZUO; WANG, 2018). A técnica comumente implantada para isolar a absorção de luz arterial para detecção do elemento SpO₂ é baseada no sinal PPG (NITZAN; TAITELBAUM, 2008).

2.3.1 Sensoriamento por Fotoplethysmografia

Um sensor PPG consiste em dois elementos básicos para seu funcionamento: uma fonte de luz e um fotodetector para medir a quantidade de luz que atravessa o tecido epitelial. Conforme o sensor atinge níveis mais profundos no tecido, é possível a coleta de mais informações de acordo com o comprimento do sinal retornado (HAN et al., 2019). A Tabela 2.2 apresenta as principais características encontradas no sinal PPG. Essas características podem ser encontradas pelo fotodetector que absorve a luz de duas formas: via transmissão, quando a luz do sensor PPG atravessa o tecido humano; ou via reflexão, quando a luz do sensor PPG que incide sob o tecido reflete para o fotodetector, conforme visto na Figura 2.2.

Tabela 2.2 Principais características que podem ser extraídas de um sinal PPG.

Características	Descrição
Amplitude Sistólica	Reflete a variação AC no volume sanguíneo no local de aferição.

Área de Pulso	Área total sob a curva PPG.
Intervalo Pico a Pico	Intervalo sobre dois picos sistólicos.
Índice de Rigidez de Grandes Artérias	Intervalo entre os picos sistólicos e diastólicos.




Figura 2.2 Modo de transmissão de luz e método de reflexão. Fonte: adaptada de (LEMAY, 2014).

Conforme Allen (2007), existem vários estudos na literatura que apontam áreas de coleta no corpo humano para medição do PPG, onde o sinal PPG pode ser facilmente identificado em lugares como orelhas, dedos de mãos e pés. Além desses locais, Ghamari et al. (2018) apontam regiões do corpo para medição do sinal PPG, como a cabeça, torso e pulso. Como o sinal PPG pode ser coletado em diferentes regiões do corpo, é natural que o comportamento do sinal também varie, conforme visto na Figura 2.3.




Figura 2.3 Lugares de coleta do sinal PPG, com destaque para amostras de sinais coletados nas regiões da testa e antebraço. Fonte: adaptado de (GHAMARI, 2018; HARTMANN et al. 2019).

Sensores de PPG são capazes de emitir luz no tecido epitelial utilizando um ou mais diodo emissor de luz (do inglês, LED) (Ghamari, 2019). A absorção e transmissão da luz depende de alguns fatores, como o caminho que a luz percorre, a densidade do tecido epitelial, o volume de sangue no tecido e a composição sanguínea (Mannheimer, 2007). Os fotodiodos são os responsáveis por medir a intensidade da luz refletida da pele, no qual

representa a variação de volume sanguíneo inferida a partir da proporção de luz refletida (FISCHER et al., 2017).

Assim como a fonte de luz, a sua tonalidade desempenha um importante papel na detecção volumétrica de vasos sanguíneos. Existem tonalidades como vermelha, verde, amarela e azul. Embora a maioria das abordagens do PPG seja com coloração vermelha, o PPG com coloração verde tem apresentado menos interferência em decorrência de ruídos causados pela movimentação corporal (denominados artefatos), sendo menos vulnerável a ruídos (MAEDA; SEKINE; TAMURA, 2011). De acordo com Tamura et al. (2014), LEDs de luz verde possuem maior absortividade tanto para oxiemoglobina¹ quanto para desoxiemoglobina², o que leva a resultados mais notáveis em mudanças de pulsos sanguíneos em torno do tecido epitelial que a reflexão em luz infravermelha.

Câmeras de vídeo também podem ser utilizadas como fontes de sinal PPG, devido os canais de luz verde, vermelho e azul conterem informações PPG encontradas no formato RGB (*red, green, blue*), onde existe maior predominância de informação no canal de luz verde (Tamura et al., 2014). Existem dois tipos de PPG em vídeo, móveis sem contato e os tangíveis. Os PPGs móveis, incluídos em câmeras de smartphones ou webcams permitem a realização de exames com a luz diretamente refletida da pele (TYAPOCHKIN; SMORODNIKOVA; PRAVDIN, 2019). Além disso, os sinais PPG podem ser captados de forma remota, com distâncias acima de um metro através de luz ambiente (VERKRUYSSE; SVAASAND; NELSON, 2008). Os tangíveis necessitam de uma distância menor para medições e necessitam do contato direto da pele com o dispositivo, visto em casos em que é necessário o contato da ponta do dedo sobre a luz de LED do flash da câmera do celular (JONATHAN; LEAHY, 2010).

2.3.2 Artefatos de Movimentos

Devido às possibilidades de aplicações com o sensor PPG para monitoramento fisiológico, bastante explorado na área esportiva, existe um desafio em potencial correspondente a atenuação dos ruídos causados por pequenos movimentos que podem alterar o comportamento padrão do sinal PPG. A esta distorção causada ao sinal é atribuída o nome de artefatos de movimentos. A Figura 2.4 apresenta três amostras de um sinal PPG com duas representações do sinal com ruído e uma com sua forma ideal. De acordo com Maeda, Sekine e Tamura (2011), a principal interferência que o sinal pode sofrer tem relação com ruídos em baixa frequência, e a maioria dos métodos usados para redução dos artefatos emprega técnicas de pré-processamento.

¹ Hemoglobina oxigenada, com brilho mais avermelhado.

² Hemoglobina sem oxigênio, com uma cor mais azulada / roxa.




Figura 2.4 Amostras de sinal ideal e ruidoso de Oximetria de Pulso (SpO_2). Fonte: adaptado de (REDDY; GEORGE; KUMAR, 2009).

Segundo Fischer et al. (2017), a remoção ou a identificação de artefatos tem impacto no sinal coletado, pois artefatos de movimento são as causas mais comuns de alarmes falsos, corrupção do sinal e medição imprecisa no monitoramento clínico. Além disso, sua forma, incidência, duração e gravidade variam significativamente entre diferentes ambientes e populações de pacientes (LEE; ZHANG, 2003; KIM; YOO, 2006; KIM; RYOO; BAE, 2007; REDDY; GEORGE; KUMAR, 2009; LEE, 2010; RAM ET AL., 2012).

2.4 Técnicas de Processamento do Sinal PPG

O sinal PPG é sensível a movimentos, sejam eles proporcionados pela respiração ou por movimentos corporais intencionais, que geralmente distorcem seu padrão de onda, conforme apresentado na Figura 2.4. Para atenuar esses efeitos indesejados encontrados no sinal PPG, normalmente se aplicam técnicas de processamento de sinal como os filtros de pré-processamento *Butterworth* (PINTO, 2019), *Savitzky-Golay* (SCHAFER, 2011), *Chebyshev II* (SMITH, 2003), dentre outros (LEE; ZHANG, 2003). O objetivo do processamento de sinal é acurar a morfologia do dado sensorial com a eliminação de pontos anômalos contidos no sinal, ou com a transformação do mesmo para visualização de novas características (VAN DRONGELEN, 2018).

Segundo Riaz et al. (2019), existem três tipos de movimentos que podem tornar o sinal ruidoso: 1) interferência do sinal por força eletromagnética; 2) desalinhamento do sensor PPG em relação a pele causado pela constante intermitência de contato; e 3) ruído em alta frequência como interferência por ambiente e atividades musculares. A importância em se utilizar filtros de sinal, baseia-se na concepção de tornar o sinal mais limpo, com a minimização de anomalias para que se possa extrair características padronizadas.

A técnica de filtragem é um elemento que desempenha um importante papel para posterior caracterização do sinal PPG com possibilidade de melhora na morfologia do sinal. Na literatura, a aplicação de filtros sobre o sinal de séries temporais PPG é uma prática comum devido a sensibilidade exposta do sinal captado, seja ele em infravermelho ou nas cores verde e azul. No entanto, devido a sua complexidade e abrangência de contextos de sua aplicação para dispositivos móveis vestíveis direcionados à saúde, a

aplicação de filtros é concebida de maneira empírica, não havendo, portanto, um consenso sobre qual filtro aplicar (ELGENDI et al., 2019).

Conforme Elgendi, et al. (2019), dentre os filtros encontrados na literatura para melhorar a morfologia do sinal PPG, os mais utilizados são: *Butterworth* e *Chebyshev II*. A Figura 2.5 apresenta um comparativo de seus efeitos sobre o sinal PPG puro. O filtro de *Chebyshev II* possui algumas vantagens, como ter uma zona de transição de frequência mais limpa, e manter um nível horizontal sem ondulações em seu intervalo de frequência.

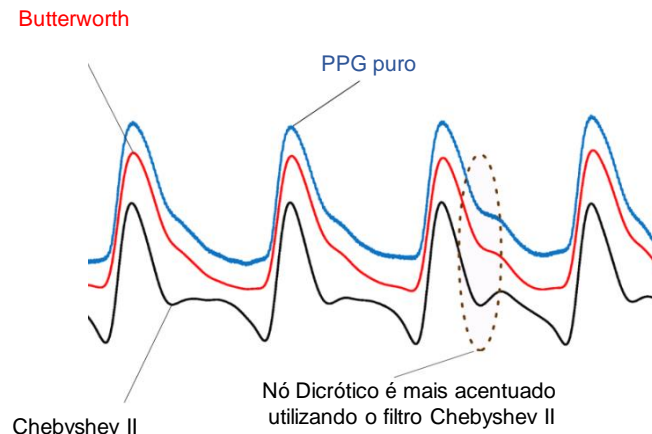


Figura 2.5 Aplicação dos filtros de Butterworth (linha vermelha) e Chebyshev II (linha preta), sobre o sinal PPG. O filtro de Chebyshev II acentua a diferença entre as ondas sistólica e diastólica quando comparado ao filtro de Butterworth..Fonte: adaptada de (ELGENDI et. al., 2019).

Tamura et al. (2014) apresentam os métodos de filtros adaptativos como outra maneira de cancelar ruídos de sinal. Esses métodos dispõem de algoritmos recursivos que atualizam seus próprios parâmetros de filtros para obter o nível desejado de rejeição de ruído, sem estimativas a priori do sinal ou ruído. O seu funcionamento depende de duas entradas: sinal corrompido e uma entrada de referência contendo alguma correlação de ruído em potencial com o ruído primário. Exemplos de algoritmos relacionados a esta técnica são: mínimo quadrado, filtro de *Kalman*, frequência de tempo e transformação de *wavelet*, PCA (*Principal Component Analysis*), *Widrow's* e *Laguerre Expansion*.

Os esforços para melhorar o sinal PPG não se restringem apenas a utilização de filtros. Conforme Lai e Kim (2015) existem métodos que se baseiam em decomposição do sinal (*Fourier Transform*, e *Singular Spectrum Analysis*), métodos de heurística, e Análise de *Componente Independente e Restrito* (ICA).

Trabalhos Relacionados

Este capítulo descreve os principais trabalhos relacionados a presente pesquisa, ou seja, a abordagens em assuntos que utilizam técnicas de aprendizagem de máquina para estimar a pressão sanguínea via sinal de oximetria de pulso (SpO_2). Os algoritmos de aprendizagem de máquina para estimar a pressão podem ser divididos em dois grupos: (1) técnicas clássicas de aprendizagem de máquina e (2) técnicas de aprendizagem profunda. Vários trabalhos utilizam dados extraídos do sinal PPG manualmente como média, desvio padrão, cálculo de distância entre picos, dentre outros. Esses dados possibilitam o treinamento de modelos gerados a partir de técnicas clássicas como *SVM*, *AdaBoost*, floresta aleatória e redes neurais rasas com uma ou até duas camadas ocultas. Outros trabalhos utilizam o sinal puro e empregam técnicas profundas de convolução e recorrência para realizar a extração de características e análise ao longo do tempo. Além disso, também são abordadas aplicações com a geração de modelos especializados (ou personalizados), as quais os dados fisiológicos de uma pessoa encontram-se distribuídos em subconjuntos de treino, teste e validação.

3.1 Estimativa da Pressão Sanguínea com Modelos Clássicos de Aprendizagem de Máquina

Xie et al. (2018) apresentam modelos de aprendizagem de máquina para contínua estimativa da pressão sanguínea através do sinal PPG. De modo geral, a estimativa da pressão sanguínea pode ser realizada por métodos de inferência estatística sobre o sinal PPG para estimar os pontos fundamentais da pressão, tais como os pontos de sístole e diástole. Neste sentido, Xie et al. (2018) propõem a avaliação de modelos de estimativa de pressão sanguínea baseados em regressão linear, rede neural, árvore de decisão, método de *bagging* e floresta aleatória.

Os modelos propostos são gerados com as seguintes etapas: 1) pré-processamento dos dados com o uso de filtro passa baixa; 2) extração de características, conforme mostrado na Figura 3.1, como os pontos de (a) base do pulso, (b) pico sistólico, (c) ângulo

dicrótico e (d) pico diastólico; e 3) modelo de regressão conforme as técnicas propostas para inferir os valores da pressão sanguínea.




Figura 3.1 Características do sinal PPG. (a) base do pulso; (b) pico sistólico; (c) ângulo dicrótico; (d) pico diastólico no ângulo dicrótico; (T_s) período de tempo entre a base do ciclo e o pico sistólico; (T_v) intervalo de tempo entre o pico sistólico e o ângulo dicrótico; (T_{sd}) período entre o pico sistólico e o pico diastólico; (T_c) período completo de um ciclo; (T_d) período entre o pico sistólico e a próxima base de início de ciclo; Fonte: (XIE et al., 2018).

Os experimentos foram conduzidos usando a base de dados UQVS (*University of Queensland Vital Signs*) (LIU; GÖRGES; JENKINS, 2012). Esta base contém 11.492 registros do sinal PPG, distribuídos pela técnica de separação dos dados *holdout* com separação de 80% para treino e 20% para teste. Como função de perda adotada para avaliação dos modelos, foi implementada a função de *Root Mean Square Error* (RMSE), onde foram alcançados valores de sístole e diástole de 7.57mmHg e 5.40 mmHg , respectivamente. Para avaliar a precisão do melhor modelo (modelo usando floresta aleatória) dentre os experimentados foram aplicadas as métricas de Média Absoluta e Desvio Padrão ($Me; \sigma$), com os respectivos valores para sístole e diástole de $(4.21;3.24)$ e $(7.59;5.39)\text{ mmHg}$.

Zhang e Feng (2017) apresentam um estudo para conseguir estimar a pressão sanguínea via sinal PPG avaliando três algoritmos de aprendizagem de máquina: regressão linear, rede neural artificial e SVM. Os experimentos foram conduzidos usando a base de dados UQVS, onde foram aplicadas etapas de pré-processamento. O sinal PPG possui baixa variação da corrente contínua (DC) devido os movimentos respiratórios e componentes de ruído de alta frequência gerados por movimentos abruptos. A frequência fundamental do sinal PPG está contida entre 1 e 1,5Hz, baseada na média por minuto de batimento cardíaco humano, que varia entre 60 e 90. Logo, foi aplicado o método de deslocamento do sinal PPG puro para sua média zero e em seguida, aplicado o filtro passa baixa com frequências de corte de 0-5 Hz.

A quantidade de dados extraídos do sinal PPG foi reduzida conforme o modelo experimentado com características apresentadas na Figura 3.2. Por exemplo, o modelo em rede neural utilizou 9 características de entrada, enquanto o modelo em SVM recebeu 15 características. Dentre os modelos experimentados, o modelo de SVM apresentou melhores resultados dentro das mesmas configurações de ambiente.

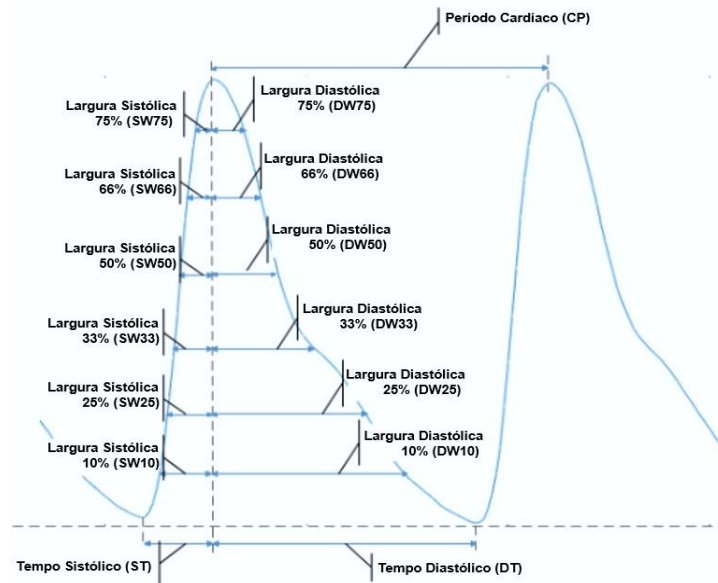


Figura 3.2 Características de um ciclo PPG. Fonte: adaptado de (ZHANG; FENG, 2017).

Em seus experimentos, os autores dividiram a base em treino e teste de maneira não personalizada, ou seja, reservando mais de 7000 amostras para treino, e cerca de 1000 amostras totalmente diferentes para o teste. O modelo SVM foi gerado com auxílio da biblioteca LIBSVM, com parametrização padrão fornecida por ela. Os valores dos testes para a pressão sanguínea determinados pelos pontos de sístole e diástole foram submetidos às métricas de erro absoluto ($e_{abs} = PS_{estimada} - PS_{real}$) e erro relativo ($e_{rel} = e/p_S$) com os valores de média (Me) e desvio padrão (σ) encontrados em e_{abs} . Logo, os seguintes valores (e_{abs_Me} ; $e_{rel_}\sigma$) de sístole e diástole foram relatados, respectivamente: $(11,641 \pm 8,202\text{mmHg})$ e $(7,617 \pm 6,783\text{mmHg})$.

Kurylyak, Lamonaca, Grimaldi (2013) apresentam uma das pesquisas mais conceituadas em se tratando de estimativa contínua da pressão sanguínea via sinal PPG. No trabalho proposto pelos autores foram utilizados dados da base *Multiparameter Intelligent Monitoring in Intensive Care* - MIMIC (Johnson et al., 2016) e uma estrutura em redes neurais para se realizar a predição dos parâmetros sistólicos e diastólicos.

Vale ressaltar que os autores não deixam explícito quais técnicas de filtros no sinal foram aplicadas para extração das 21 características. Contudo, os autores descrevem com atenção o modelo de rede neural definido, onde o modelo ótimo determinado pelo erro quadrático médio possui duas camadas ocultas com 35 e 20 neurônios cada, além de 2 neurônios de saída para os parâmetros de sístole e diástole. Foram gerados três modelos para fins de comparação de resultados de média e desvio padrão: modelo com regressão linear; modelo de rede com entrada de 4 atributos; e modelo de rede com entrada de 21 atributos. Alinhado às características extraídos do sinal, que incluem larguras sistólicas e diastólicas (Figura 3.2).

Dos valores separados para o experimento, 70% deles foram usados para treino, 15% para validação e 15% para teste. Os dados foram passados para o modelo neural, com destaque para o modelo com 21 neurônios de entradas, para o qual os autores relataram o erro absoluto médio (MAE) e desvio padrão de $3,80 \pm 3,46\text{mmHg}$ para sístole

e $2,21 \pm 2,09$ mmHg para diástole no conjunto de validação. Embora os resultados de erro tenham sido extremamente baixos, apenas um pequeno subconjunto não divulgado do banco de dados MIMIC foi utilizado, contabilizando mais de 150.000 ciclos do sinal PPG com sua correspondente pressão definida pelo sinal ABP.

Os valores dos testes para pressão sanguínea determinado pelos pontos de sístole e diástole foram submetidos às métricas de erro absoluto e erro relativo. Logo, os seguintes valores de $e_{abs}(Me; \sigma)$ e $e_{rel}(Me; \sigma)$ foram reportados para sístole e diástole, respectivamente: $e_{abs_sis}(3.80 \pm 3.46 \text{ mmHg}); e_{rel_sis}(3.48 \pm 3.19 \text{ mmHg})$ e $e_{abs_dias}(2.21 \pm 2.09 \text{ mmHg}); e_{rel_dias}(3.90 \pm 3.51 \text{ mmHg})$.

3.2 Estimativa da Pressão Sanguínea com Modelos Profundos de Aprendizagem de Máquina

Em relação ao método aplicado de aprendizagem de máquina com redes neurais profundas, Liang et al. (2018c) apresentam uma proposta para classificação e avaliação da pressão sanguínea através do sinal PPG, com a finalidade de detecção preventiva de doenças cardiovasculares em decorrência da hipertensão.

Para a realização dessa tarefa, foram realizadas as seguintes etapas: 1) Coleta de dados: sinais PPG e ABP de 121 indivíduos da base MIMIC III (Johnson et al., 2016); 2) Pré-processamento: em relação aos sinais utilizados de PPG e ABP. O pré-processamento foi realizado apenas no sinal PPG por meio do filtro de Chebyshev II com cortes de 0.5 – 10 Hz. O sinal ABP foi utilizado apenas para coleta dos parâmetros de sístole e diástole para determinar os níveis da pressão sanguínea para rotular os níveis de hipertensão. Ambos os sinais foram segmentados em 5 segundos; 3) Transformação do sinal: uma vez que o modelo utilizado para pré-treino (GoogleNet) aceita como entrada, dados em formato de imagem RGB, foi feita uma transformação no sinal PPG com aplicação da Transformação de Wavelet Contínuo (CWT) para criação de escalogramas, sendo empregada como uma forma de identificar baixas frequências; 4) Treinamento do modelo: o treinamento é feito com apoio da técnica de transferência de aprendizado do modelo GoogLeNet para o problema de classificação do sinal, recebendo entradas de imagens de dimensão (224 x 224 x 3) com amostras de sinais PPG convertidos na frequência de 125 Hz e janelas de 5 segundos de dados; 5) Classificação: nesta etapa, foi avaliada a capacidade do modelo gerado em estimar a pressão sanguínea, para classificar o nível de pressão em Normotenso (NT), Pré-hipertensão (PHT) e Hipertensão (HT) conforme a métrica $F_1 - Score$, responsável por reportar a média harmônica entre as classes.

Os resultados foram apresentados com a comparação de três experimentos: NT versus PHT, NT versus HT e (NT + PHT) versus HT. Para a métrica de F1 Score, o comparativo entre NT versus PHT resultou em 80,52% de precisão; NT versus HT resultou em 92,55% de precisão; (NT + PHT) versus HT resultou em 82,95% de precisão. Como o número pequena de dados, é possível que haja uma lacuna quando avaliado o modelo com dados ruidosos e em maior quantidade, tanto nos trabalhos apresentados por (KURYLYAK; LAMONACA; GRIMALDi, 2013) quanto em (LIANG et al., 2018c). É

possível notar que a base de dados UQVS utilizada nesse trabalho possui boa diversificação dos dados com 32 casos com duração entre 13 minutos e 5 horas, a ponto de tornar-se um desafio fazer a estimativa dos parâmetros da pressão sanguínea apenas com o sinal puro do PPG.

Em abordagens realizadas por Slapničar, Mlakar e Luštrek (2018) e Slapničar, Mlakar, Luštrek (2019), dos sistemas propostos, a etapa de pré-processamento contou com o maior nível de detalhes apresentados. Em ambos os trabalhos, as bases de dados aplicadas foram: MIMIC-III e *JSI-collected everyday-life*. A base MIMIC-III é uma base pública. A base JSI é uma base privada, extraída de dispositivo de pulso *Empatica E4* por meio de padrões de protocolos clínicos para coleta do sinal PPG, em sincronia com o dispositivo invasivo *Omron* utilizado para monitoramento da pressão sanguínea automática.

No trabalho de Slapničar, Mlakar e Luštrek (2018) foi proposto um sistema para estimar a pressão sanguínea continuamente, por meio da coleta do sinal PPG. A metodologia adotada pelos autores consiste em três etapas: coleta dos dados, pré-processamento e aplicação de algoritmos de aprendizagem de máquina para selecionar um subconjunto de características extraídas pré-selecionadas e repassá-las para um algoritmo de regressão.

Os autores deram destaque ao pré-processamento, sendo ele dividido em três fases. A primeira consiste na limpeza dos dados num critério clínico sugerido por Xing e Sun (2016) nos sinais de PPG e ABP, a qual exclui segmentos de ondas do sinal com valores sistólicos acima de 250 mmHg e menor que 80 mmHg, e diastólicos acima de 150 mmHg e menor que 40 mmHg. A segunda etapa consiste em detectar picos e ciclos do sinal PPG, pelo filtro de frequência passa-baixa (LPD), para transformar o sinal a fim de acentuar pontos de sístole e diástole, facilitando a detecção dos picos, bem como a determinação de seu ciclo.

A etapa final do pré-processamento corresponde a análise de autocorrelação *Dynamic Time Warping* (DTW), onde uma cópia do sinal PPG na janela atual é retirada para substituir de cada amostra um determinado comprimento do sinal que contenha pelo menos dois batimentos cardíacos. Quando a cópia é deslocada pelo número de amostras correspondente a exatamente um ciclo, a autocorrelação atinge seu primeiro pico de um número L de amostras.

É importante destacar que esse processo foi realizado para que fossem extraídas características (temporal, frequência e análise de complexidade) de amostras com ciclos bem definidos e menor variação de impureza. Uma vez que características do sinal PPG foram extraídas, 10% das amostras escolhidas de forma aleatória foram submetidas ao algoritmo de seleção de características *RReliefF*. Este procedimento de escolha aleatória foi repetido 10 vezes.

Na fase de experimentação e geração dos modelos foram implementadas duas configurações para validação dos resultados, *k-fold cross validation* com 5 subconjuntos e *Leave One Subject Out* (LOSO) com sub amostras de 500 ciclos por paciente devido a sua complexidade computacional. A experimentação com *k-fold cross validation* ($k = 5$)

foi precedida da sincronização dos segmentos PPG com seus respectivos rótulos extraídos do ABP, e divisão do conjunto de dados em treino e teste com 80% e 20% dos dados, respectivamente. Em vista disso, esta técnica de avaliação do modelo não garante que a base seja dividida por indivíduos, gerando enviesamento em sua validação uma vez que pode haver dados de um mesmo paciente no conjunto de treino e validação. Logo, a fim de evitar o viés do modelo foi empregada a avaliação LOSO. Esse tipo de configuração permite que o treino de um modelo seja feito sobre todos os pacientes, exceto o paciente em observação no qual é separado para validação. Percebeu-se que mesmo implementando a configuração LOSO, os autores optaram por adicionar instâncias do paciente selecionado para validação ao treinamento (chegando a adicionar até 50%), utilizando-se da justificativa da singularidade do sinal PPG em cada indivíduo.

Os autores implementaram modelos de regressão com variáveis *dummy*, floresta aleatória com todas as características e floresta aleatória com características selecionadas via seletor de características *RReliefF*, a qual os melhores resultados foram obtidos pelo último modelo, com os seguintes valores da métrica MAE para sístole e diástole com $Me \pm \sigma$. O MAE mais baixo alcançada para o conjunto de dados hospitalares MIMIC-III na validação 5-fold foi de $4,90 \pm 6,59$ mmHg para sístole e $2,21 \pm 3,70$ mmHg para diástole.

Os mesmos modelos foram submetidos a testes com o conjunto de dados JSI. O menor valor alcançado nas avaliações foi de $7,87 \pm 7,47$ mmHg para sístole e $3,84 \pm 3,63$ mmHg para diástole. Nas configurações LOSO com 50% de enviesamento, os resultados alcançados com a base MIMIC-III foram de 4.47 ± 5.85 mmHg para sístole e 2.02 ± 2.94 mmHg para diástole. De acordo com a base JSI, esta configuração atingiu resultado de 8.57 ± 7.93 mmHg para SBP e 4.42 ± 3.61 mmHg para diástole.

Os resultados da validação cruzada atingiram valores menores que os experimentos realizados pela validação LOSO, e em suma, os autores constataram que a divisão dos dados pela validação cruzada pode conter muito mais enviesamento dos dados devido seu arranjo aleatório, o que não garante um modelo que generalize para dados completamente novos.

É importante ressaltar que, dentre os trabalhos da literatura, a pesquisa conduzida pelos autores Slapničar, Mlakar, Luštrek (2019) foi a que apresentou maiores detalhes de implementação e um dos melhores resultados diante da variação de dados utilizadas pela base de dados MIMIC-III. Buscando manter uma referência para o modelo proposto e treinado, foram considerados apenas sinais puros PPG e ABP.

Até alcançar a fase de aplicação do modelo de predição com redes neurais profundas, a metodologia dos autores abordou a limpeza dos dados para eliminar dados sensoriais ruidosos dos sinais selecionados, o que resultou numa duração de tempo registrado de no mínimo 10 minutos em 510 pacientes habilitados. As técnicas de pré-processamento empregadas correspondem ao processo de normalização z-score, corte de banda com Butterworth (atenuar os ruídos produzidos por movimentos corporais como a respiração) e Hampel (eliminar pontos de sinais com anomalias), que podem ser acompanhadas na Figura 3.3.

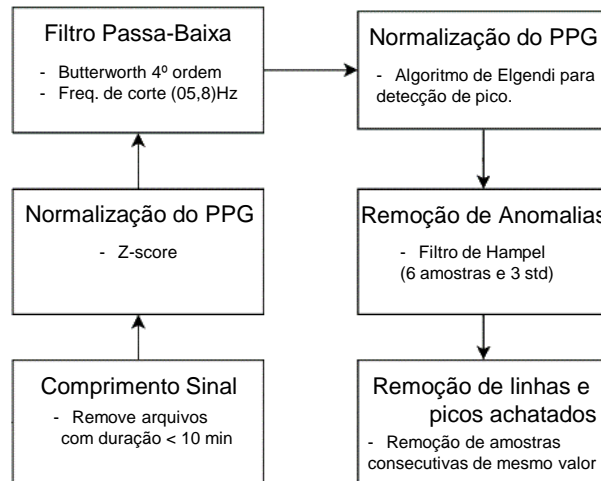


Figura 3.3 Metodologia utilizada. Fonte: Adaptada de (SLAPNIČAR, MLAKAR, LUŠTREK, 2019).

Ao modelo profundo com camadas residuais foram designadas três entradas para a estrutura a qual contém o sinal PPG puro, a primeira derivativa (PPG') e a segunda derivativa (PPG''). A janela de sinal repassado corresponde a 5 segundos, ou seja, com o comprimento de sinais de 625 amostras, dado que a base MIMIC III possui frequência de 125Hz. A Figura 3.4 apresenta a entrada da arquitetura de rede proposta pelos autores. Nela, existem três neurônios de entrada que recebem as 625 amostras do sinal PPG e suas derivativas separada em cada canal. Para cada canal de sinal recebido, os dados são enviados a blocos residuais e camadas espectro-temporal a fim de transformar o sinal captado em espectrogramas e aumentar a percepção do modelo em relação ao problema.




Figura 3.4 Camadas de entrada do modelo proposto pelos autores. Fonte: (SLAPNIČAR; MLAKAR; LUŠTREK, 2019).

Conforme os autores elencaram, foram realizados testes com modelos de ResNet, Regressão e Floresta aleatória. Além disso, para cada modelo foi atribuída a validação LOSO (com e sem personalização) com extrações de características temporal e frequência. O LOSO aplicado consiste em 20% dos dados de cada indivíduo que seria avaliado no teste, adicionados ao conjunto de treinamento. Essa abordagem com o método de janela deslizante de 5 segundos demonstrou ser mais efetiva frente a abordagem com detecção de picos e extração de características. Dentre os modelos gerados, o modelo de ResNet personalizado apresentou os melhores resultados relacionados à métrica do erro médio absoluto, onde foram encontrados valores para sístole e diástole de 9.43mmHg e 6.88mmHg, respectivamente.

3.3 Discussão

Os trabalhos selecionados possuem como objetivo comum, o monitoramento contínuo da pressão sanguínea por meio de dispositivos não invasivos. Neste sentido, o método comumente utilizado se baseia na técnica de Oximetria de Pulso que indica o volume sanguíneo circulado em determinada área do corpo. Para a coleta deste volume é utilizado sinal fotoelétrico denominado PPG. É evidente que o sinal PPG sozinho não possui uma abordagem direta para extração de informações sobre a pressão sanguínea arterial, definida pelo sinal ABP. Por se tratar de biosinais que monitoram a atividade sanguínea, é possível fazer uma relação entre estes dois sinais. Logo, é possível observar o esforço nos trabalhos descritos em alcançar um modelo de aprendizagem de máquina que consiga estimar a pressão sanguínea com base no PPG.

Embora os trabalhos tenham alcançados resultados dentro da estimativa aceitável pela AAMI para os valores de sístole e diástole, é possível notar que existe uma manipulação nos conjuntos destinados ao treinamento destes modelos, no qual adicionam uma parcela de dados atribuídos ao teste no conjunto de treino, de modo a enviar os modelos em suas validações. Essa abordagem pode estar sendo considerada devido à natureza singular do sinal PPG. Ainda assim, essa metodologia pode levar a conclusões precipitadas quanto a capacidade de generalização desses modelos. A Tabela 3.1 apresenta uma sumarização dos trabalhos supracitados, com a apresentação dos sinais utilizados, a técnica de processamento utilizada (quando apresentada), a base de dados, os algoritmos experimentos, bem como seus resultados dos modelos que obtiveram menores erros.

Tabela 3.1 Sumarização dos resultados encontrados pelos trabalhos relacionados.

Trabalho	Sinais	Pré-processamento	Base de Dados	Algoritmo	Métrica (sístole; diástole)
Xie et al. (2018)	PPG, ABP	Filtro Passa baixa	UQVS	Regressão Linear, Rede Neural, Árvore de Decisão, Método de <i>Bagging</i> e Floresta Aleatória.	Média Absoluta: (4.21mmHg; 3.24 mmHg) Desvio Padrão: (\pm 7.59mmHg; \pm 5.39 mmHg).
Zhang e Feng (2017)	PPG, ABP	Filtro passa baixa	UQVS	Regressão Linear, Rede Neural e Máquina de Vetores de Suporte.	Média Absoluta: (11,641mmHg; 7,617mmHg) Desvio Padrão: (\pm 8,2022 mmHg; \pm 6,7837 mmHg)

Kurylyak, Lamonaca, Grimaldi (2013)	ABP; PPG	Não especificado	MIMIC	Regressão Linear, Redes Neurais Artificiais (4 entradas), Redes Neurais Artificiais (21 entradas).	Média Absoluta: (3,80 mmHg; 2,21 mmHg) Desvio Padrão: (\pm 3,46 mmHg; \pm 2,09 mmHg)
Liang et al. (2018c)	ABP; PPG	Chebyshev II (PPG); Extração dos pontos de sístole e diástole (ABP)	MIMIC	Modelo Pré-treinado GoogleNet	F1-Score:
Slapničar, Luštrek, Marinko (2018)	PPG, ABP	Extração de características temporal, frequência e complexidade do sinal	MIMIC e JSI	Dummy, Linear, Ensamble (todas as caract.), Ensamble (caract. Selcionadas RReliefF)	Média absoluta (MIMIC - 5-fold): (4.90 mmHg, 2,21 mmHg) Desvio Padrão (MIMIC- 5-fold): (\pm 6,9 mmHg, \pm 3,70 mmHg) Média absoluta (JSI - 5-fold): (7,87 mmHg, 3,84 mmHg) Desvio Padrão (JSI- 5-fold): (\pm 7,47 mmHg, \pm 3,63 mmHg)
Slapničar, Luštrek, Marinko (2019)	PPG, ABP	Normalização z-score, Butterworth (0.5Hz, 8Hz), Hampel	MIMIC	Dummy Floresta Aleatória ResNet Espectro-Temporal	Média absoluta (9.43mmHg, 6.88mmHg)

Diferente dos trabalhos relacionados, a proposta deste trabalho visa gerar um modelo de aprendizagem baseado em redes neurais que receba como entrada apenas o sinal de SpO₂, sem a utilização de dados em *handcraft* ou dados transformados sobre o sinal puro como forma de enriquecer a entrada do modelo neural, como por exemplo, o uso de derivativas do sinal. Além disso, é possível observar nestes trabalhos, que a forma

de separação do conjunto de dados para formação dos subconjuntos destinado a treino, validação e teste, possuem enviesamento no subconjunto de treino, uma vez que são adicionados a este subconjunto dados de pacientes contidos nos subconjuntos de teste e validação. Como proposta de trabalho, a base de dados utilizada no protocolo experimental foi totalmente dividida entre dados de pacientes para treinamento e dados de pacientes destinada a teste e validação.

CAPÍTULO

4

MoNePS

Este capítulo apresenta o método proposto MoNePS (Modelo Neural para Pressão Sanguínea) para realizar a predição de sístole e diástole via sinal fotoelétrico PPG para posterior classificação. Ao longo deste capítulo, será apresentada a visão geral do método proposto com os passos percorridos até a geração da solução pretendida. As seções subsequentes apresentam em detalhe cada elemento arquitetural.

4.1 Visão Geral

Esta seção apresenta o método MoNePS (Modelo Neural para Pressão Sanguínea) proposto para realizar a estimativa de sístole e diástole, com a finalidade de identificar momentos de hipertensão, conforme uma sequência de amostras do sinal PPG. Para encontrar a relação comportamental entre a pressão arterial e os dados coletados pelo sensor PPG deve-se implementar uma técnica que permita a identificação dessas características não lineares. Portanto, o MoNePS tem como finalidade apresentar essas correlações e sua abordagem é destacada por meio de uma visão geral de seu método na Figura 4.1.

O método proposto é composto por 4 etapas ilustrado pela Figura 4.1, onde possui: I) aquisição de Dados; II) pré-processamento, local em que são aplicados filtros para atenuação de ruídos, normalização do sinal PPG, segmentação de sinais ABP e PPG e, de acordo com cada segmentação correlacionada, a extração dos pontos médios dos valores de sístole e diástole; III) geração do modelo neural profundo que tem como principal característica a dilatação entre camadas convolucionais e; IV) classificação, que consiste em identificar a classe de pressão sanguínea que correspondem aos valores preditos.

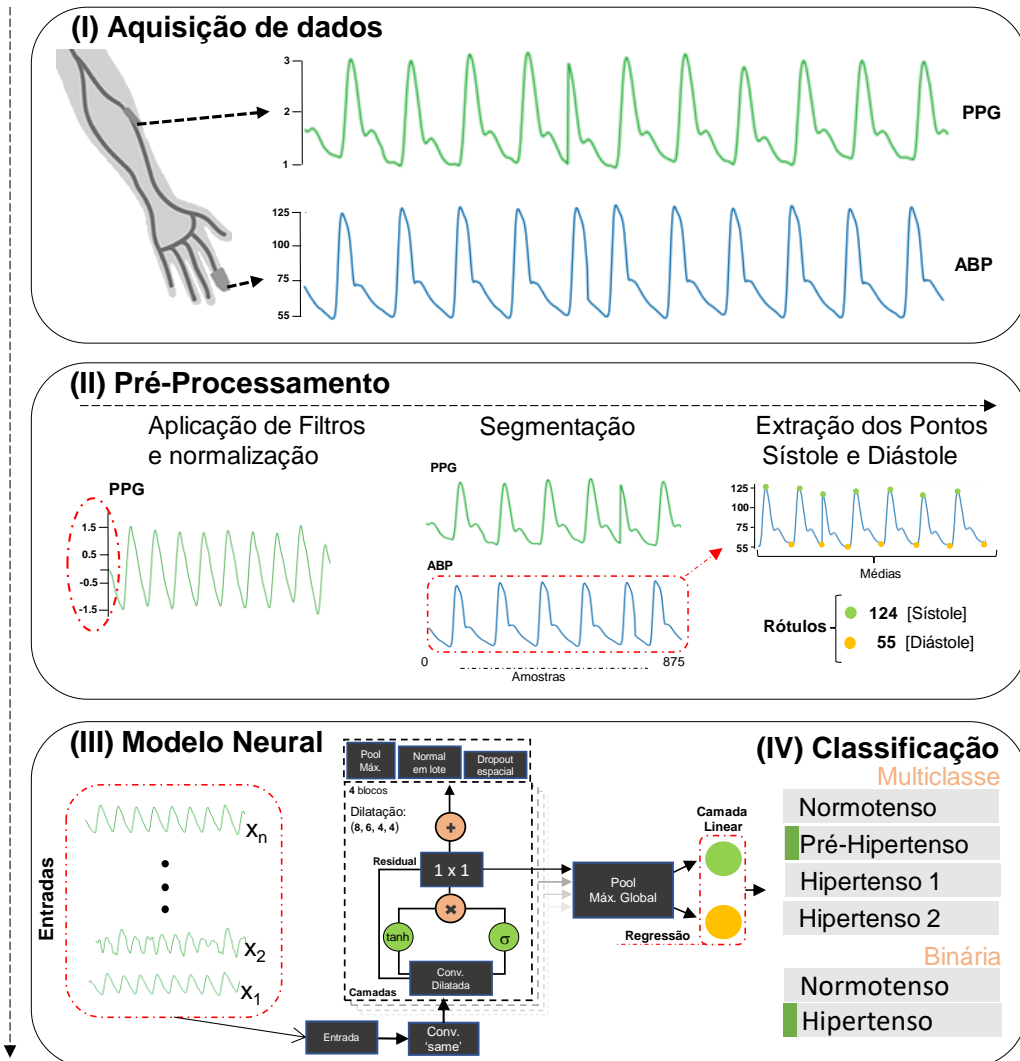


Figura 4.1 Visão geral sobre o método proposto. (I) Sinais de coleta de PPG e ABP; (II) Aplicação das operações de filtros, normalização, segmentação e extração dos pontos de sístole e diástole dos segmentos de ABP; (III) Modelo Neural Convolutivo com Técnica de Dilatação com duas saídas referente aos pontos de sístole e diástole; (IV) Classificação Multiclasse e Binária a partir dos pontos preditos pelo MoNePS. Fonte: próprio autor.

4.2 Aquisição dos dados

Os dados de entrada correspondem a dados de séries temporais puros, vetoriais ou 1D, como pode ser observado na primeira etapa apresentada na Figura 4.1. Ao longo do levantamento sobre as abordagens relacionadas, foi observado que a maioria dos trabalhos utiliza extratores manuais de características temporais e de frequência sobre o sinal PPG para encaminhar esses dados ao modelo de aprendizagem adotado. Uma vez que os modelos de aprendizagem profunda extraem automaticamente essas características, a obtenção dos sinais torna-se suficiente para conclusão desta etapa.

Como descrito na figura 4.1, os dados de aquisição correspondem aos sinais de PPG e ABP devido à correlação de suas características temporais, de frequência e principalmente pelo sinal ABP carregar informações intrínsecas como os pontos de sístole

e diástole responsáveis por determinar a pressão sanguínea a qual podem ser extraídos no passo seguinte deste método.

4.3 Pré-processamento

A etapa de pré-processamento tem como objetivo diminuir ruídos que podem ser passados ao modelo de aprendizagem durante o seu treinamento. Neste sentido, no trabalho proposto foram realizadas as seguintes subetapas: normalizar o sinal PPG, segmentar os sinais de ABP e PPG de forma sincronizada por janela deslizante conforme o comprimento de entrada do MoNePS, e extrair as características de sístole e diástole com as camadas de convolução empregadas ao modelo neural.

Em relação aos dados PPG, a adoção da técnica de filtro para suavização em sua forma de onda, nesta pesquisa, restringiu-se ao uso da técnica de *ButterWorth* aplicada a um filtro de fase zero *FiltFilt* a fim de não distorcer o comportamento de tendência do sinal aos quais são exploradas em pesquisas com biossinais por permitir o corte de ruídos em baixa e alta frequência e atenuação de valores distorcidos. A esse filtro foi aplicada a 4ª ordem e seus cortes de baixa e alta frequência foram configurados em 0,5Hz e 8Hz, respectivamente. Em contrapartida, os dados do sinal ABP, por se tratar de um formato de onda sensível obtido de maneira invasiva, é preferível que se tenham os dados puros para extração dos pontos de sístole e diástole.

Uma vez filtrados os sinais PPG, foi realizada a normalização do mesmo com aplicação da equação de escala de média zero e desvio padrão 1 (Equação 4.2) a fim de diminuir possíveis distorções do sinal contidos nas amostras contidas nos segmentos por conta da diminuição de sua escala e destacar pontos onde possam estar ocorrendo eventos diferentes dos encontrados em casos de pressão normal, como os casos de hipertensão. Nas equações supracitadas, χ_i representa o segmento em questão, local em que \bar{x}_i representa o valor médio, n o número de valores (amostras), σ o desvio padrão e $X_{n(i)}$ a atribuição para o segmento modificado.

$$\sigma = \sqrt{\frac{\sum(x_i - \bar{x}_i)^2}{n}} \quad (4.1)$$

$$X_{n(i)} = \frac{\chi_i - \bar{x}_i}{\sigma} \quad (4.2)$$

Após a obtenção dos dados, uma tarefa importante a realizar quando se utiliza algoritmos de aprendizagem de máquina é determinar a sua dimensão de entrada para o modelo pretendido. Dados de biossinais comumente terão dimensões vetoriais e seu comprimento determinará a quantidade de dados que alimenta o modelo. Portanto, uma vez que as bases podem conter longas amostras que podem dificultar o aprendizado do modelo, é comum a utilização de sub amostras desses dados contidos em segmentos oriundos de técnicas de janelamento. A técnica de janelamento pode conter elemento de sobreposição aplicada como forma de preservar informações entre janelas e aumentar o número de observações, conforme apresentado na Figura 4.2.




Figura 4.2 Segmentação com janela deslizante e sobreposição de 50%. Fonte: próprio autor.

Ambos os sinais ABP e PPG passam pelo processo de segmentação conforme apresentado na Figura 4.2. Contudo, apenas o sinal ABP é submetido à etapa de extração de picos de sístole e diástole. Para que seja retirado o valor alvo de sístole e diástole do segmento, é realizado um cálculo simples de média entre os pontos detectados no segmento correspondente à janela do segmento PPG.

Existem duas observações sobre esse procedimento para modelos de aprendizagem profundos de máquina. A perspectiva positiva sobre a aplicação de filtros se dá pela possível melhora da morfologia do sinal, com cortes passa baixa e passa alta fazendo com que sinais anômalos não prejudiquem o aprendizado do modelo. Em contrapartida, a eliminação dos ruídos pode interferir de forma negativa na variação de dados conforme o campo de observação no processo de aprendizagem do modelo.

4.4 Modelo

O modelo neural profundo é responsável por gerar as estimativas dos valores de sístole e diástole contidos em sinais ABP a partir de bio-sinais de PPG. Para isso, foram utilizados modelos com abordagens em extração de características advindas de técnicas de redes neurais de convolução (LECUN et. al, 1999) de dimensão vetorial ou 1D.

A extração de características pode ser realizada de forma manual ou automática. Na extração manual de características são aplicadas funções estatísticas em séries temporais que atuam nos domínios de frequência e tempo. Em contrapartida, camadas convolucionais para redes neurais, como replicadores do funcionamento da transformada de *Fourier*, conseguem efetuar a extração automática dessas características da frequência em multidimensões, de forma que em cada dimensão possam ser destacados os valores mais representativos dos dados. Conforme a Equação 4.3, a convolução é definida por duas funções de uma variável contínua α , onde uma função se desloca sobre a outra por

meio da integração, no qual o sinal negativo representa a inversão de α , e x a variável que será integrada (GONZALEZ, 2008).

$$f(x) * g(t) = \int_{-\infty}^{\infty} f(\alpha)g(x - \alpha) d\alpha \quad (4.3)$$

Dentro dessa abordagem, foi incorporada a este modelo a técnica de dilatação, capaz de armazenar ao longo do tempo características em subamostras espaciais referente às camadas de convolução. O mecanismo de dilatação pode ser utilizado para aumentar o campo receptivo sem aumentar o custo computacional (van den Oord et. al, 2016). Além disso, em uma convolução dilatada, seus filtros são aplicados a áreas maiores que seus comprimentos, saltando valores conforme seu passo de dilatação. Esse comportamento permite que uma rede convolucional dilatada opere em escalas maiores que uma convolucional comum ao qual possui semelhança por meio dos *poolings* ou *strides* (passos que o filtro fará para percorrer campo receptivo).

A principal diferença entre as convoluções dilatadas e convoluções comuns encontra-se nas dimensões de entrada e saída. Nas redes dilatadas estes parâmetros são os mesmos, enquanto nas convoluções comuns acontece a redução dessa dimensionalidade ao passo em que a rede neural cresce. Por meio da Figura 4.3 é possível observar esse comportamento da rede pelas dilatações D1, D2, D3 e D4 para gerar uma saída S ligada a um bloco com respectivas camadas de convolução. A dilatação ocorre da seguinte maneira: um bloco de convolução contém camadas criadas com espaçamentos entre seus neurônios de acordo com o nível de dilatação atribuído. Por exemplo, a dilatação D1 tem distanciamento 1 entre seus neurônios. Em seguida, os dados referentes ao que foi extraído pelo D1 (nível 0) também são vistos pelo nível D2 (nível 1), na qual são extraídas informações mais esparsas, tendo um salto 2 entre os neurônios. O próximo nível possui dilatação 4 ou D4, portanto, um esparsamento 4 entre os neurônios. Este comportamento exponencial da dilatação é replicado para os demais níveis de dilatação, permitindo que sejam extraídas características diversas na saída do bloco para a regressão dos pontos de sístole e diástole.

O modelo neural utilizado no método proposto é apresentado na Figura 4.3 e é composto por: 4 blocos de 8,6,4,4 de dilatações com respectivos filtros receptivos de 32,32,64,64; *Pooling* Máximo sobre núcleos de dimensão vetorial de comprimento 2; Normalização; *Dropout* Espacial de 50%; Máximo *Pooling Global*; camadas Densas de 1 neurônio na saída. Antes de conectar o bloco de dilatação à camada de Máximo *Pooling Global*, o bloco de dilatação é ligado às camadas de extração de mapas de características compostas apresentados ao topo da imagem. A saída do modelo neural é composta por dois neurônios densos que com saída linear para realização da predição. O MoNePS contou com 246,690 parâmetros finais.

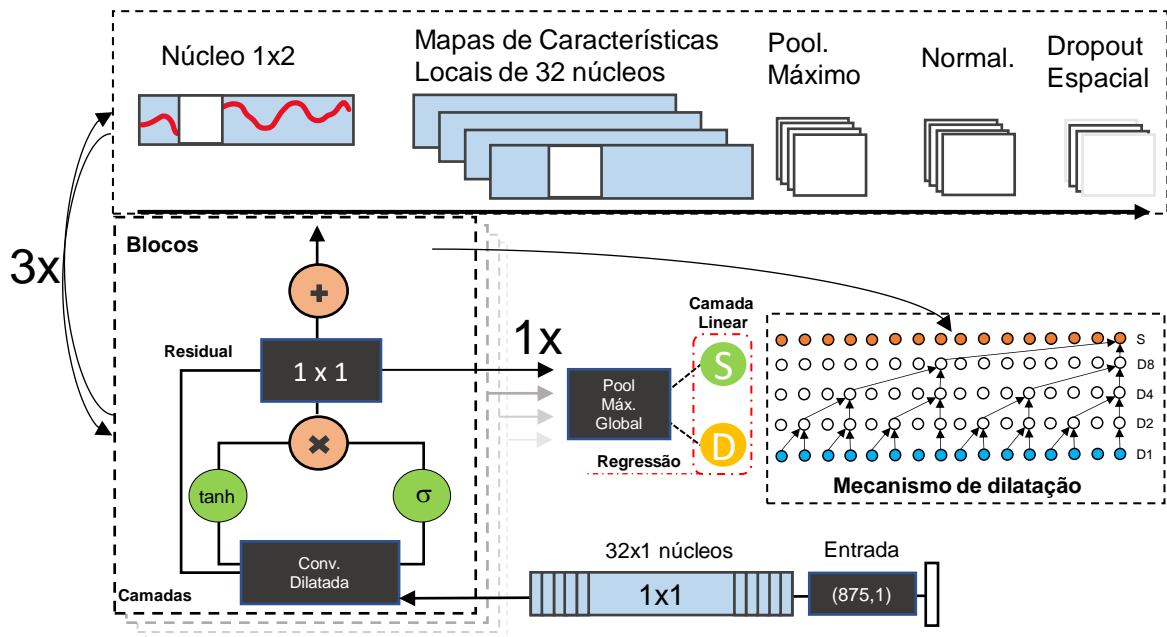


Figura 4.3 Arquitetura do modelo neural proposto. Fonte: próprio autor.

As previsões realizadas pelo MoNePS serão fundamentais para avaliar o comportamento do modelo frente às classes de intervalo de sístole e diástole que os valores de saída estão contidos (Tabela 2.1). Portanto, são avaliados os cenários multiclasse (Normotenso, Pré-Hipertenso, Hipertenso Grau 1 e Hipertenso Grau 2) e binário (Hipertenso e Normotenso) para avaliar a confiabilidade das regressões.

Durante os experimentos foi observado que a maioria dos modelos testados apresentava um valor baixo para métrica MAE. No entanto, quando os valores preditos são levados para uma tabela que identifica a classe de pressão sanguínea aos valores preditos, foi possível notar que os modelos apresentados na literatura priorizam à métrica de média absoluta e não reportam às métricas de classificação, uma vez que são priorizados apenas experimentos de regressão da pressão sanguínea. Portanto, ao encaminhar os valores preditos às métricas de classificação como Acurácia, Precisão, Sensibilidade e F₁-Score, é possível notar o quanto o modelo de aprendizagem distingue suas classes conforme os dados de PPG repassados.

Experimentos e Resultados

Neste capítulo são apresentados os experimentos realizados para avaliar o método MoNePS na predição dos pontos de sístole e diástoles a partir de sinais PPG. O capítulo apresenta a descrição do protocolo experimental, incluindo a descrição da base de dados utilizada nos experimentos, métricas de avaliação, configurações de ambientes, bem como os hiperparâmetros definidos para o modelo regressor. Os resultados dos experimentos são separados em três etapas para o modelo neural analisado: (i) avaliação da regressão dos pontos de sístole e diástoles; (ii) a partir da regressão, é avaliada a capacidade do modelo em diferenciar as classes relacionados a tensão da pressão sanguínea e; (iii) ao considerar apenas duas classes, analisar o grau de confiança do modelo neural para as classes normotenso e hipertenso. Por fim, são descritos os resultados experimentais junto a análises e conclusões obtidas a partir da comparação do cenário descrito a seguir.

5.1 Protocolo Experimental

As predições de sístole e diástole são submetidas à tabela de definição de hipertensão, segundo a Sociedade Internacional de Hipertensão (UNGER, 2020), para correlacionar os valores referentes à classe da pressão sanguínea arterial. Com base no conjunto de dados captados, os experimentos foram agrupados em três cenários:

- Modelo Generalista (MG). Com um modelo generalista, o objetivo é alcançar a predição dos valores de sístole e diástole com dados não antes atribuídos ao modelo durante a fase de treino;
- Modelo Especialista com retreino (MEMG). Este tipo de modelo considera a utilização do modelo generalista como base para aplicar um retreino com parte dos dados de um determinado usuário que será avaliado na fase de teste;
- Modelo Especialista sem retreino (ME). Por outro lado, um modelo especialista que não considera modelo com seus pesos pré-treinados, parte de um ponto totalmente aleatório nos seus pesos;

Em cada cenário, são utilizados dois métodos, o MoNePS e o modelo espectro-temporal de (SLAPNIČAR; MLAKAR; LUŠTREK, 2019). A ênfase nesses dois modelos é feita pela seguinte avaliação: o MoNePS tem como característica blocos de convolução dilatadas por ter como base a WaveNet, além de receber como entrada apenas um vetor que representa o segmento do sinal PPG. O modelo Espectro-Temporal do *baseline*, além de receber três vetores como entrada (PPG, PPG-I e PPG-II) convertidos pelo próprio modelo internamente em imagens de espectro do domínio do tempo, o que aumenta a complexidade e tempo de processamento quando comparamos ao modelo desenvolvido neste trabalho.

5.1.1 Conjunto de Dados

Dentre diversas bases comuns expostas pela literatura que contém dados de PPG ou ABP (LIU; GÖRGES; JENKINS, 2012; LIAG et al., 2018), este trabalho ficou limitado a bases com sinais sincronizados de PPG e ABP. Desta forma, a base MIMIC-III foi utilizada por possuir tanto os dados de PPG quanto ABP.

Devido ao tamanho total da base e tempo de processamento de todos os dados tornarem a execução dos experimentos muito custosas, foi selecionado uma partição da base de 1629 usuários. Destes, janelas de amostras do ABP que continuam valores de sístole e diástole fora do respectivo intervalo de 75 a 165 mmHg e 40 a 80 mmHg foram descartados para atenuar *outliers* e permanecer no cenário apenas de Hipertensão.

Os sinais ABP e PPG elencados para os experimentos possuem taxa de amostragem de 125Hz com resolução podendo variar entre, 8, 10 ou 12 bits. As amostras foram segmentadas em janelas de 7 segundos totalizando 875 pontos por segmentos. Estes foram estruturados em formato vetorial de (875,1) para alimentar os modelos neurais. A Figura 5.2 ilustra o segmento do sinal PPG de entrada do modelo.




Figura 5.1 Amostras de um segmento de 7 segundos do sinal PPG. Fonte: próprio autor.

5.1.2 Método Baseline

Como forma de comparação dos resultados obtidos pelo método MoNePS, foi utilizado o método Espectro-Temporal com três entradas vetoriais de 7 segundos cada. As entradas consistem no dado do PPG, o qual é submetido a operação de derivação do sinal, conforme Equação 5.1.

$$t = [0, 1 \dots |ppg|]$$

$$PPG' = \frac{[ppg_2 - ppg_1]}{[t_2 - t_1]}, \quad (5.1)$$

onde t representa a série temporal com o comprimento do sinal $|ppg|$ no tempo. Logo, para se alcançar a derivação do sinal é necessário dividir a diferença do sinal no tempo n por $n - 1$ em relação a diferença do vetor temporal no tempo n por $n - 1$. Esse procedimento é realizado para encontrar a velocidade (PPG-I) e aceleração do sinal (PPG-II). A Figura 5.1 ilustra o comportamento do sinal resultante do processo de derivação.




Figura 5.2 Amostras do sinal PPG com as respectivas derivativas de velocidade (PPG') e aceleração (PPG''). Fonte: próprio autor.

O modelo Espectro-Temporal possui uma arquitetura de 5 blocos residuais que extraem pelas camadas convolucionais informações temporais para cada canal da rede, antes de serem concatenados junto às camadas espectro-temporais. Por sua vez, as camadas espectro-temporais foram utilizadas para aumentar o nível de informação repassada a rede, com a adição de espectrogramas, extraídos pela aplicação da transformada curta de Fourier (STFT), ao qual são repassados às camadas de unidades recorrentes (GRU) para captar às mudanças temporais. Por fim, a camada recorrente se conecta a camadas densas, que levam à saída do modelo com os valores de sístole e diástole. O modelo ao todo é constituído por 790.043 parâmetros.

5.1.3 Estratégia de Validação

Nos experimentos, o esquema de validação adotado foi o *holdout*, considerando a separação dos subconjuntos em treino, teste e validação. Nesse contexto, foram avaliados dois particionamentos:

- O primeiro diz respeito a divisão dos subconjuntos por indivíduos para o treinamento do modelo generalista, de modo a não ter vazamento de dados de subconjuntos de teste e validação ao subconjunto de treino. Logo, o subconjunto de treinamento contou com dados de 977 indivíduos e os subconjuntos de teste e validação contaram com 326 indivíduos cada. Foram extraídos segmentos aleatórios de cada indivíduo sobre cada subconjunto, totalizando 1.000.000 de segmentos de 7 segundos para treino e 250.000 segmentos de teste e validação, respectivamente.

- O segundo particionamento levou em consideração a divisão de dados para modelos especialistas. Neste cenário de divisão de dados, foram gerados modelos que se adequaram a padrões de determinados sujeitos. Foram utilizados 80% de dados de uma pessoa em sua fase de treino, 10% para validação e os outros 10% no teste. Este tipo de modelo se justifica pela frequência peculiar do sinal biológico que cada pessoa emite, o que dificulta para um modelo distinguir as categorias de hipertensão das pessoas, conforme apresentados na seção de resultados.

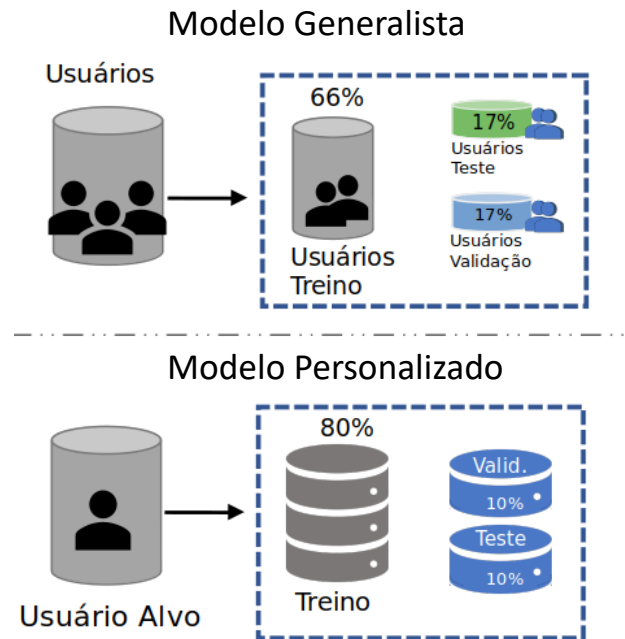


Figura 5.3 Esquema de separação da base para os modelos generalistas e especialistas. Fonte: próprio autor.

5.1.4 Métrica de Avaliação

O treinamento de um modelo de rede neural envolve funções de perda e métrica de validação que podem ser definidas conforme o objetivo do modelo. Para garantir o reajuste de seus pesos, um modelo neural conta com duas fases, *forward* (ida) e *backpropagation* (retro propagação). Em síntese, à fase de ida são aplicadas várias combinações lineares e funções de ativação dos neurônios até a sua última camada. Por sua vez, o erro gerado na última camada conforme a função aplicada, é retro propagado por toda a rede para ajustes de seus pesos até a camada inicial.

Conforme a finalidade para qual o modelo neural foi gerado, a função de ativação da última camada pode gerar uma regressão ou uma classificação. A regressão pode ser avaliada por funções de erro médio quadrático ou erro médio absoluto em relação ao número real predito. Em contrapartida, um classificador contém saídas categóricas, ou seja, existem mais de uma saída de números inteiros, e cada saída reflete por conta da entropia cruzada um reajuste de aprendizado ao modelo.

Uma vez que os experimentos consistem em realizar a predição de valores reais relacionados aos pontos de sístole e diástole, as métricas de avaliação adotadas para o

modelo foram duas: para os dados de treino do modelo foi adotada a métrica de erro médio quadrático (do inglês, *Mean Square Error* - MSE) (Equação 5.2) e para avaliar os dados de validação foi utilizado o erro médio absoluto (do inglês, *Mean Absolute Error* - MAE) (Equação 5.3).

$$MSE = \frac{\sum(y_i - \hat{y}_i)^2}{n} \quad (5.2)$$

$$MAE = \frac{1}{n} \sum |y - \hat{y}| \quad (5.3)$$

A Figura 5.4 ilustra o comportamento de cada métrica conforme o ajuste do modelo. Como é possível notar na Figura 5.4 em questão o erro gerado pela média absoluta é dado pela distância de cada ponto em relação à reta dividido pelo número de pontos. Como consequência, o MSE é mais rigoroso com pontos que se distanciam da reta. Na prática, quanto um ponto está muito do modelo (representado pela reta) ele penaliza mais o aprendizado do mesmo, o que justifica um cuidado no tratamento dos dados, para que não se atenuem os pontos faltantes ou *outliers* da base.

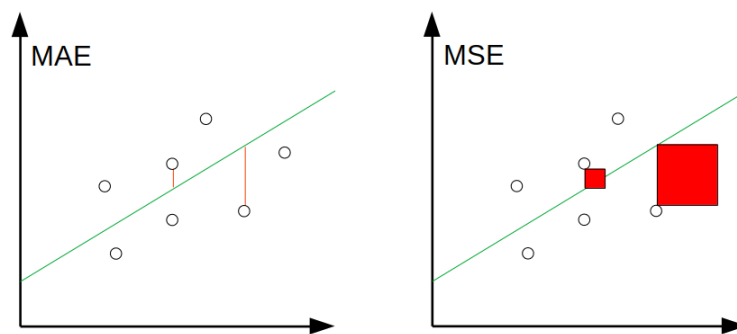


Figura 5.4 Amostras do sinal PPG com as respectivas derivativas de velocidade (PPG') e aceleração (PPG''). Fonte: próprio autor.

Neste trabalho, foram utilizados gráficos no estilo de diagrama de caixas (*Boxplot*) a fim de entender a posição, dispersão, simetria e valores discrepantes (*outliers*) dos conjuntos de pontos reais e preditos de sístole e diástole dos valores reais sob os segmentos de 7 segundos de sinal PPG. Esses gráficos de caixa nos ajudam a visualizar de forma quantitativa a dispersão dos dados rotulares passados aos modelos a partir do conjunto de teste, e como os modelos se aproximam desta distribuição com seus valores preditos correspondentes. A Figura 5.5 apresenta um exemplo deste tipo de gráfico, onde:

- *Outlier*: valores discrepantes;
- Posição: linha central do retângulo ou mediana;
- Dispersão: representada pelo intervalo entre o terceiro e primeiro quartil;
- Simetria: quando a linha do retângulo se encontra na metade do retângulo;




Figura 5.5 Exemplo de gráfico Boxplot. Fonte: próprio autor.

Uma vez que os dados preditos serão parâmetros para classificação da hipertensão segundo a Associação Internacional de Hipertensão (UNGER, 2020), as métricas de classificação serão de suma importância para entendermos se os modelos de fato correlacionam os seus rótulos reais com seus valores preditos por suas regressões, ou se os modelos apenas tendem a apontar para uma média. Logo, para avaliação deste método foram utilizadas as métricas de acurácia, sensibilidade, precisão e a medida F (F-score ou F1-Score) representadas nas equações apresentadas na Tabela 5.2. Essas métricas derivam da matriz de confusão, frequentemente utilizada para apresentar os valores acertados pelo modelo como verdadeiros positivos (VP) - quando detecta a classe hipertenso corretamente e verdadeiros negativos (VN) - quando detecta um caso Normotenso corretamente, além de apontar onde o modelo pode estar se confundindo ao tentar a classificação pelos falsos positivos (FP) - quando detecta um caso Normotenso como Hipertenso e falsos negativos (FN) - quando detecta um caso Hipertenso como Normotenso. Considere a matriz de confusão apresentado na Tabela 5.1.

Tabela 5.1 Matriz de confusão para um problema binário.

		Classe Predita	
		Hipertenso	Normotenso
Classe Real	Hipertenso	VP	FN
	Normotenso	FP	VN

Por intermédio da matriz de confusão é possível avaliar quais classes apresenta inconsistência quando uma amostra é predita e similaridades interclasses, gerando os

falsos negativos ou falsos positivos. Logo, para se alcançar as métricas de validação em problemas de classificação é importante obter a matriz de confusão.

Tabela 5.2 Tabela de Métricas e acurácia.

Métrica	Fórmula	Descrição
Acurácia (A)	$\frac{VP + VN}{VP + VN + FP + FN}$	Apresenta a classificação geral do classificador. Pouco aplicável à bases de classes desbalanceadas.
Precisão (P)	$\frac{VP}{VP + FP}$	Considera apenas as classes preditas corretamente em relação ao número geral de amostras. Menos suscetível ao desbalanceamento.
Sensibilidade (S)	$\frac{VP}{VP + FN}$	Considera as amostras preditas corretamente em relação ao número de amostras de determinada classe.
F1-Score (F)	$2 \cdot \frac{P \cdot S}{P + S}$	Combina a precisão e a sensibilidade para avaliar o desempenho geral do modelo sem manter insegurança diante os resultados tendenciosos por desbalanceamento de dados.

5.2 Resultados

Os resultados obtidos demonstram o comportamento dos métodos avaliados nos cenários descritos na Seção 5.1, onde foram conduzidos três conjuntos de experimentos, denominados como: método generalista (MG); método com modelo especialista a partir do modelo generalista relacionado a um determinado sujeito (MEMG) e; método de geração de modelos especialista sem considerar nenhum treino prévio do modelo (ME).

5.2.1 Resultados com Modelos Generalistas (MG)

O método MoNePS proposto neste trabalho consiste em validar o modelo neural com base em camadas dilatadas o qual recebe como entrada, sinais PPG refinados pelo filtro de *Butterworth* sem normalização. Em contrapartida, o modelo de comparação Espectro-Temporal de Slapničar, Mlakar, Luštrek (2019) (*Baseline*) recebe como entrada o sinal normalizado do PPG e duas derivativas do sinal (velocidade e aceleração). Com base nas predições realizadas por cada modelo neural proposto, de acordo com a Figura 5.6 é possível notar que ambos os modelos conseguiram ter uma aproximação da mediana. Porém, quando observado os valores mínimos e máximos de Milímetros de mercúrio (mmHg), é possível notar que:

- O MoNePS obteve um valor mínimo para sístole superior e de diástole inferior aos valores destacados pela base, ou valores reais. O modelo também apontou para valores discrepantes dentro do intervalo mínimo e máximo da

base real. Os valores de Diástole preditos pelo modelo seguiram dentro do intervalo de mínimos e máximos da base real.

- O Espectro-Temporal, por sua vez, obteve um valor mínimo de sístole muito superior ao mínimo real, não conseguindo realizar previsões para valores abaixo de 100 mmHg. Em contrapartida, a mediana em destaque ficou extremamente próxima.




Figura 5.6 Análise dos valores preditos pelo experimento MG em relação aos valores reais. Fonte: próprio autor.

A Tabela 5.3 mostra a média, desvio padrão e MAE. Essa tabela nos mostra o quanto os dois modelos neurais desempenharam, MoNePS e Espectro-Temporal, quando comparado ao desvio padrão e média da base de teste em questão. Quando submetido a métrica MAE ao conjunto de testes, o MoNePS alcançou valor de 17.69mmHg e Diástole de 8.90mmHg. A Tabela 5.3 apresenta os valores de média, desvio padrão e erro médio absoluto (MAE) pertinentes aos pontos de sístole e diástole extraídos da base de teste, e dos valores preditos pelos modelos utilizados neste trabalho.

Tabela 5.3 Média, Desvio Padrão e Erro Médio Absoluto do experimento MG.

	Valor alvo		MoNePS		Baseline	
	Sístole	Diástole	Sístole	Diástole	Sístole	Diástole
Desvio Padrão	23.16	11.68	11.13	5.23	13.28	6.56
Média	119.0	59.0	123.51	61.17	119.11	59.93
MAE [mmHg]	-	-	17.69	8.90	18.12	8.78

Em seguida, os valores de sístole e diástole pertencentes à base de teste e os valores preditos foram submetidos à tabela de classificação de hipertensão determinada pela Associação Internacional de Hipertensão (UNGER, 2020) para avaliar se os valores preditos estão correlacionados com suas categorias correspondentes. Esta etapa, como mencionado anteriormente, foi dividida em duas fases: 1) classificação em 4 classes (Normotenso, Pré-Hipertenso, Hipertenso Grau 1 e Hipertenso Grau 2) e 2) classificação binária (Normotenso e Hipertenso).

A Figura 5.7 apresenta a matriz de confusão e suas respectivas métricas associadas. É possível notar que ambos os modelos tendem a se inclinar para a categoria Normotenso, seguindo a mediana descrita nos diagramas de bloco.

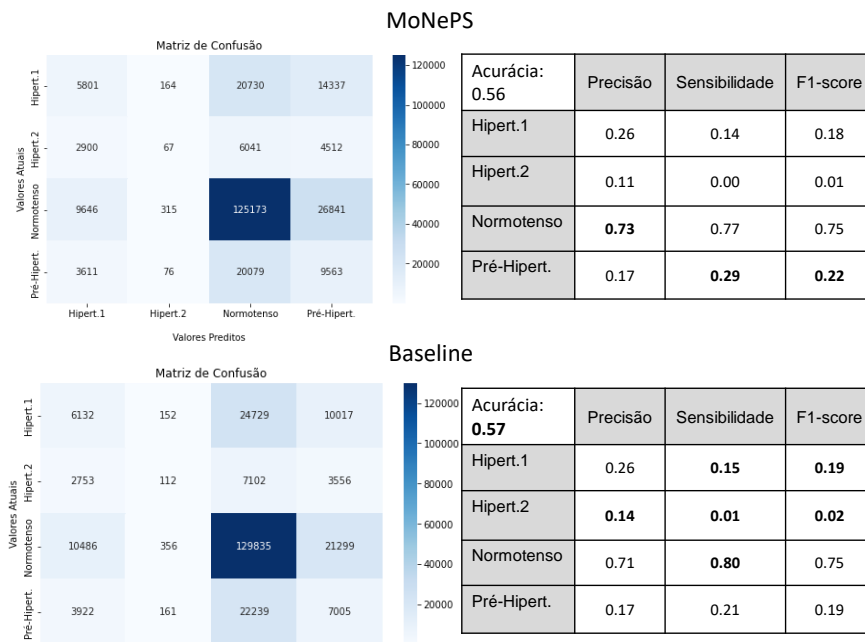


Figura 5.7 Análise das classes relacionadas aos valores preditos pelo experimento MG em relação às classes relacionadas aos valores reais. Fonte: próprio autor.

De acordo com a Sociedade Internacional de Hipertensão, uma pressão considerada hipertensa, em um cenário de aferição realizado em consultório, por conta dos sinais PPG e ABP terem sido coletados de pacientes em situação de tratamento intensivo, os valores de sístole e diástole devem se encontrar no intervalo de ≥ 149 e ≥ 90 mmHg, respectivamente. Portanto, foi realizada uma binarização dos rótulos apresentado em classes Normotenso e Hipertenso apresentados na Figura 5.8, ao qual podemos observar sua matriz de confusão, seguidos de suas métricas.

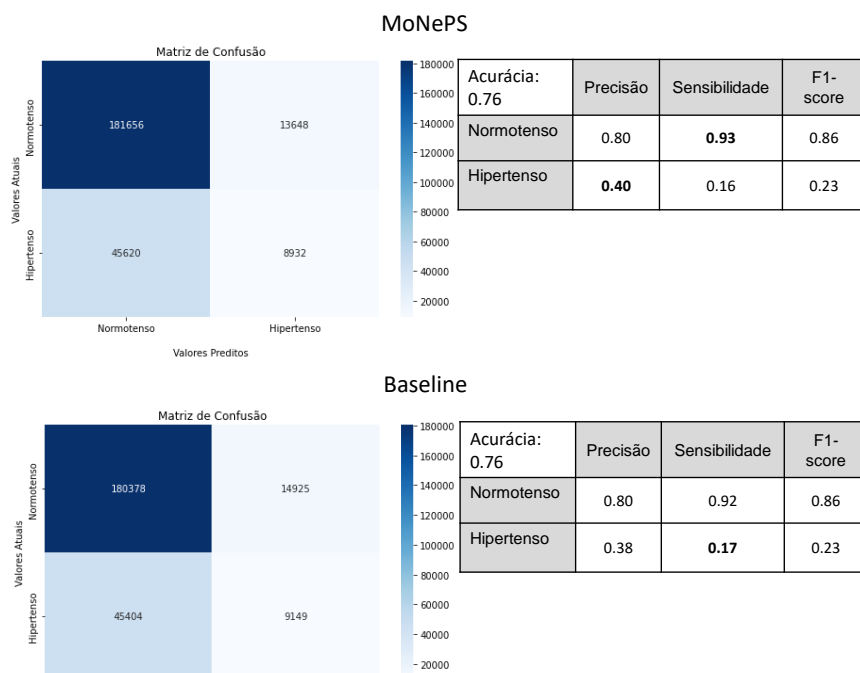


Figura 5.8 Análise dos valores preditos pelo experimento: MG em relação aos valores reais em classes binárias. Fonte: próprio autor.

Mesmo aplicando a binarização às classes, ambos os modelos conseguem atingir a mesma métrica de F1-Score para as duas classes, hipertensão e normotenso. O modelo MoNePS, mesmo que pequeno, demonstrou melhores resultados sob as métricas de precisão e sensibilidade. Portanto, é possível notar que modelos generalistas com validação *Holdout* por pessoa apresenta resultados muito pobres. Isso se deve a particularidade do sinal PPG e ABP para cada organismo, com semelhança as digitais humanas, tornando um problema difícil para resolver desta forma.

Neste sentido, uma maneira de aplicação que se comporta melhor a adversidade de particularidade de sinais é por meio de modelos especialistas. Estes modelos, como já mencionado, possuem sua divisão de dados com base em um único indivíduo, causando sobre ajustar de seus pesos em relação a um único indivíduo. Portanto, as próximas duas avaliações apresentam resultados de cenários de modelos especialistas.

5.2.2 Resultados com Modelo Especialista-Modelo Generalista (MEMG)

O cenário em questão tende a mitigar os problemas detectados no cenário anterior, pois, neste cenário, os modelos são treinados com dados de usuários pertencentes ao subconjunto de teste. A sua divisão ficou em 80% para treino, 10% validação e 10% teste. A priori, foram selecionados 50 usuários. Destes, apenas 46 usuários foram credenciados ao experimento, uma vez que atingiram o mínimo de amostras validação e teste de 9 amostras ou 63 segundos. É importante ressaltar que foram gerados modelos especialistas com base no modelo pré-treinado apresentado no cenário anterior ao qual constituiu o modelo generalista.

Conforme pode ser observado na Figura 5.9, os modelos praticamente imitaram o comportamento de distribuição dos dados de teste. Esse comportamento já era previsto, uma vez que os modelos são aplicados a dados com padrões semelhantes nos subconjuntos de treinamento e testes por pertencer a um único usuário.




Figura 5.9 Análise dos valores preditos pelo experimento MG em relação aos valores reais em classes binárias. Fonte: próprio autor.

As informações de média, desvio padrão e MAE apresentadas na Tabela 5.4 mostram uma redução significativa dos valores de erros para ambos os modelos, tendo o MoNePS apresentado um MAE melhor por apresentar um valor menor. Em relação aos valores preditos para sístole, o Espectro-Temporal apresentou uma aproximação maior em relação ao MoNePS. Em contrapartida, o MoNePS apresentou uma maior aproximação

aos valores de diástole. Ao olhar as médias, ambos os modelos apresentaram valores inteiros idênticos.

Tabela 5.4 Média, Desvio Padrão e Erro Médio Absoluto do Experimento MEMG.

	Valor alvo		MoNePS		Baseline	
	Sístole	Diástole	Sístole	Diástole	Sístole	Diástole
Desvio Padrão	23.18	12.99	21.94	12.28	22.07	11.86
Média	116.0	62.0	116.38	62.32	116.68	62.88
MAE [mmHg]	-	-	5.02	3.11	5.75	3.77

Ao utilizar os valores de sístole e diástole e classificá-los conforme a Sociedade Internacional de Hipertensão (UNGER, 2020), é possível notar conforme a Figura 5.10 que a categoria Normotenso apresentou o maior número de dados, levando desequilíbrio à base de teste. No entanto, os modelos conseguiram distinguir os sinais da classe em questão das demais, dando espaço para uma binária entre Normotenso e Hipertenso mais precisa.

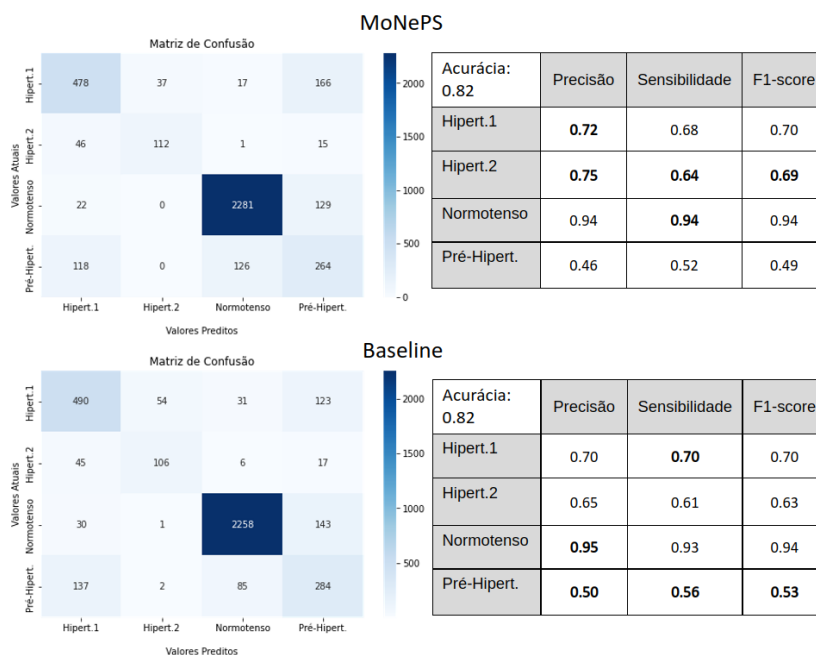


Figura 5.10 Análise das classes relacionadas aos valores preditos pelo experimento MEMG em relação às classes relacionadas aos valores reais. Fonte: próprio autor.

Conforme apresentado na Figura 5.11, ambos os modelos conseguiram um desempenho bem mais otimista, tendo igualdade na métrica F1-Score e similaridades nas demais métricas.

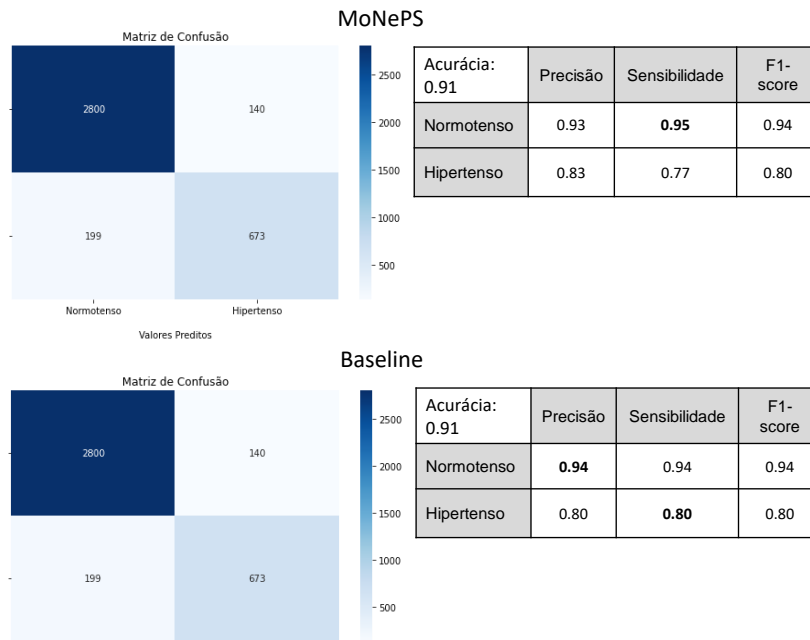


Figura 5.11 Análise dos valores preditos pelo experimento MEMG em relação aos valores reais em classes binárias. Fonte: próprio autor.

É importante ressaltar que os experimentos para modelos especialistas com MoNePS e Espectro-Temporal partiram de um pré-treino geral. Logo, existe a necessidade de avaliar o desempenho de um modelo especialista sem que o mesmo tenha algum pré-treino, de modo a comparar a melhor abordagem para aplicação de uma metodologia com modelo especialista. Portanto, o próximo experimento tem como finalidade extrair o desempenho dos modelos analisados.

5.2.3 Resultados do Modelo Especialista (ME)

As mesmas amostras utilizadas no experimento anterior foram aplicadas no experimento ME, o qual foram criados modelos neurais sem pré-treino sobre ajustados a um determinado indivíduo. Na prática, foram criados modelos com pesos randômicos sem nenhum tipo de ajustes, submetidos a dados de um único indivíduo nas etapas de treino, validação e teste. A Figura 5.12 apresenta o comportamento dos modelos com os valores preditos em relação aos rótulos de sístole e diástole. É possível notar que ambos os modelos tiveram dificuldades, tendo bastantes valores discrepantes em suas predições, prejudicando a correlação dos rótulos com as categorias da pressão sanguínea.

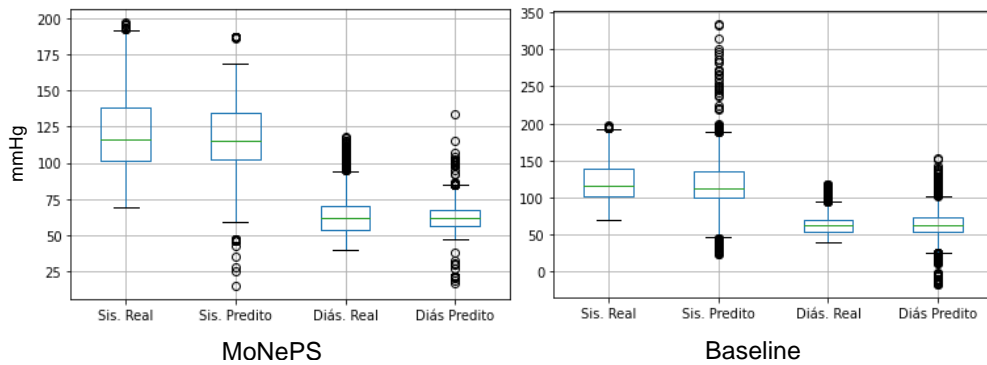


Figura 5.12 Análise dos valores preditos pelo experimento ME em relação aos valores reais em classes binárias. Fonte: próprio autor.

Mesmo apresentando valores discrepantes o MoNePS conseguiu alcançar um desvio padrão e média mais correlatos aos rótulos, além de ter apresentado um MAE menor, conforme apresentado na Tabela 5.5.

Tabela 5.5 Média, Desvio Padrão e Erro Médio Absoluto do Experimento ME.

	Valor alvo		MoNePS		Baseline	
	Sístole	Diástole	Sístole	Diástole	Sístole	Diástole
Desvio Padrão	23.18	12.99	19.35	10.99	30.23	17.02
Média	116.0	62.0	115.36	62.25	111.72	61.45
MAE [mmHg]	-	-	11.03	6.30	16.00	9.27

Embora este experimento tenha tido como foco gerar modelos especializados, existe uma notória lacuna deste experimento com o experimento MEMG. É possível que ao treinar um modelo especialista sem pré-treino exija-se mais amostras para treino de modo que o modelo se ajuste aos dados do indivíduo. Contudo, o MoNePS demonstrou um desempenho melhor quando aplicado a métrica de F1-Score às classes Normotenso e Hipertensão grau 1, conforme apresentado na Figura 5.13.

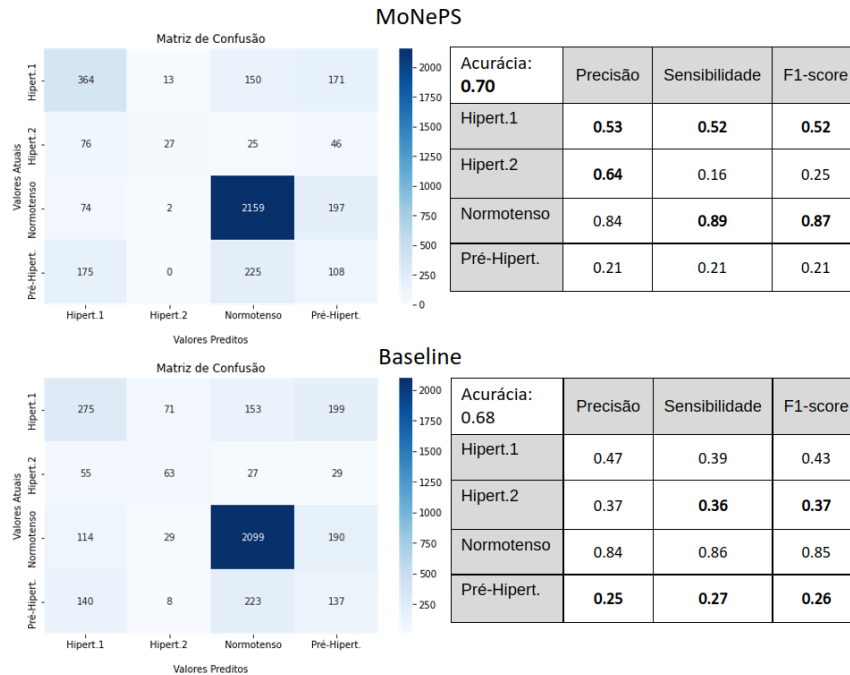


Figura 5.13 Análise das classes relacionadas aos valores preditos pelo experimento ME em relação às classes relacionadas aos valores reais. Fonte: próprio autor.

Por fim, ao visualizar a distribuição dos rótulos preditos em perspectiva binária, conforme a Figura 5.14 o MoNePS obteve um melhor desempenho ao observar a métrica F1-Score, não superando o Espectro-Temporal apenas na precisão referente à classe Hipertenso.

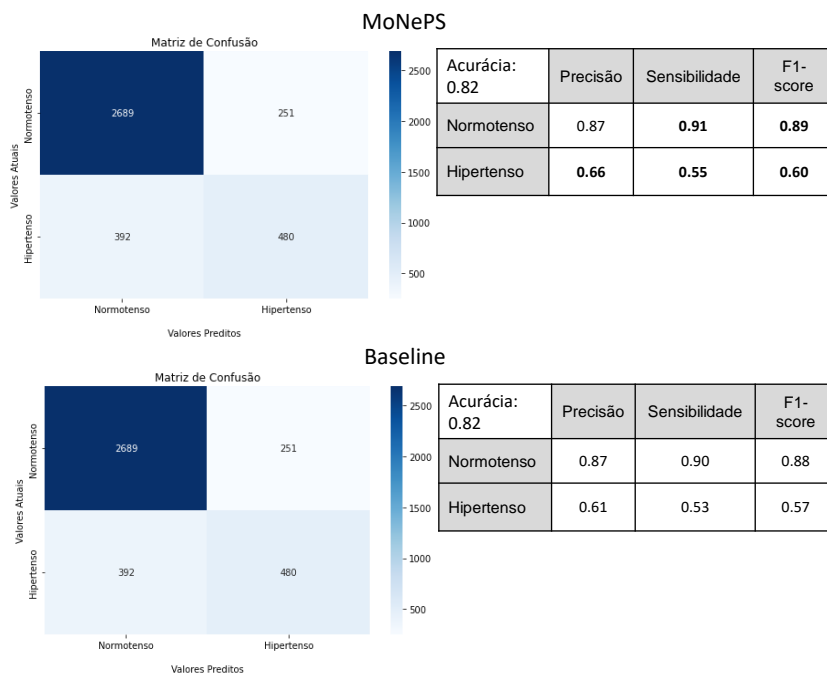


Figura 5.14 Análise dos valores preditos pelo experimento MEMG em relação aos valores reais em classes binárias. Fonte: próprio autor.

5.3 Discussão

Diante dos resultados apresentados, mesmo com um modelo com menor número de parâmetros e tendo apenas o segmento de sinal PPG, é possível obter resultados que competem a modelo de maior complexidade apresentado pelo Espectro-Temporal. Dessa forma, pode-se afirmar que o uso de modelos menos complexos é capaz de identificar as mudanças que ocorrem com o sinal fisiológico captado via PPG, para determinar por meio dos valores de pressão se determinada pessoa está ou não hipertensa.

A realização da etapa posterior de classificação foi apresentada como uma forma de analisar se o que está sendo predito nos pontos de sístole e diástole sobre o sinal PPG está de acordo com as categorias definidas pelo Sociedade Internacional de Hipertensão. A Tabela 5.6 a seguir apresenta um resumo do desempenho dos modelos, com destaque em negrito às situações em que cada modelo obteve uma métrica de erro menor durante os testes.

Tabela 5.6 Sumarização dos resultados dos experimentos de acordo com as regressões.

Experimentos	MoNePS		Baseline	
	MAE _{Sístole} [mmHg]	MAE _{Diástole} [mmHg]	MAE _{Sístole} [mmHg]	MAE _{Diástole} [mmHg]
MG	17.69	8.90	18.12	8.78
MEMG	5.02	3.11	5.75	3.77
ME	11.03	6.30	16.00	9.27

Portanto, é possível analisar na Tabela 5.6 que o MoNePS, embora utilize apenas um canal de entrada para a realização da estimativa da pressão sanguínea, alcançou os menores erros segundo a métrica MAE quase todos os experimentos. No experimento MG, pode-se perceber uma aproximação nos valores de erro para os pontos de diástole, enquanto o MoNePS foi superior em relação à sístole, obtendo um menor erro.

Quando observado os erros reportados no experimento MEMG, é nítido que o erro gerado por ambos os modelos ficou bem abaixo que o experimento anterior (MG) e que o MoNePS conseguiu menores taxas de erro, mesmo com a proximidade dos resultados reportados por ambos os modelos.

O experimento ME, que conta com treinamento de modelos especializados sem pré-treino, sob as mesmas circunstâncias de dados do experimento anterior (MEMG), não alcançou resultados tão otimistas quanto os relatados no experimento MEMG. De todo modo, mais uma vez o MoNePS demonstrou resultados melhores quando comparado ao Espectro-Temporal, resultado num melhor poder computacional para se adaptar aos dados particulares de um indivíduo.

Conclusões

Este capítulo apresenta conclusões e considerações sobre a viabilidade do método MoNePS para a estimativa da pressão sanguínea a partir de sinais PPG. Além disso são apresentados potenciais trabalhos futuros em relação a classificação da hipertensão a partir da inferência dos pontos de sístole e diástole extraídos do sinal PPG.

Com base nos resultados obtidos, foi possível observar o potencial do método MoNePS na tarefa de regressão para estimativa da pressão sanguínea. A aplicação dos métodos de filtragem no sinal PPG, atenuação dos *outliers* e extração dos rótulos do sinal ABP foram essenciais para que se alcançasse um resultado competitivo ao apresentado pelo Espectro-Temporal. Deste modo, foi possível avaliar as predições por meio de métricas de erro relacionados à regressão e métricas vinculadas à classificação. Considerando os resultados obtidos na Seção 5.2 é possível observar que o método MoNePS obteve resultados comparáveis com o método Espectro-Temporal, mesmo utilizando um modelo com menos parâmetros e complexidade. Além disso, o MoNePS dispensa a necessidade extração de características manuais, para serem passadas como entrada para modelo neural proposto, necessitando apenas dos segmentos de sinal PPG, diferente do método Espectro-Temporal que além dos seguimentos de sinal PPG, necessita de mais dois segmentos derivativos do sinal PPG.

A estratégia de utilizar um modelo neural com núcleo composto por blocos de dilatação com camadas de Convolução 1D, possibilitou o aumento da escala de características extraídas pelo modelo, utilizando um modelo menos complexo capaz de identificar alterações nos sinais fisiológicos captados pelo PPG para determinar se o indivíduo é acometido pela hipertensão arterial por meio de suas variações. Desta forma, o MoNePS demonstrou ser promissor para a tarefa de regressão da pressão sanguínea. Demonstrando uma maior viabilidade para a sua utilização em cenários reais, por se tratar de um modelo menos complexo.

A partir das métricas de erro de regressão utilizada na inferência dos sinais de sístole e diástole é possível observar que de modo geral o MoNePS alcançou resultados comparáveis com o Espectro-Temporal. Os pontos preditos de sístole e diástole foram utilizados para classificação como forma de analisar se o conteúdo previsto pelos pontos

da Sístole e Diástole no sinal do PPG estava de acordo com as categorias definidas pela Sociedade Internacional de Hipertensão. No entanto, foi possível analisar que tanto o MoNePS quanto o modelo Espectro-Temporal possuem maior dificuldade de generalização, apontando os valores de sístole e diástole para a média, em relação a predição personalizada por paciente é possível observar maior viabilidade.

6.1 Trabalhos Futuros

Considerando os resultados obtidos nesses experimentos, os trabalhos futuros serão: aprimorar o processo de monitoramento contínuo embarcando o modelo em dispositivos móveis e aplicar modelos específicos para classificação com os dados proveniente da regressão, utilizando processos de compressão e otimização de modelos para minimizar os custos computacionais para a execução em um dispositivo vestível. Além disso, é essencial que sejam otimização dos hiperparâmetros do modelo ao qual pode ser viabilizado por meio de técnicas de como o *Hyperband* ou *Random Search*.

Além disso, uma forma de melhoria e adaptação de modelos neurais pode ser concebido pelo retreino do modelo com os dados característicos de uma determinada pessoa. Logo, modelos de predição embarcados com entradas de dados oriundos do sensor PPG para realização de predições de valores que são característicos do sinal ABP, acendem à necessidade de obter dados do sinal ABP para realização do procedimento de retreino. Portanto, o desenvolvimento de um modelo que reconstrua o sinal ABP a partir do sinal PPG para posterior extração de seus rótulos sincronizados a dados futuros PPG pode ser de grande valia para a realização de predições da pressão sanguínea arterial independentes, por meio unicamente de sinais PPG.

Referências

- AGHAM, N.; CHASKAR, U. PREVALENT APPROACH OF LEARNING BASED CUFFLESS BLOOD PRESSURE MEASUREMENT SYSTEM FOR CONTINUOUS HEALTH-CARE MONITORING. IEEE INTERNATIONAL SYMPOSIUM ON MEDICAL MEASUREMENTS AND APPLICATIONS (MEMEA). 2019.
- ALESSI, A. ET AL. I BRAZILIAN POSITION PAPER ON PREHYPERTENSION, WHITE COAT HYPERTENSION AND MASKED HYPERTENSION: DIAGNOSIS AND MANAGEMENT. ARQUIVOS BRASILEIROS DE CARDIOLOGIA. 2014.
- ALIAN, A. A.; SHELLEY, K. H. PHOTOPLETHYSMOGRAPHY. BEST PRACTICE & RESEARCH CLINICAL ANAESTHESIOLOGY, V. 28, N. 4, P. 395–406, DEZ. 2014.
- ALLEN, J. PHOTOPLETHYSMOGRAPHY AND ITS APPLICATION IN CLINICAL PHYSIOLOGICAL MEASUREMENT. PHYSIOLOGICAL MEASUREMENT, V. 28, N. 3, P. R1–R39, 20 FEV. 2007.
- ALPERT, BS, QUINN, D, GALLICK, D. OSCILLOMETRIC BLOOD PRESSURE: A REVIEW FOR CLINICIANS. J AM SOC HYPERTENS. 2014.
- BLANCHARD, S.; BRONZINO, J. D. ANATOMY AND PHISIOLOGY. IN: ENDERLE, J. D.; BRONZINO, J. D. (ED.). INTRODUCTION TO BIOMEDICAL ENGINEERING. 3. ED. BURLINGTON: ELSEVIER INC., CAP. 3, P. 75–132 . 2012.
- BOWDLE, T ANDREW. “COMPLICATIONS OF INVASIVE MONITORING.” ANESTHESIOLOGY CLINICS OF NORTH AMERICA VOL. 20,3 (2002).
- CAN, Y., ET AL. CONTINUOUS STRESS DETECTION USING WEARABLE SENSORS IN REAL LIFE: ALGORITHMIC PROGRAMMING CONTEST CASE STUDY. SENSORS, V. 19, N. 8, P. 1849, 18 ABR. 2019.
- CUOCOLO, R. ET AL. “CURRENT APPLICATIONS OF BIG DATA AND MACHINE LEARNING IN CARDIOLOGY.” JOURNAL OF GERIATRIC CARDIOLOGY : JGC VOL. 16,8. 601-607. 2019.
- ELGENDI, M. ET AL. THE USE OF PHOTOPLETHYSMOGRAPHY FOR ASSESSING HYPERTENSION. NPJ DIGITAL MEDICINE, V. 2, N. 1, 26 JUN. 2019.
- FARSANG, C., ET AL., “WHEREAREWEWITH THE MANAGEMENT OF HYPERTENSION? FROM SCIENCE TO CLINICALPRACTICE,”THE JOURNAL OF CLINICAL HYPERTENSION,VOL.11,NO.2,PP.66–73, 2009.
- FERREIRA, K. A. S. L. ET AL. VALIDAÇÃO DO ESFIGMOMANÔMETRO ANEROIDE MISSOURI PARA MEDIR PRESSÃO ARTERIAL EM PACIENTES COM CÂNCER. ARQUIVOS BRASILEIROS DE CARDIOLOGIA, V. 95, N. 2, P. 244–250, AGO. 2010.

- FISCHER, C. ET AL. AN ALGORITHM FOR REAL-TIME PULSE WAVEFORM SEGMENTATION AND ARTIFACT DETECTION IN PHOTOPLETHYSMOGRAMS. IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS, V. 21, N. 2, P. 372–381, MAR. 2017.
- FRANKLIN, S. S. ET AL. DOES THE RELATION OF BLOOD PRESSURE TO CORONARY HEART DISEASE RISK CHANGE WITH AGING? CIRCULATION, V. 103, N. 9, P. 1245–1249, 6 MAR. 2001.
- GESCHE, H. ET AL. CONTINUOUS BLOOD PRESSURE MEASUREMENT BY USING THE PULSE TRANSIT TIME: COMPARISON TO A CUFF-BASED METHOD. EUROPEAN JOURNAL OF APPLIED PHYSIOLOGY, V. 112, N. 1, P. 309–315. 2011.
- GHAMARI, M. ET AL. A REVIEW ON WEARABLE PHOTOPLETHYSMOGRAPHY SENSORS AND THEIR POTENTIAL FUTURE APPLICATIONS IN HEALTH CARE. INTERNATIONAL JOURNAL OF BIOSENSORS & BIOELECTRONICS, V. 4, N. 4, 2018.
- GONZALEZ, R. E. W. R. C. DIGITAL IMAGE PROCESSING. 3ED.. ED. [S.L.]: PRENTICE HALL. 2008.
- HABBU, S.; DALE, M.; GHONGADE, R. ESTIMATION OF BLOOD GLUCOSE BY NON-INVASIVE METHOD USING PHOTOPLETHYSMOGRAPHY. SĀDHANĀ, V. 44, N. 6. 2019.
- HAN, S. ET AL. DESIGN OF MULTI-WAVELENGTH OPTICAL SENSOR MODULE FOR DEPTH-DEPENDENT PHOTOPLETHYSMOGRAPHY. SENSORS, V. 19, N. 24, P. 5441. 2019.
- HANNUN, A. Y. ET AL. CARDIOLOGIST-LEVEL ARRHYTHMIA DETECTION AND CLASSIFICATION IN AMBULATORY ELECTROCARDIOGRAMS USING A DEEP NEURAL NETWORK. NATURE MEDICINE, V. 25, N. 1, P. 65–69, JAN. 2019.
- HARTMANN, V. ET AL. TOWARD ACCURATE EXTRACTION OF RESPIRATORY FREQUENCY FROM THE PHOTOPLETHYSMOGRAM: EFFECT OF MEASUREMENT SITE. FRONTIERS IN PHYSIOLOGY, V. 10, 18 JUN. 2019.
- HSIAO, C. C., KUO, H. C., LEE, R. G., & LIN, R. EFFECTS OF PULSE TRANSIT TIME AND PHYSIOLOGICAL DIFFERENCES ON WEARABLE DEVICE BASED BLOOD PRESSURE ESTIMATION. IN 2016 INTERNATIONAL AUTOMATIC CONTROL CONFERENCE (CAC), IEEE P. 242-246. 2016.
- HSIU H., HSU C.-L., WU T.-L. A PRELIMINARY STUDY ON THE CORRELATION OF FREQUENCY COMPONENTS BETWEEN FINGER PPG AND RADIAL ARTERIAL BP WAVEFORMS; PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON BIOMEDICAL AND PHARMACEUTICAL ENGINEERING; SINGAPORE. 2009.
- JEYHANI, V. ET AL. COMPARISON OF HRV PARAMETERS DERIVED FROM PHOTOPLETHYSMOGRAPHY AND ELECTROCARDIOGRAPHY SIGNALS. 37TH ANNUAL

- INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC). 2015.
- JOHN DIAN, F.; VAHIDNIA, R.; RAHMATI, A. WEARABLES AND THE INTERNET OF THINGS (IOT), APPLICATIONS, OPPORTUNITIES, AND CHALLENGES: A SURVEY. IEEE ACCESS, V. 8, P. 69200–69211. 2020.
- JOHNSON, A. E., POLLARD, T. J., SHEN, L., LEHMAN, L.-W. H., FENG, M., GHASSEMI, M., MOODY, B., SZOLOVITS, P., ANTHONY CELI, L., E MARK, R. G. MIMIC-III, A FREELY ACCESSIBLE CRITICAL CARE DATABASE. SCIENTIFIC DATA. 2016.
- JOHNSON, ALISTAIR E.W. ET AL. MIMIC-III, A FREELY ACCESSIBLE CRITICAL CARE DATABASE. SCIENTIFIC DATA. [S.L.]: SPRINGER SCIENCE AND BUSINESS MEDIA LLC. DISPONÍVEL EM: <[HTTP://DX.DOI.ORG/10.1038/SDATA.2016.35](http://dx.doi.org/10.1038/sdata.2016.35)>. , 24 MAIO 2016.
- JONATHAN, E.; LEAHY, M. INVESTIGATING A SMARTPHONE IMAGING UNIT FOR PHOTOPLETHYSMOGRAPHY. PHYSIOLOGICAL MEASUREMENT, V. 31, N. 11, P. N79–N83, 24 SET. 2010.
- KACHUEE, M. ET AL. CUFFLESS BLOOD PRESSURE ESTIMATION ALGORITHMS FOR CONTINUOUS HEALTH-CARE MONITORING. IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING, V. 64, N. 4, P. 859–869. 2017.
- KAPTOGE, S. ET AL. WORLD HEALTH ORGANIZATION CARDIOVASCULAR DISEASE RISK CHARTS: REVISED MODELS TO ESTIMATE RISK IN 21 GLOBAL REGIONS. THE LANCET GLOBAL HEALTH, V. 7, N. 10, P. E1332–E1345. 2019.
- KHALID, S. G. ET AL. BLOOD PRESSURE ESTIMATION USING PHOTOPLETHYSMOGRAPHY ONLY: COMPARISON BETWEEN DIFFERENT MACHINE LEARNING APPROACHES. JOURNAL OF HEALTHCARE ENGINEERING, V. 2018, P. 1–13. 2018.
- KIM, B. S.; YOO, S. K. MOTION ARTIFACT REDUCTION IN PHOTOPLETHYSMOGRAPHY USING INDEPENDENT COMPONENT ANALYSIS. IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING, V. 53, N. 3, P. 566–568. 2006.
- KIM, S. H.; RYOO, D. W.; BAE, C. ADAPTIVE NOISE CANCELLATION USING ACCELEROMETERS FOR THE PPG SIGNAL FROM FOREHEAD. 2007 29TH ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY. ANAIS. 2007.
- KRAUSMAN, DAVID T. METHODS AND PROCEDURES FOR MONITORING AND RECORDING BLOOD PRESSURE. AMERICAN PSYCHOLOGIST. 1975.
- KURYLYAK, Y.; LAMONACA, F.; GRIMALDI, D. A NEURAL NETWORK-BASED METHOD FOR CONTINUOUS BLOOD PRESSURE ESTIMATION FROM A PPG SIGNAL. IN PROCEEDINGS OF THE 2013 IEEE INTERNATIONAL INSTRUMENTATION AND MEASUREMENT TECHNOLOGY CONFERENCE (I2MTC), MINNEAPOLIS, MN, USA. 2013;

- LAI, P.-H.; KIM, I. LIGHTWEIGHT WRIST PHOTOPLETHYSMOGRAPHY FOR HEAVY EXERCISE: MOTION ROBUST HEART RATE MONITORING ALGORITHM. HEALTHCARE TECHNOLOGY LETTERS, V. 2, N. 1, P. 6–11, 1 FEV. 2015.
- LAIZZO, P. A. GENERAL FEATURES OF THE CARDIOVASCULAR SYSTEM. IN: LAIZZO, P. A. (ED.). HANDBOOK OF CARDIAC ANATOMY. 1. ED. NEW YORK: SPRINGER, LLC. CAP. 1, P. 3–12. 2009.
- LECUN, Y., HAFFNER P., BOTTOU L., E BENGIO, Y. OBJECT RECOGNITION WITH GRADIENT-BASED LEARNING. IN SHAPE, CONTOUR AND GROUPING IN COMPUTER VISION. SPRINGER-VERLAG, BERLIN, HEIDELBERG, 319. 1999.
- LEE, B. ET AL. IMPROVED ELIMINATION OF MOTION ARTIFACTS FROM A PHOTOPLETHYSMOGRAPHIC SIGNAL USING A KALMAN SMOOTHER WITH SIMULTANEOUS ACCELEROMETRY. PHYSIOLOGICAL MEASUREMENT, V. 31, N. 12, P. 1585–1603. 2010.
- LEE, C. M.; ZHANG, Y. T. REDUCTION OF MOTION ARTIFACTS FROM PHOTOPLETHYSMOGRAPHIC RECORDINGS USING A WAVELET DENOISING APPROACH. IEEE EMBS ASIAN-PACIFIC CONFERENCE ON BIOMEDICAL ENGINEERING, 2003.
- LEMAY, M., BERTSCHI, M., SOLA, J., RENEVEY, P., PARAK, J. & KORHONEN, I. APPLICATION OF OPTICAL HEART RATE MONITORING, IN: SAZONOV, E. & NEUMAN, M.R. (ED.), WEARABLE SENSORS: FUNDAMENTALS, IMPLEMENTATION AND APPLICATIONS, ELSEVIER; IMPRINT: ACADEMIC PRESS, OXFORD, PP. 105-129. 2014.
- LEUNG, A.A.; DASKALOPOULOU, S.S.; DASGUPTA, K.; MCBRIEN, K.; BUTALIA, S.; ZARNKE, K.B.; NERENBERG, K.; HARRIS, K.C.; NAKHLA, M.; CLOUTIER, L.; ET AL. HYPERTENSION CANADA'S 2017 GUIDELINES FOR DIAGNOSIS, RISK ASSESSMENT, PREVENTION, AND TREATMENT OF HYPERTENSION IN ADULTS. CAN. J. CARDIOL. 2017.
- LIANG, Y. ET AL. AN OPTIMAL FILTER FOR SHORT PHOTOPLETHYSMOGRAM SIGNALS. SCIENTIFIC DATA, V. 5, N. 1. 2018A.
- LIANG, Y. ET AL. HYPERTENSION ASSESSMENT VIA ECG AND PPG SIGNALS: AN EVALUATION USING MIMIC DATABASE. DIAGNOSTICS, V. 8, N. 3, P. 65. 2018B.
- LIANG, Y. ET AL. PHOTOPLETHYSMOGRAPHY AND DEEP LEARNING: ENHANCING HYPERTENSION RISK STRATIFICATION. BIOSENSORS, V. 8, N. 4, P. 101. 2018C.
- LIANG, Y. ET AL. PPG-BP DATABASE FIGSHARE, 6 FEV. 2018. DISPONÍVEL EM: [HTTPS://DOI.ORG/10.6084/M9.FIGSHARE.5459299.V3](https://doi.org/10.6084/M9.FIGSHARE.5459299.V3). ACESSO EM 23 JULHO DE 2022.
- LIU, D.; GÖRGES, M.; E JENKINS, S. A. UNIVERSITY OF QUEENSLAND VITAL SIGNS DATASET: DEVELOPMENT OF AN ACCESSIBLE REPOSITORY OF ANESTHESIA

- PATIENT MONITORING DATA FOR RESEARCH., ANESTHESIA & ANALGESIA, VOL. 114, NO. 3, PP. 5849. 2012.
- LURBE, E. ET AL. MANAGEMENT OF HIGH BLOOD PRESSURE IN CHILDREN AND ADOLESCENTS: RECOMMENDATIONS OF THE EUROPEAN SOCIETY OF HYPERTENSION. JOURNAL OF HYPERTENSION, V. 27, N. 9, P. 1719–1742, SET. 2009.
- MAEDA, Y., SEKINE M., E TAMURA, T. RELATIONSHIP BETWEEN MEASUREMENT SITE AND MOTION ARTIFACTS IN WEARABLE REFLECTED PHOTOPLETHYSMOGRAPHY, J. MED. SYST. 35. 2011.
- MALACHIAS, M. ET AL. DIAGNÓSTICO E CLASSIFICAÇÃO. ARQUIVOS BRASILEIROS DE CARDIOLOGIA, V. 107, N. 3. 2016.
- MANCIA G, FAGARD R, NARKIEWICZ K, REDON J, ZANCHETTI A, BÖHM M, ET AL. ESH/ESC GUIDELINES FOR THE MANAGEMENT OF ARTERIAL HYPERTENSION: THE TASK FORCE FOR THE MANAGEMENT OF ARTERIAL HYPERTENSION OF THE EUROPEAN SOCIETY OF HYPERTENSION (ESH) AND OF THE EUROPEAN SOCIETY OF CARDIOLOGY (ESC). 2013.
- MANNHEIMER, P. D. THE LIGHT-TISSUE INTERACTION OF PULSE OXIMETRY. ANESTHESIA & ANALGESIA, V. 105, N. ON LINE SUPPL., P. S10–S17. 2007.
- MANUAL MSD. INSUFICIÊNCIA CARDÍACA: PROBLEMAS DE BOMBEAMENTO E PREENCHIMENTO. 2019. DISPONÍVEL EM <[HTTPS://WWW.MSDMANUALS.COM/PT/CASA/MULTIMEDIA/FIGURE/CVS_HEART_FAILURE_PT](https://www.msmanuals.com/pt/casa/multimedia/figure/cvs_heart_failure_pt)>. ACESSO EM 20 DE ABRIL DE 2019.
- MARSHALL SJ. DEVELOPING COUNTRIES FACE DOUBLE BURDEN OF DISEASE. BULL WORLD HEALTH ORGAN. 2004.
- MARTÍNEZ, G. ET AL. CAN PHOTOPLETHYSMOGRAPHY REPLACE ARTERIAL BLOOD PRESSURE IN THE ASSESSMENT OF BLOOD PRESSURE? JOURNAL OF CLINICAL MEDICINE, V. 7, N. 10, P. 316. 2018.
- MCCUTCHEON EP, RUSHMER RF. KOROTKOFF SOUNDS: AN EXPERIMENTAL CRITIQUE. CIRC RES. 1967.
- MEHROTRA, P. BIOSENSORS AND THEIR APPLICATIONS – A REVIEW. JOURNAL OF ORAL BIOLOGY AND CRANIOFACIAL RESEARCH, V. 6, N. 2, P. 153–159. 2016.
- MUNTNER, P. ET AL. MEASUREMENT OF BLOOD PRESSURE IN HUMANS: A SCIENTIFIC STATEMENT FROM THE AMERICAN HEART ASSOCIATION. HYPERTENSION, V. 73, N. 2019.
- NABEEL, P. M. ET AL. SINGLE SOURCE PHOTOPLETHYSMOGRAPH TRANSducer FOR LOCAL PULSE WAVE VELOCITY MEASUREMENT. 38TH ANNUAL INTERNATIONAL

- CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC). IEEE. 2016.
- NITZAN, M.; TAITELBAUM, H. THE MEASUREMENT OF OXYGEN SATURATION IN ARTERIAL AND VENOUS BLOOD. IEEE INSTRUMENTATION & MEASUREMENT MAGAZINE, V. 11, N. 3, P. 9–15. 2008.
- O'BRIEN E., FITZGERALD D. THE HISTORY OF BLOOD PRESSURE MEASUREMENT. J HUM HYPERTENS. 1994.
- OGEGEBE G., & PICKERING T. PRINCIPLES AND TECHNIQUES OF BLOOD PRESSURE MEASUREMENT. CARDIOL CLIN. 2010.
- PADWAL R, STRAUS SE, MCALISTER FA. EVIDENCE BASED MANAGEMENT OF HYPERTENSION. CARDIOVASCULAR RISK FACTORS AND THEIR EFFECTS ON THE DECISION TO TREAT HYPERTENSION: EVIDENCE BASED REVIEW. 2001.
- PARRY FUNG ET AL. CONTINUOUS NONINVASIVE BLOOD PRESSURE MEASUREMENT BY PULSE TRANSIT TIME. THE 26TH ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY. 2004.
- PERNICE, R. ET AL. COMPARISON OF SHORT-TERM HEART RATE VARIABILITY INDEXES EVALUATED THROUGH ELECTROCARDIOGRAPHIC AND CONTINUOUS BLOOD PRESSURE MONITORING. MEDICAL & BIOLOGICAL ENGINEERING & COMPUTING, V. 57, N. 6, P. 1247–1263. 2019.
- PETER, L.; NOURY, N.; CERNY, M. A REVIEW OF METHODS FOR NON-INVASIVE AND CONTINUOUS BLOOD PRESSURE MONITORING: PULSE TRANSIT TIME METHOD IS PROMISING? IRBM, V. 35, N. 5, P. 271–282. 2014.
- PINTO, P. M. ET AL. A 0.25-V FIFTH-ORDER BUTTERWORTH LOW-PASS FILTER BASED ON FULLY DIFFERENTIAL DIFFERENCE TRANSCONDUCTANCE AMPLIFIER ARCHITECTURE. MICROELECTRONICS JOURNAL, V. 92, P. 104606, 2019.
- RADHA, M. ET AL. ESTIMATING BLOOD PRESSURE TRENDS AND THE NOCTURNAL DIP FROM PHOTOPLETHYSMOGRAPHY. PHYSIOLOGICAL MEASUREMENT, V. 40, N. 2, P. 25006, 26 FEB. 2019.
- RAM, M. R. ET AL. A NOVEL APPROACH FOR MOTION ARTIFACT REDUCTION IN PPG SIGNALS BASED ON AS-LMS ADAPTIVE FILTER. IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, V. 61, N. 5, P. 1445–1457, MAIO 2012.
- REDDY, K. A.; GEORGE, B.; KUMAR, V. J. USE OF FOURIER SERIES ANALYSIS FOR MOTION ARTIFACT REDUCTION AND DATA COMPRESSION OF PHOTOPLETHYSMOGRAPHIC SIGNALS. IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, V. 58, N. 5, P. 1706–1711. 2009.

- RIAZ, F., AZAD, M. A., ARSHAD, J., IMRAN, M., HASSAN, A., & REHMAN, S. PERVASIVE BLOOD PRESSURE MONITORING USING PHOTOPLETHYSMOGRAM (PPG) SENSOR. FUTURE GENERATION COMPUTER SYSTEMS, 98, 120–130. 2019.
- RUNDO, F. ET AL. AN ADVANCED BIO-INSPIRED PHOTOPLETHYSMOGRAPHY (PPG) AND ECG PATTERN RECOGNITION SYSTEM FOR MEDICAL ASSESSMENT. SENSORS, V. 18, N. 2, P. 405. 2018.
- SAWICKA, KATARZYNA ET AL. "HYPERTENSION – THE SILENT KILLER." J PRE CLIN CLIN RES., VOL. 5, NO. 2, 2011, PP. 43-46.
- SCHAFER, R. WHAT IS A SAVITZKY-GOLAY FILTER? IEEE SIGNAL PROCESSING MAGAZINE, V. 28, N. 4, P. 111–117. 2011.
- SEVAKULA, R. K. ET AL. STATE-OF-THE-ART MACHINE LEARNING TECHNIQUES AIMING TO IMPROVE PATIENT OUTCOMES PERTAINING TO THE CARDIOVASCULAR SYSTEM. JOURNAL OF THE AMERICAN HEART ASSOCIATION, V. 9, N. 4. 2020.
- SLAPNIČAR, G., LUŠTREK, M., E MARINKO, M. "CONTINUOUS BLOOD PRESSURE ESTIMATION FROM PPG SIGNAL." INFORMATICA 42.1. 2018.
- SLAPNIČAR, G.; MLAKAR, N.; LUŠTREK, M. BLOOD PRESSURE ESTIMATION FROM PHOTOPLETHYSMOGRAM USING A SPECTRO-TEMPORAL DEEP NEURAL NETWORK. SENSORS, V. 19, N. 15, P. 3420. 2019.
- SMITH, S. W. CHEBYSHEV FILTERS. IN: DIGITAL SIGNAL PROCESSING. [S.L.] ELSEVIER. P. 333–342. 2003.
- SOLÀ, J., E RICARD, G. HANDBOOK OF CUFFLESS BLOOD PRESSURE MONITORING: A PRACTICAL GUIDE FOR CLINICIANS. CHAM: SPRINGER, 2019.
- STAESSEN JA, BEILIN L, PARATI G, WAEBER B, WHITE W, TASK FORCE IV. CLINICAL USE OF AMBULATORY BLOOD PRESSURE MONITORING. PARTICIPANTS OF THE 1999 CONSENSUS CONFERENCE ON AMBULATORY BLOOD PRESSURE MONITORING. BLOOD PRESS MONIT. 1999.
- TAMURA, T. ET AL. WEARABLE PHOTOPLETHYSMOGRAPHIC SENSORS - PAST AND PRESENT. ELECTRONICS, V. 3, N. 2, P. 282–302. 2014.
- THANACHARTWET, V. ET AL. DYNAMIC MEASUREMENT OF HEMODYNAMIC PARAMETERS AND CARDIAC PRELOAD IN ADULTS WITH DENGUE: A PROSPECTIVE OBSERVATIONAL STUDY. PLOS ONE, V. 11, N. 5, P. E0156135. 2016.
- TYAPOCHKIN, K.; SMORODNIKOVA, E.; PRAVDIN, P. SMARTPHONE PPG: SIGNAL PROCESSING, QUALITY ASSESSMENT, AND IMPACT ON HRV PARAMETERS. 41ST ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC). 2019.

- UNGER, T. ET AL. 2020 INTERNATIONAL SOCIETY OF HYPERTENSION GLOBAL HYPERTENSION PRACTICE GUIDELINES. HYPERTENSION, V. 75, N. 6, P. 1334–1357. 2020.
- VAN DEN OORD, A., DIELEMAN, S., ZEN, H., SIMONYAN, K., VINYALS, O., GRAVES, A., KALCHBRENNER, N., SENIOR, A., KAVUKCUOGLU, K. WAVENET: A GENERATIVE MODEL FOR RAW AUDIO. PROC. 9TH ISCA WORKSHOP ON SPEECH SYNTHESIS WORKSHOP (SSW 9), 125. 2016.
- VAN DRONGELEN, W. INTRODUCTION. IN: SIGNAL PROCESSING FOR NEUROSCIENTISTS. [S.L.] ELSEVIER P. 1–15. 2018.
- VASWANI, A., SHAZEER, N., PARMAR, N., USZKOREIT, J., JONES, L., GOMEZ, A. N., KAISER, Ł., & POLOSUKHIN, I. ATTENTION IS ALL YOU NEED. PROCEEDINGS OF THE 31ST INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 6000–6010. 2017.
- VERKRUYSSE, W.; SVAASAND, L. O.; NELSON, J. S. REMOTE PLETHYSMOGRAPHIC IMAGING USING AMBIENT LIGHT. OPTICS EXPRESS, V. 16, N. 26, P. 21434. 2008.
- VIGATO, ESTEFANIE SIQUEIRA AND LAMAS, JOSÉ LUIZ TATAGIBA. BLOOD PRESSURE MEASUREMENT BY OSCILLOMETRIC AND AUSCULTATORY METHODS IN NORMOTENSIVE PREGNANT WOMEN. REV. BRAS. ENFERM. [ONLINE]. 2019.
- WANG, W.; YANG, C.; WU, Y. SVM-BASED CLASSIFICATION METHOD TO IDENTIFY ALCOHOL CONSUMPTION USING ECG AND PPG MONITORING. PERSONAL AND UBIQUITOUS COMPUTING, V. 22, N. 2, P. 275–287. 2017.
- WEBER, M. A. ET AL. CLINICAL PRACTICE GUIDELINES FOR THE MANAGEMENT OF HYPERTENSION IN THE COMMUNITY. THE JOURNAL OF CLINICAL HYPERTENSION, V. 16, N. 1, P. 14–26. 2013.
- WHELTON PK, CAREY RM, ARONOW WS, ET AL.. 2017 ACC/AHA/AAPA/ABC/ACPM/AGS/APHA/ASH/ASPC/NMA/PCNA GUIDELINE FOR THE PREVENTION, DETECTION, EVALUATION, AND MANAGEMENT OF HIGH BLOOD PRESSURE IN ADULTS: EXECUTIVE SUMMARY: A REPORT OF THE AMERICAN COLLEGE OF CARDIOLOGY/AMERICAN HEART ASSOCIATION TASK FORCE ON CLINICAL PRACTICE GUIDELINES.
- WILLIAMS, B.; MANCIA, G.; SPIERING, W.; AGABITI ROSEI, E.; AZIZI, M.; BURNIER, M.; CLEMENT, D.L.; COCA, A.; DE SIMONE, G.; DOMINICZAK, A.; ET AL. 2018 ESC/ESH GUIDELINES FOR THE MANAGEMENT OF ARTERIAL HYPERTENSION. EUR. HEART J. 2018.
- WORLD HEALTH ORGANIZATION (WHO). HYPERTENSION. [HTTP://WWW.WHO.INT/CARDIOVASCULAR_DISEASES/PUBLICATIONS/GLOBAL_BRIEF_HYPERTENSION/EN/](http://www.who.int/cardiovascular_diseases/publications/global_brief_hypertension/en/). 2021.

- WORLD HEALTH ORGANIZATION. A GLOBAL BRIEF ON HYPERTENSION: SILENT KILLER, GLOBAL PUBLIC HEALTH CRISIS. WORLD HEALTH ORGANIZATION, GENEVA, SWITZERLAND. 2013.
- XIE, Q. ET AL. MACHINE LEARNING METHODS FOR REAL-TIME BLOOD PRESSURE MEASUREMENT BASED ON PHOTOPLETHYSMOGRAPHY. 2018 IEEE 23RD INTERNATIONAL CONFERENCE ON DIGITAL SIGNAL PROCESSING (DSP). ANAIS. 2018.
- XING, X.; SUN, M. OPTICAL BLOOD PRESSURE ESTIMATION WITH PHOTOPLETHYSMOGRAPHY AND FFT-BASED NEURAL NETWORKS. BIOMEDICAL OPTICS EXPRESS, V. 7, N. 8, P. 3007. 2016.
- ZHANG, D., ZUO, W., WANG, P. COMPUTATIONAL PULSE SIGNAL ANALYSIS. S.L: SPRINGER. 2018.
- ZHANG, Y.; FENG, Z. A SVM METHOD FOR CONTINUOUS BLOOD PRESSURE ESTIMATION FROM A PPG SIGNAL. PROCEEDINGS OF THE 9TH INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND COMPUTING – ICMLC. 2017.
- ZHU, J. CHEN, H. E YE W. A HYBRID CNN–LSTM NETWORK FOR THE CLASSIFICATION OF HUMAN ACTIVITIES BASED ON MICRO-DOPPLER RADAR, IEEE ACCESS, VOL. 8. 2020.