



UFRPE

UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
UNIDADE ACADÊMICA DO CABO DE SANTO AGOSTINHO
BACHARELADO EM ENGENHARIA ELETRÔNICA

LUIGI FERNANDO MARQUES DA LUZ

PyCBPE: Um *Framework Open-source* Para Estudo de Desempenho de Algoritmos de Aprendizagem de Máquina Aplicados Para Estimar a Pressão Arterial Através de Sinais de Fotopletismografia

Cabo de Santo Agostinho - PE

2021

LUIGI FERNANDO MARQUES DA LUZ

PyCBPE: Um *Framework Open-source* Para Estudo de Desempenho de Algoritmos de Aprendizagem de Máquina Aplicados Para Estimar a Pressão Arterial Através de Sinais de Fotopletismografia

Monografia apresentada ao Curso de Graduação em Engenharia Eletrônica da Unidade Acadêmica do Cabo de Santo Agostinho da Universidade Federal Rural de Pernambuco para obtenção do título de Bacharel em Engenharia Eletrônica.

Orientador: Prof. Fernando Gonçalves de Almeida Neto, D.Sc.

Co-orientador: Eronides Felisberto da Silva Neto, M.Sc.

Cabo de Santo Agostinho - PE

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

- L979p Luz, Luigi Fernando Marques da
PyCBPE: Um Framework Open-source Para Estudo de Desempenho de Algoritmos de Aprendizagem de Máquina Aplicados Para Estimar a Pressão Arterial Através de Sinais de Fotopletismografia / Luigi Fernando Marques da Luz. - 2021.
84 f. : il.
- Orientador: Fernando Goncalves de Almeida Neto.
Coorientador: Eronides Felisberto da Silva Neto.
Inclui referências.
- Trabalho de Conclusão de Curso (Graduação) - Universidade Federal Rural de Pernambuco, Bacharelado em Engenharia Eletrônica, Cabo de Santo Agostinho, 2021.
1. pressão arterial. 2. fotopletismografia. 3. aprendizagem de máquina. 4. framework open-source. I. Neto, Fernando Goncalves de Almeida, orient. II. Neto, Eronides Felisberto da Silva, coorient. III. Título

LUIGI FERNANDO MARQUES DA LUZ

PyCBPE: Um *Framework Open-source* Para Estudo de Desempenho de Algoritmos de Aprendizagem de Máquina Aplicados Para Estimar a Pressão Arterial Através de Sinais de Fotopletismografia

Monografia apresentada ao Curso de Graduação em Engenharia Eletrônica da Unidade Acadêmica do Cabo de Santo Agostinho da Universidade Federal Rural de Pernambuco para obtenção do título de Bacharel em Engenharia Eletrônica.

Aprovado em: 15/07/2021

Banca Examinadora

Prof. Fernando Gonçalves de Almeida Neto, D.Sc.
Universidade Federal Rural de Pernambuco, UFRPE

Prof. Vitor de Andrade Coutinho, D.Sc.
CESAR School

Prof. Felipe Alberto Barbosa Simão Ferreira, D.Sc.
Universidade Federal Rural de Pernambuco, UFRPE

Dedico este trabalho à minha mãe, por me incentivar todos os dias ao dizer que me ama e que se orgulha de mim.

AGRADECIMENTOS

À minha mãe, Flávia, por sempre me incentivar, me ajudar com as dificuldades da vida e me tranquilizar nos momentos mais complicados.

Ao meu pai, Luiz, pela ajuda ao longo dos anos, desde à cortar pedaços de cano para os projetos, até as caronas para encurtar o trajeto de ida a faculdade e ao trabalho.

Ao meu orientador, professor Fernando, por ter me aceito como um aluno de iniciação científica ainda no meu segundo ano de graduação e desde então colaborado imensamente com a minha formação pessoal e acadêmica.

Aos resistores, Ricardo e Natasha, pelo suporte ao longo dos anos da graduação, desde as noites em claro na universidade até os churrascos de comemoração, a presença de vocês foi essencial durante toda essa trajetória.

Aos meus colegas de trabalho, Allysson, Cristóvão, Day, Eron, Gabi, Gabor, Iza, Lucas, Manu, Victor e Vitor, pelo companheirismo e suporte ao longo do último ano, que contribuiu para que cada dia fosse vencido de uma vez e sempre mantendo o bom humor, independente da situação.

*A coisa mais bela que podemos experimentar é o mistério.
Essa é a fonte de toda a arte e ciências verdadeiras.
- Albert Einstein*

RESUMO

Doenças cardíacas são uma grande causa de mortes na atualidade. Um indicador típico de doenças cardíacas graves é a pressão arterial elevada, que pode ser usada para auxiliar no diagnóstico de muitas doenças do coração. Contudo, o diagnóstico apropriado de muitas doenças pode requerer um monitoramento contínuo da pressão sanguínea, o que pode ser difícil de se obter, uma vez que o método padrão, baseado no esfigmomanômetro, não permite medições contínuas e a cânula invasiva é custosa, desconfortável para o paciente e necessita de infraestrutura hospitalar. Como alternativa, técnicas aplicando sinais de fotopletismografia (PPG) têm sido propostas recentemente para estimar a pressão arterial. Essas técnicas usam sinais de PPG, que podem ser aferidos através de um sensor não-invasivo, aplicados no dedo do paciente, por exemplo. Avanços recentes na literatura mostram que esses sinais podem ser usados como entradas para modelos de algoritmos de aprendizagem de máquina, com o propósito de estimar a pressão arterial de forma a atender alguns padrões internacionais para equipamentos médicos. Embora o número de trabalhos relacionados a este campo de estudo esteja aumentando, os autores normalmente não disponibilizam suas simulações, o que dificulta a comparação entre essas diferentes abordagens. Este trabalho propõe um *framework* de código aberto para auxiliar na comparação de desempenho entre algoritmos de aprendizagem de máquina, aplicados para estimar a pressão arterial a partir de sinais de PPG. A metodologia utilizada para desenvolver o *framework* é detalhada neste documento e uma comparação de desempenho entre modelos gerados por quatro algoritmos de aprendizagem de máquina (Regressão Linear, Árvore de Decisão, *Random Forest* e *AdaBoost*) é apresentada. A comparação mostra que usando o *framework* proposto, os modelos conseguem alcançar desempenhos semelhantes aos obtidos na literatura.

Palavras-chaves: pressão arterial; fotopletismografia; aprendizagem de máquina; *framework open-source*.

ABSTRACT

Heart diseases are a major cause of death nowadays. A typical sign of a serious heart conditions is the high blood pressure, which can be employed for helping the diagnosis of several heart diseases. However, the proper diagnosis of many heart illness may require a continuous monitoring of blood pressure, which can be difficult to achieve, since the standard sphygmomanometer method does not allow a continuous measurement of blood pressure, and the invasive cannula method is costly, uncomfortable for the patient and requires access to hospital facilities. As an alternative, techniques employing photoplethysmography signals (PPG) have been proposed recently to estimate the blood pressure. These techniques use PPG signals, which can be acquired with a non-invasive sensor that can be applied to the patient's finger, for instance. Recent advances in the literature show that these signals can be used as input for machine learning models to provide an adequate estimation of blood pressure, according to some international standards for medical equipments. Besides an increasing number of studies in this field of knowledge, the authors usually do not make their simulations available, what makes it difficult to compare different approaches. This work proposes an open-source framework to help researchers to compare the performance of machine learning algorithms, employed to estimate the blood pressure using PPG signals. The methodology to develop the framework is presented in detail in this document and a performance comparison of the models generated by four machine learning algorithms (Linear Regression, Decision Tree, Random Forest and AdaBoost) is presented. The comparison show that using the proposed framework, the models achieve performance results similar to those obtained in the literature.

Key-words: blood pressure; photoplethysmography; machine learning; open-source framework.

LISTA DE ILUSTRAÇÕES

Figura 1 – Forma de onda da pressão arterial obtida por um método invasivo.	23
Figura 2 – Modos de operação do sensor utilizado para a aquisição do sinal de PPG.	26
Figura 3 – Forma de onda típica e pontos de destaque do sinal de PPG.	27
Figura 4 – Pulso de PPG e seus pontos chave.	28
Figura 5 – Comparação visual em diagrama de blocos da programação tradicional e da aprendizagem de máquina.	29
Figura 6 – Exemplos de aprendizagem supervisionada e não-supervisionada. Fonte: (SIMEONE, 2018), pág. 2	30
Figura 7 – Exemplo de uma árvore de decisão.	32
Figura 8 – Intervalos que podem ser utilizados para o cálculo do PTT.	34
Figura 9 – Intervalos que podem ser utilizados para o cálculo do PAT.	35
Figura 10 – <i>Features</i> utilizadas para o modelo da rede neural artificial.	39
Figura 11 – <i>Features</i> obtidas a partir da segunda derivada do sinal de PPG.	40
Figura 12 – Diagrama esquemático com as etapas propostas para a estimativa da pressão arterial, proposto em (WANG <i>et al.</i> , 2018)	41
Figura 13 – Diagrama de blocos das etapas propostas para a metodologia.	43
Figura 14 – Separação da gravação de sinais de PPG em gravações de 5 segundos.	45
Figura 15 – Diagrama de blocos com as etapas de pré-processamento a serem realizadas.	45
Figura 16 – Diagrama de blocos com as etapas para detecção do pulso de PPG.	47
Figura 17 – Diagrama de blocos com as etapas para detecção dos pontos chave do sinal de PPG.	49
Figura 18 – Diagrama de blocos para extração das <i>features</i> do sinal de PPG.	51
Figura 19 – Diagrama de blocos das etapas para extração das <i>labels</i> do sinal de ABP.	55
Figura 20 – Diagrama de blocos das etapas para treinamento e validação do modelo de aprendizagem de máquina.	56

Figura 21 – Diagrama de blocos com a relação entre os <i>scripts</i> disponíveis para serem utilizados.	63
Figura 22 – Análise comparativa entre as medidas resumo dos quatro algoritmos avaliados.	67
Figura 23 – Experimento que considera o desempenho do <i>AdaBoost</i> em função da profundidade da árvore.	69
Figura 24 – Experimento que considera o desempenho do algoritmo <i>Random Forest</i> em função da profundidade da árvore.	72

LISTA DE TABELAS

Tabela 1 – Valores de referência para o padrão de avaliação da BHS.	24
Tabela 2 – Resumo dos resultados dos trabalhos apresentados nesta seção .	42
Tabela 3 – Métricas obtidas para o algoritmo de Regressão Linear.	65
Tabela 4 – Métricas obtidas para o algoritmo de Árvore de Decisão.	65
Tabela 5 – Métricas obtidas para o algoritmo de <i>Random Forest</i>	66
Tabela 6 – Métricas obtidas para o algoritmo de <i>AdaBoost</i>	66
Tabela 7 – Métricas obtidas pelos modelos usados no artigo (HASANZADEH; AHMADI; MOHAMMADZADE, 2019).	68
Tabela 8 – Métricas obtidas para a variação da profundidade da árvore com o algoritmo de <i>AdaBoost</i>	70
Tabela 9 – Comparação entre as métricas obtidas com o <i>AdaBoost</i> com profun- didade máxima 20 e com o artigo de referência.	70
Tabela 10 – Métricas obtidas para a variação da profundidade da árvore com o algoritmo <i>Random Forest</i>	72
Tabela 11 – Comparação entre as métricas obtidas com o <i>Random Forest</i> com profundidade máxima 10, 15 e com o artigo de referência.	73

LISTA DE ABREVIATURAS E SIGLAS

AAMI	<i>Association for the Advancements of Medical Instrumentation</i>
ABP	Pressão sanguínea arterial, do inglês <i>Arterial Blood Pressure</i>
Ada	<i>AdaBoost</i>
BHS	<i>Britain Hypertension Society</i>
CORR	Coeficiente de correlação, do inglês <i>Correlation Coefficient</i>
DBP	Pressão sanguínea diastólica, do inglês <i>Diastolic Blood Pressure</i>
DT	Árvore de decisão, do inglês <i>Decision Tree</i>
LiR	Regressão linear, do inglês <i>Linear Regression</i>
MAE	Erro médio absoluto, do inglês <i>Mean Absolute Error</i>
MAP	Pressão arterial média, do inglês <i>Mean Arterial pressure</i>
ME	Erro médio, do inglês <i>Mean Error</i>
PPG	Fotopletismografia, do inglês <i>Photoplethysmography</i>
pyCBPE	<i>python Continuous Blood Pressure Estimation</i>
RF	<i>Random Forest</i>
SBP	Pressão sanguínea sistólica, do inglês <i>Systolic Blood Pressure</i>
STD	Desvio padrão, do inglês <i>Standard Deviation</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	CONTEXTUALIZAÇÃO	16
1.2	JUSTIFICATIVA	18
1.3	OBJETIVOS	18
1.3.1	Geral	18
1.3.2	Específicos	18
1.4	ORGANIZAÇÃO DO TRABALHO	19
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	PRESSÃO ARTERIAL	21
2.1.1	Métodos de medição da pressão arterial	22
2.1.1.1	Esfigmomanômetro	22
2.1.1.2	Cânula invasiva	23
2.1.2	Padrões internacionais de avaliação de instrumentos de medição da pressão arterial	23
2.1.2.1	Association for the Advancements of Medical Instrumentation (AAMI)	24
2.1.2.2	Britain Hypertension Society (BHS)	24
2.2	FOTOPLETISMOGRAFIA	25
2.2.1	Sensor de fotopletismograma	25
2.2.2	Forma de onda típica do sinal do fotopletismograma	26
2.2.2.1	Pontos chave do sinal do fotopletismograma	28
2.3	APRENDIZAGEM DE MÁQUINA	29
3	REVISÃO BIBLIOGRÁFICA	33
3.1	MÉTODOS NÃO INVASIVOS DE MEDIÇÃO DA PRESSÃO ARTERIAL QUE UTILIZAM O SINAL DE PPG	33
3.1.1	Métodos baseados no tempo de trânsito do pulso	33
3.1.2	Métodos baseados no tempo de chegada do pulso	35
3.1.3	Métodos baseados na velocidade da onda do pulso	36

3.1.4	Métodos baseados na análise da onda do pulso	37
3.2	MÉTODOS BASEADOS NA ESTIMAÇÃO DA PRESSÃO ARTERIAL COM PPG E ALGORITMOS DE APRENDIZAGEM DE MÁQUINA	38
4	METODOLOGIA	43
4.1	SELEÇÃO DA BASE DE DADOS	43
4.2	PREPARAÇÃO DA BASE DE DADOS	44
4.3	PRÉ-PROCESSAMENTO DO SINAL DE PPG	45
4.3.1	Remoção de ruídos de alta frequência	45
4.3.2	Remoção do <i>baseline wander</i>	46
4.3.3	Sobre-amostragem dos sinais	46
4.4	DETECÇÃO E NORMALIZAÇÃO DO PULSO DE PPG	47
4.4.1	Detecção de picos do sinal	47
4.4.2	Seleção do pulso central	47
4.4.3	Detecção do pico sistólico	48
4.4.4	Normalização da amplitude do pulso	48
4.5	DETECÇÃO DOS PONTOS-CHAVE	48
4.5.1	Separação das seções do pulso	48
4.5.2	Regressão polinomial	49
4.5.3	Pontos-chave	49
4.6	EXTRAÇÃO DAS <i>FEATURES</i>	50
4.6.1	Frequência cardíaca	51
4.6.2	Volume de pulso normalizado modificado	51
4.6.3	<i>Features</i> relacionadas à área	52
4.6.4	<i>Features</i> relacionadas à amplitude	52
4.6.5	<i>Features</i> relacionadas ao tempo	52
4.6.6	Propriedades da variabilidade da frequência cardíaca	53
4.6.7	Funções não-lineares das <i>features</i>	54
4.7	EXTRAÇÃO DAS LABELS	54
4.8	PÓS-PROCESSAMENTO	55
4.9	TREINAMENTO E VALIDAÇÃO DOS MODELOS	56
4.9.1	Análise de desempenho	57
4.9.1.1	Medidas resumo e de dispersão	57

4.9.1.2	Padrões internacionais de avaliação de instrumentos de medição de pressão arterial	59
4.10	APRIMORAMENTO DOS MODELOS: HIPER PARÂMETROS	59
5	RESULTADOS E DISCUSSÕES	61
5.1	<i>FRAMEWORK OPEN-SOURCE</i>	61
5.1.1	Guia de uso	62
5.2	EXPERIMENTOS	65
5.3	APRIMORAMENTO DOS RESULTADOS	67
6	CONCLUSÃO	76
7	TRABALHOS FUTUROS	78
7.1	EXPANSÃO DA BASE DE DADOS	78
7.2	ESTUDO PARA FAVORECER A SELEÇÃO DE <i>FEATURES</i>	78
7.3	<i>DEEP LEARNING</i>	79
7.4	<i>EMBEDDED MACHINE LEARNING</i>	79
	REFERÊNCIAS	80

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Doenças cardíacas são consideradas um dos maiores problemas de saúde pública na atualidade e são responsáveis por grande parte das mortes ao redor do mundo, especialmente em populações de grandes centros urbanos. De acordo com dados da Organização Mundial de Saúde, 17,3 milhões de pessoas morreram em 2012 como vítimas desses tipos de doenças. A estimativa é que até 2030, este número cresça para 23,6 milhões de vítimas (ORGANIZATION *et al.*, 2014).

Entre as diversas doenças que afetam o coração, a hipertensão arterial é uma doença bastante comum e pode ser usada como um indicativo de que um indivíduo pode estar sendo afetado por alguma patologia cardíaca de natureza mais grave. Embora seu tratamento demande cuidados contínuos, o diagnóstico pode ser realizado de forma bastante simples, através da aferição da pressão arterial, monitorada por um pequeno intervalo (ORGANIZATION *et al.*, 2013). Ao se identificar a hipertensão em seus estágios iniciais, é possível minimizar o risco de ataques cardíacos, falhas cardíacas e falhas renais, favorecendo a detecção precoce de doenças cardíacas. O monitoramento da pressão arterial também pode atuar como um fator de orientação para que as pessoas mudem seus hábitos comportamentais, tornando-se mais saudáveis e auxiliando na prevenção desse tipo de doenças (ORGANIZATION *et al.*, 2013).

Métodos tradicionais aplicados para o monitoramento da pressão arterial, tais como o esfigmomanômetro – um equipamento colocado ao redor do braço do paciente e usado em conjunto com um estetoscópio para a aferição da pressão arterial– ou a utilização de uma cânula, inserida na artéria do paciente, permitem medições que auxiliam nos diagnósticos, mas têm suas limitações. O primeiro método não permite o monitoramento contínuo da pressão arterial, enquanto que o segundo método é invasivo, desconfortável e requer acesso à infraestrutura hospitalar (EL-HAJJ; KYRIACOU, 2020). Por essas razões, é interessante avaliar outras maneiras de medição da pressão arterial que possibilitem o monitoramento contínuo, seguro e mais confortável ao paciente. Nesse contexto, técnicas baseadas em sinais de fotopletagemografia (em

inglês *photoplethysmography* (PPG)) vêm sendo propostas recentemente, como uma alternativa para permitir o monitoramento contínuo e não invasivo da pressão arterial (NYE; ZHANG; FANG, 2015).

O sinal de PPG é um sinal de origem biológica e pode ser utilizado para inferir a variação do volume sanguíneo em um tecido vivo, de forma não invasiva, por meio de um sensor aplicado para captar a variação da luminosidade refletida pelo tecido vivo, que a literatura descreve como sendo relacionada ao volume de sangue no tecido no momento da aferição (HASANZADEH; AHMADI; MOHAMMADZADE, 2019).

Existem diversos benefícios associados ao monitoramento contínuo da pressão arterial utilizando métodos baseados em sinais de PPG – e em sinais de PPG associado a outros sinais biológicos, como o eletrocardiograma (em inglês *electrocardiogram* (ECG)) (KACHUEE *et al.*, 2015) – reportados na literatura, tais como: o favorecimento à identificação de doenças cardíacas que necessitam de um histórico contínuo de aferições da pressão arterial, maior conforto proporcionado ao paciente, menor custo associado ao monitoramento da pressão arterial em relação ao método utilizando a cânula, possibilidade de realização de monitoramento de forma remota, possibilidade de se registrar um histórico de medições realizadas, entre outros. Devido a essas vantagens, existem diversas pesquisas que visam viabilizar a estimativa da pressão arterial apenas por meio do sinal de PPG, realizado em conjunto com técnicas de inteligência artificial e aprendizagem de máquina. (EL-HAJJ; KYRIACOU, 2020).

Embora existam diversos trabalhos que realizem a estimativa da pressão arterial por meio de sinais de fotopletismografia em conjunto com algoritmos de aprendizagem de máquina, em geral, os códigos e simulações utilizados não são disponibilizados pelos autores, o que dificulta a reprodutibilidade da metodologia utilizada no trabalho para eventuais análises de desempenho e comparações com outros algoritmos. Com isso em mente, este trabalho tem como objetivo principal desenvolver uma ferramenta de código aberto com o intuito de avaliar o desempenho de algoritmos de aprendizagem máquina aplicados para realizar a estimação da pressão arterial por meio de sinais de fotopletismografia.

1.2 JUSTIFICATIVA

A ferramenta proposta neste trabalho permitirá a realização de estudos comparativos entre algoritmos aplicados para estimar a pressão arterial a partir de sinais de PPG, comparados a partir de diversas métricas reportadas na literatura. Segundo o conhecimento do autor, ainda não há uma ferramenta livre com as funcionalidades detalhadas ao longo deste texto disponível ao público.

A ferramenta desenvolvida também deve contribuir para o desenvolvimento de estudos nessa linha de pesquisa, com potencial para favorecer o surgimento de novas técnicas de estimação da pressão arterial a partir de sinais de PPG, mais precisas, menos invasivas e mais confortáveis para os pacientes. Sob uma perspectiva mais ampla, os resultados deste trabalho podem auxiliar no desenvolvimento de técnicas aplicadas para o diagnóstico precoce de algumas doenças cardíacas através do monitoramento da pressão arterial, favorecendo o tratamento de doenças em estágios iniciais, menos onerosos aos pacientes e ao sistema público de saúde.

1.3 OBJETIVOS

1.3.1 Geral

Este trabalho tem como objetivo desenvolver o *framework open-source* pyCBPE, nome criado a partir das palavras *python* (linguagem de programação utilizada para desenvolver a ferramenta) e *Continuous Blood Pressure Estimation* (um dos objetivos da ferramenta), que facilite a realização de estudos sobre o desempenho de algoritmos de aprendizagem de máquina e outros tipos de algoritmos que possam ser aplicados para realizar a estimativa contínua da pressão arterial por meio de sinais de fotopleti-mografia.

1.3.2 Específicos

- Elaborar a estrutura de processamento do sinal de PPG para o *framework* proposto com base nas etapas normalmente utilizadas na literatura, detalhando processos de condicionamento dos sinais de PPG para a extração de *features*, uti-

lização de algoritmos de aprendizagem de máquina de diversas naturezas e obtenção das métricas de interesse para posterior comparação entre diferentes técnicas;

- Aplicar quatro algoritmos de aprendizagem de máquina existentes na literatura, sendo eles: Regressão Linear, Árvores de Decisão, *Random Forest* e *AdaBoost*, para realizar a estimativa da pressão arterial a partir de sinais de fotopletismografia, utilizando para isso bases públicas internacionais de medições de sinais de PPG, consideradas para testagem e validação dos algoritmos;
- Comparar o desempenho dos algoritmos de aprendizagem de máquina sugeridos para realizar a estimativa contínua da pressão arterial, utilizando para isso métricas de desempenho usualmente aplicadas na literatura: Erro Médio (ME, do inglês *Mean Error*), Erro Médio Absoluto (MAE, do inglês *Mean Absolute Error*), Desvio Padrão (STD, do inglês *Standard Deviation*) e o Coeficiente de Correlação (CORR), e também padrões de avaliação de instrumentos de medição de pressão arterial tais como o padrões da *Association for the Advancements of Medical Instrumentation* (AAMI) e o da *Britain Hypertension Society* (BHS);
- Documentar e disponibilizar publicamente o *framework* pyCBPE, por meio de um repositório no *Github* para que outros estudantes e pesquisadores possam utilizá-lo para desenvolver novos estudos na área.

1.4 ORGANIZAÇÃO DO TRABALHO

O trabalho está estruturado da seguinte forma: no Capítulo 2, será apresentada a fundamentação teórica deste trabalho, de modo a apresentar os instrumentos de medição da pressão arterial, bem como os sensores utilizados para obter o sinal de fotopletismografia e sua forma de onda típica. No Capítulo 3 é apresentada uma revisão bibliográfica sobre o estado da arte da utilização de sinais de fotopletismografia para estimativa da pressão arterial e sobre a aplicação de algoritmos de aprendizagem de máquina para este fim. Na sequência, o Capítulo 4 detalha a metodologia associada à estruturação do *framework* proposto, detalhando-se as etapas utilizadas para o desenvolvimento da ferramenta e para a avaliação de desempenho dos algoritmos de

aprendizagem de máquina considerados nos testes de validação da ferramenta desenvolvida. Logo após, no Capítulo 5, associado aos resultados e discussões, o *framework* é apresentado em conjunto com a sua forma de utilização, bem como os experimentos realizados. No Capítulo 6, são apresentadas as conclusões obtidas a partir do desenvolvimento do trabalho e dos experimentos realizados. Por fim, no Capítulo 7, que corresponde à seção de trabalhos futuros, são apresentadas possibilidades de melhorias e de futuras continuações e aplicações dos resultados deste trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, é apresentada uma revisão bibliográfica relativa aos conceitos associados à pressão arterial e aos métodos de aferição dessa grandeza, assim como uma explicação mais detalhada sobre o sinal de PPG, métodos de aferição do sinal de PPG e sua utilização em conjunto com algoritmos de aprendizagem de máquina para estimar a pressão arterial de maneira contínua.

2.1 PRESSÃO ARTERIAL

O sangue é transportado do coração para todas as partes do corpo por meio dos vasos sanguíneos. A pressão arterial é a força imposta pelo sangue aos vasos sanguíneos durante o processo de bombeamento (ORGANIZATION *et al.*, 2013).

O bombeamento do sangue é realizado em etapas associadas ao ciclo cardíaco, que é a sequência de eventos que ocorre entre os batimentos cardíacos. O ciclo cardíaco pode ser dividido em duas fases principais: a sístole e a diástole. Na sístole, ou fase de contração, o sangue é bombeado e distribuído para todo o corpo. Na diástole, também conhecida como fase de relaxação, o sangue faz o trajeto inverso, causando a redução da pressão nos vasos sanguíneos (SUN; THAKOR, 2015).

A pressão arterial é registrada em equipamentos de medição por meio de dois valores numéricos distintos, tipicamente apresentados em *displays* de instrumentos digitais em duas linhas separadas, referenciados em milímetros de mercúrio (mmHg). O número apresentado na linha superior é conhecido como pressão sistólica e corresponde à pressão mais elevada observada nos vasos sanguíneos. A pressão sistólica é medida durante a etapa de contração do ciclo cardíaco. O número apresentado na linha inferior indica a pressão diastólica, que corresponde à menor pressão observada nos vasos sanguíneos e ocorre durante a fase de relaxação. O valor de pressão sanguínea típico para um adulto corresponde a uma pressão sistólica de 120 mmHg e uma pressão diastólica de 80 mmHg (ORGANIZATION *et al.*, 2013). Um paciente é classificado como hipertenso quando sua pressão sistólica apresenta um valor igual ou superior a 140 mmHg e sua pressão diastólica apresenta um valor igual ou superior

a 90 mmHg. (ORGANIZATION *et al.*, 2013).

Manter os valores da pressão arterial dentro da faixa normal é um fator de extrema importância para garantir um funcionamento eficiente de órgãos vitais como o coração, cérebro e rins, e também para garantir uma boa saúde e bem estar. Dessa forma, é importante que a pressão arterial seja monitorada regularmente para se ter noção do estado do sistema cardiovascular. (ORGANIZATION *et al.*, 2013)

2.1.1 Métodos de medição da pressão arterial

Existem algumas maneiras comumente utilizadas para a realização da aferição da pressão arterial de indivíduos. A seguir, o esfigmomanômetro e a cânula invasiva são brevemente discutidos.

2.1.1.1 Esfigmomanômetro

O método do esfigmomanômetro é o método de aferição da pressão arterial mais consolidado e muito encontrado em consultórios médicos. Consiste na utilização de uma braçadeira inflável, que normalmente é colocada ao redor do braço do paciente. A braçadeira é inicialmente inflada, enquanto uma pessoa capacitada, usualmente um médico ou enfermeiro, ausculta o fluxo sanguíneo por meio de estetoscópio. Para se ter a aferição da pressão, são realizadas duas leituras, uma durante a fase sistólica e outra na fase diastólica (NYE; ZHANG; FANG, 2015). Os valores das medições são então comparados pelo profissional de saúde com os valores típicos de pressão e, a partir dessa comparação, pode-se constatar se a pressão do paciente é considerada normal ou está alterada.


Devido ao advento das tecnologias digitais, atualmente também existem as versões digitais do esfigmomanômetros, que possuem a capacidade de realizar a aferição da pressão arterial de forma automática. Ressalte-se que, embora seja um método muito consolidado e de baixo custo, o esfigmomanômetro (seja ele digital ou não) não permite aferir os valores de pressão sistólica e diastólica de forma contínua, uma vez que cada nova medição requer a repetição do procedimento de inflar o equipamento e apenas depois realizar a medição (via ausculta ou automaticamente pelo equipamento digital), não sendo possível monitorar a pressão arterial a cada batimento cardíaco.

2.1.1.2 Cânula invasiva

A medição invasiva da pressão utilizando uma cânula é normalmente utilizada em unidades de tratamento intensivo (UTIs) ou durante cirurgias. Essa técnica envolve a medição direta da pressão arterial por meio de uma cânula que é inserida em uma artéria do paciente. Além de ser um método de medição extremamente preciso, também permite que a pressão arterial do paciente seja monitorada constantemente a cada batimento cardíaco. O ponto negativo deste tipo de medição é que por se tratar de um método invasivo, não é aplicável em situações fora do âmbito hospitalar (NYE; ZHANG; FANG, 2015).

Utilizando-se a cânula, é possível obter um sinal contínuo associado à pressão arterial, que pode ser visualizado em tempo real por médicos e técnicos. Um exemplo de um sinal típico obtido por meio do monitoramento via cânula é apresentado na Figura 1.

Figura 1 – Forma de onda da pressão arterial obtida por um método invasivo.



Fonte: Autor

2.1.2 Padrões internacionais de avaliação de instrumentos de medição da pressão arterial

Nesta seção, são descritos os padrões mais utilizados para avaliação de instrumentos de medição da pressão arterial, de modo que esses padrões são indicativos sobre a adequação do instrumento para aplicações com fins clínicos.

2.1.2.1 Association for the Advancements of Medical Instrumentation (AAMI)

Esse padrão de avaliação, definido em (INSTRUMENTATION *et al.*, 1993), indica que o instrumento cumpre com os padrões caso o erro médio e o desvio padrão dos valores de pressão arterial sejam menores que 5 e 8 mmHg, respectivamente. Além disso, é necessário que o método de medição seja validado em pelo menos 85 indivíduos.

2.1.2.2 Britain Hypertension Society (BHS)

Este padrão definido em (O'BRIEN *et al.*, 1990) toma como métrica principal o erro percentual cumulativo. Ou seja, para garantir um determinado padrão de qualidade, é necessário que uma determinada porcentagem dos valores totais do erro absoluto seja menor que um determinado limiar.

A qualidade dos instrumentos é definida com base nas classes A, B, C e D e que utilizam como referência as porcentagens e valores apresentados na tabela 1. Um equipamento é classificado como classe D quando nenhuma das outras classes for atingida. Dessa forma, para que um instrumento seja classificado como classe A, por

Tabela 1 – Valores de referência para o padrão de avaliação da BHS.

Classes	Erro percentual cumulativo		
	≤ 5 mmHg	≤ 10 mmHg	≤ 15 mmHg
Classe A	60%	85%	95%
Classe B	50%	75%	90%
Classe C	40%	65%	85%

Fonte: (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) Adaptado.

exemplo, ele precisa apresentar um erro médio percentual de pelo menos 60% dos valores menores que 5 mmHg, pelo menos 85% dos valores menores que 10 mmHg pelo menos 95% dos valores menores que 15 mmHg.

Com base em (O'BRIEN *et al.*, 1990), para que um equipamento possa ser aprovado para uso clínico, ele deve obter uma nota superior a B.

2.2 FOTOPLETISMOGRAFIA

Fotopletismografia (do inglês *Photoplethysmography*) é a junção das palavras "foto" e "pletismografia". A palavra "pletismografia" se refere à medição do volume de um órgão, principalmente quando este se expande devido a variações das quantidades de ar ou de sangue em seu interior. O prefixo "foto" é utilizado para indicar que a "pletismografia" é obtida por técnicas baseadas na emissão de luz (NYE; ZHANG; FANG, 2015).

A fotopletismografia é uma técnica não invasiva aplicada para a medição do volume sanguíneo através dos tecidos, realizada por meio da emissão de raios de luz (MORAES *et al.*, 2018) em direção ao tecido e do monitoramento da quantidade de luz absorvida ou refletida pelo mesmo. A mudança na quantidade de luz absorvida/refletida está associada à circulação de sangue pelo tecido observado e pode ser relacionada aos processos de sístole e diástole do ciclo cardíaco (SLAPNIČAR; MLAKAR; LUŠTREK, 2019).

As aplicações mais comuns do PPG em uso médico são para medição da frequência cardíaca e saturação do oxigênio (NYE; ZHANG; FANG, 2015). O PPG é uma das tecnologias mais populares da última década quando se trata de monitorar as condições fisiológicas de um paciente. Por se tratar de um método não invasivo, o PPG têm sido utilizado em equipamentos pessoais portáteis (como *wearables*, principalmente em *smart-bands*) e em oxímetros, devido à conveniência e à capacidade de fornecer medições contínuas. Além disso, tem a capacidade de fornecer informações a respeito dos sistemas cardiovascular e respiratório (MORAES *et al.*, 2018).


2.2.1 Sensor de fotopletismograma

A aquisição do sinal de PPG se baseia na iluminação da pele e na medição das mudanças na absorção de luz. O sensor de PPG é usualmente implementado com um emissor de luz, normalmente um diodo emissor de luz (do inglês *light-emitting diode* (LED)) e um fotodetector (fotodiodo) para medir a quantidade de luz que foi transmitida ou refletida pela pele (SLAPNIČAR; MLAKAR; LUŠTREK, 2019).

Existem duas maneiras de funcionamento para os sensores de PPG, que po-

dem fazer a aquisição de medições por meio da transmissão ou da reflexão da luz. Na abordagem baseada na transmissão da luz, o emissor e o fotodetector são posicionados em faces opostas, de tal forma que o tecido fique entre o emissor e o fotodetector. Dessa forma, o fotodetector irá medir a quantidade de luz que foi transmitida através da pele. Na abordagem que considera a reflexão, o emissor e o fotodetector são posicionados lado a lado, de tal forma que o fotodetector consiga medir a quantidade de luz refletida (MORAES *et al.*, 2018). Na Figura 2 são apresentados os dois modos de operação para a aquisição do sinal de PPG.

Figura 2 – Modos de operação do sensor utilizado para a aquisição do sinal de PPG.



Fonte: (MORAES *et al.*, 2018) pág. 8

O sensor é tipicamente colocado em um lóbulo da orelha ou em um dedo do indivíduo e o formato do sinal de PPG aferido dependerá principalmente do fluxo sanguíneo e do oxigênio diluído nos vasos capilares a cada batida do coração, mas também será afetado pela movimentação da pessoa enquanto utiliza o medidor, uma vez que o movimento pode alterar o posicionamento do sensor, inserindo ruídos nas medições (ZHAO *et al.*, 2017).


2.2.2 Forma de onda típica do sinal do fotopleletismograma

O sinal de PPG é composto por duas componentes: uma componente contínua (DC) e uma oscilante (AC). A componente DC representa a absorção constante da luminosidade que passa pelos tecidos, já a componente AC está associada à variação do volume sanguíneo, que é medido pela quantidade de luz absorvida pelo tecido

(MORAES *et al.*, 2018). Além dessas componentes, o sinal de PPG também possui uma componente de baixa frequência, que se dá o nome de *baseline wander*, que é proveniente da respiração do paciente. (AWODEYI; ALTY; GHAVAMI, 2014).

O formato do sinal de PPG está associado a alterações no fluxo sanguíneo, que podem ser capturadas por um sensor óptico adequado. Essa forma de onda é relacionada à sístole e à diástole do ciclo cardíaco (SUWA, 2003). O formato típico do sinal de PPG é apresentado na Figura 3, na qual são identificados alguns pontos de destaque e parâmetros desse sinal. Note-se que o sinal apresentado na figura detalha três pulsos típicos de PPG.

Figura 3 – Forma de onda típica e pontos de destaque do sinal de PPG.



Fonte: (MORAES *et al.*, 2018) pág. 5

Na Figura 3, os pontos destacados são os seguintes:


- O ponto indicado por 2, corresponde ao pico sistólico;
- P_1 corresponde a amplitude do pico sistólico;
- O ponto indicado por 3 corresponde ao pico diastólico;
- P_2 corresponde a amplitude do pico diastólico;
- t_1 é o intervalo entre dois picos sistólicos consecutivos.

Esses pontos são de interesse pois podem ser utilizados em algoritmos para a estimativa da pressão arterial a partir do sinal de PPG, conforme será detalhado em seções posteriores.

2.2.2.1 Pontos chave do sinal do fotopletismograma

Os picos sistólico e diastólico também podem ser chamados de pontos chave do sinal de PPG. Além desses, existem também outros, que são: o ponto de máxima inclinação, o ponto de inflexão e o *dicrotic notch*. Tais pontos são de extrema importância para encontrar parâmetros morfológicos que descrevem o sinal de PPG. (HASANZADEH; AHMADI; MOHAMMADZADE, 2019). Na Figura 4, é apresentada a localização de cada um dos pontos chaves observados em um pulso típico de PPG, já normalizado para o intervalo entre zero e um.

Figura 4 – Pulso de PPG e seus pontos chave.



Fonte: (HASANZADEH; AHMADI; MOHAMMADZADE, 2019)

Na figura, os pontos destacados são os seguintes:

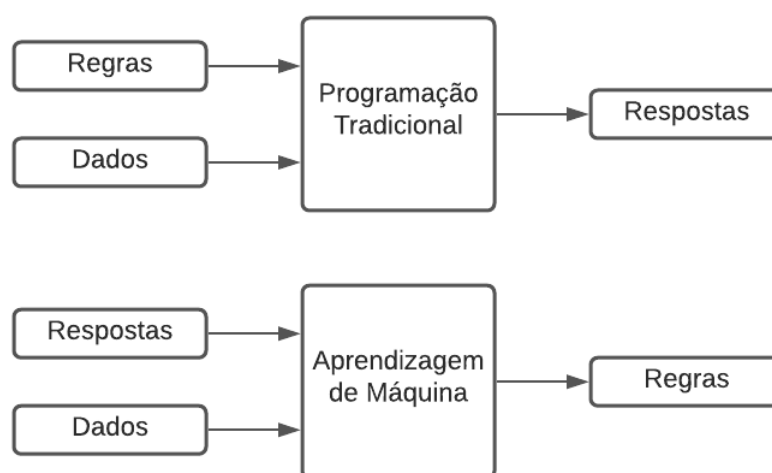
- *Systolic peak* é o pico sistólico do pulso de PPG;
- *Max slope* é o ponto de máxima inclinação do pulso de PPG;
- *Diastolic peak* é o pico diastólico do pulso de PPG;
- *Inflection point* é o ponto de inflexão do pulso de PPG;
- *Dicrotic notch* é a incisura dicrótica ou nó dicrótico do pulso de PPG. O *Dicrotic Notch* está associado à uma pequena deflexão para baixo no pulso arterial que separa a fase sistólica da diastólica (NARA; KAUR; VERMA, 2014);

- O valor x corresponde a amplitude do pico sistólico do pulso de PPG;
- O valor y corresponde a amplitude do ponto de inflexão do pulso de PPG;
- ΔT_{DVP} corresponde ao intervalo entre o pico sistólico e o ponto de inflexão do pulso de PPG.

2.3 APRENDIZAGEM DE MÁQUINA

Diferentemente da programação tradicional, que cria regras explícitas para classificar eventos e/ou dados, os algoritmos de aprendizagem de máquina podem realizar o processo inverso. Isto é, uma vez que existem dados de entrada disponíveis e saídas que representam as respostas a esses dados, o algoritmo de aprendizagem de máquina se propõe a aprender regras que relacionam os dados de entrada com as saídas (RAY, 2019). Na Figura 5, é apresentada uma representação visual das diferenças entre a programação tradicional e os algoritmos de aprendizagem de máquina.

Figura 5 – Comparação visual em diagrama de blocos da programação tradicional e da aprendizagem de máquina.



Fonte: Autor

Existem três categorias principais que envolvem algoritmos de aprendizagem de máquina, que são as seguintes (SIMEONE, 2018):

- Aprendizagem supervisionada


Na aprendizagem supervisionada, o algoritmo aprende com base em conhecimentos prévios, chamados de dados de treinamento, que possuem os parâmetros de entradas e as saídas geradas a partir desses valores. A partir desse conjunto de dados, o objetivo do algoritmo é aprender uma forma de mapear os parâmetros de entrada para obter as saídas desejadas. Um exemplo de aprendizagem supervisionada é apresentado na Figura 6a.

- Aprendizagem não-supervisionada


Nesse caso, não se tem conhecimento a respeito dos valores de saída esperados. Dessa forma, um dos objetivos da aprendizagem não-supervisionada é de agrupar dados com características parecidas e extrair informações a partir dos grupos encontrados. Um exemplo de aprendizagem não-supervisionada é apresentado na Figura 6b.

- Aprendizagem por reforço

A aprendizagem por reforço se encontra num meio termo entre a aprendizagem supervisionada e a não-supervisionada. Para esse caso, existe uma certa forma de supervisão, mas que não parte da especificação de uma saída esperada para cada conjunto de parâmetros de entrada. Ao invés disso, a aprendizagem por reforço recebe um *feedback* do ambiente, que indica se a saída obtida pelo modelo é condizente ou não.



(a) Aprendizagem supervisionada.



(b) Aprendizagem não-supervisionada.

Figura 6 – Exemplos de aprendizagem supervisionada e não-supervisionada. Fonte: (SIMEONE, 2018), pág. 2

Pelo fato deste trabalho se tratar de uma aplicação de aprendizagem supervisionada, a fundamentação a respeito dessa categoria será melhor detalhada a seguir.

Na categoria de aprendizagem supervisionada, existem dois tipos de abordagem, que são:

- Classificação

Nesse tipo de abordagem, os dados de saída são separados em classes, ou seja, tratam-se de variáveis categóricas. Exemplo: prever qual o tipo de flor de íris a partir das dimensões da sua pétala e sépala.

- Regressão

Na regressão, as variáveis preditas se tratam de valores numéricos. Dessa forma, o problema consiste em prever um determinado valor para um conjunto de parâmetros de entrada. Exemplo: prever qual o preço de um imóvel com base na quantidade de quartos e de cômodos que ele possui.

O trabalho em questão se enquadra numa aplicação de regressão, pelo fato dos modelos testados realizarem a predição do valor da pressão arterial. Dessa forma, alguns algoritmos normalmente utilizados para esse tipo de problema são apresentados a seguir.

- Regressão linear

Esse tipo de algoritmo busca uma relação linear entre a variável dependente e a variável independente. No seu caso mais simples, a regressão linear simples apresenta apenas uma variável dependente e uma independente, conforme mostrado em 2.1 (MAULUD; ABDULAZEEZ, 2020).

$$y = \beta_0 + \beta_1 x + \epsilon \quad (2.1)$$

Além disso, também pode ser estabelecida uma relação entre uma única variável dependente e múltiplas variáveis independentes, conforme mostrado em 2.2.


$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_m x_m + \epsilon \quad (2.2)$$

- Árvore de decisão

As árvores de decisão são um dos modelos mais utilizados em aprendizagem de máquina, devido a sua vasta possibilidade de aplicações e também por serem facilmente representadas por um conjunto de regras de "if-else" (MITCHELL *et al.*, 1997).

Uma árvore de decisão se trata de um modelo hierárquico, que pode ser dividido de forma recursiva em conjuntos menores, com base nas regras aprendidas no processo de treinamento (ALPAYDIN, 2020). Na Fig. 7 é apresentada a representação gráfica de uma árvore de decisão.

Figura 7 – Exemplo de uma árvore de decisão.



Fonte: (ALPAYDIN, 2020), pág. 214.

No capítulo a seguir, será apresentada uma revisão bibliográfica sobre trabalhos que utilizam métodos não invasivos de medição da pressão que se baseiam no sinal de fotopletoisografia, com ênfase nos métodos que se baseiam no uso de algoritmos de aprendizagem de máquina. Uma discussão detalhada, comparando diversos aspectos relevantes para a aplicação discutida neste documento é realizada, com o intuito de favorecer a interpretação dos resultados obtidos com a ferramenta *pyCBPE* desenvolvida.

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo, são apresentados alguns métodos recentemente propostos na literatura, não invasivos, utilizados para a medição da pressão arterial através de sinais de PPG. No escopo desta discussão, são abordados desde métodos que utilizam o sinal de PPG em conjunto com outros sinais, como o sinal de eletrocardiografia, até os métodos que utilizam o sinal de PPG em conjunto com técnicas de aprendizagem de máquina.

3.1 MÉTODOS NÃO INVASIVOS DE MEDIÇÃO DA PRESSÃO ARTERIAL QUE UTILIZAM O SINAL DE PPG

Devido ao fato do sinal de PPG ser de fácil aquisição e permitir o monitoramento contínuo de diversos parâmetros de saúde, como o batimento cardíaco e a saturação de oxigênio no sangue, nos últimos anos foram estudadas as possibilidades de se aferir também a pressão arterial a partir deste sinal. Existem diversos métodos que propõem a realização da estimativa da pressão arterial dessa forma, desde métodos que utilizam o sinal de PPG em conjunto com o sinal de eletrocardiografia (em inglês, *Electrocardiogram* (ECG)), até métodos que modelam a relação do PPG com a pressão arterial por meio de modelos de aprendizagem de máquina (EL-HAJJ; KYRIACOU, 2020). Nas próximas subseções, algumas dessas abordagens serão apresentadas.


3.1.1 Métodos baseados no tempo de trânsito do pulso

O tempo de trânsito do pulso (em inglês *Pulse Transit Time* (PTT)) é definido como o tempo que um pulso proveniente de um ciclo cardíaco leva para viajar do coração à um outro ponto do sistema cardiovascular (MUKKAMALA *et al.*, 2015).

Métodos baseados no tempo de trânsito de pulso são utilizados em função da relação inversamente proporcional entre o tempo de trânsito de pulso e a pressão arterial (EL-HAJJ; KYRIACOU, 2020). Para medir este parâmetro, é necessário utilizar dois sensores (podendo ser ambos de PPG ou um de PPG e outro de ECG) posicionados em diferentes locais do corpo, normalmente os dedos das mãos, dos pés ou lóbulos

da orelha. O tempo de trânsito de pulso é estimado por meio do atraso entre o sinal proximal (mais próximo do coração) e o distal (mais distante do coração), em relação ao coração do indivíduo (MORAES *et al.*, 2018). Quando utilizados dois sensores de PPG, também pode ser medido de outras formas, como a diferença de tempo entre o ponto central da borda de descida do PPG proximal e o pico sistólico do PPG distal, ou também como a diferença de tempo entre o *dicrotic notch* do PPG proximal e o pico sistólico do PPG distal (SHARMA *et al.*, 2017). Na Figura 8 são apresentadas algumas formas de se obter o PTT a partir de dois sinais de PPG.

Figura 8 – Intervalos que podem ser utilizados para o cálculo do PTT.



Fonte: (EL-HAJJ; KYRIACOU, 2020) pág. 3

Na Figura 8, (a), (b) e (c) indicam:

- (a) é o intervalo entre os pontos iniciais dos sinais de PPG;
- (b) é o intervalo entre o pico sistólico e o *dicrotic notch*;
- (c) é o intervalo entre o pico sistólico e o ponto central da borda de descida;

Existem algumas desvantagens ao utilizar esse método. A principal desvantagem está associada à necessidade de se utilizar dois sensores para a aquisição dos

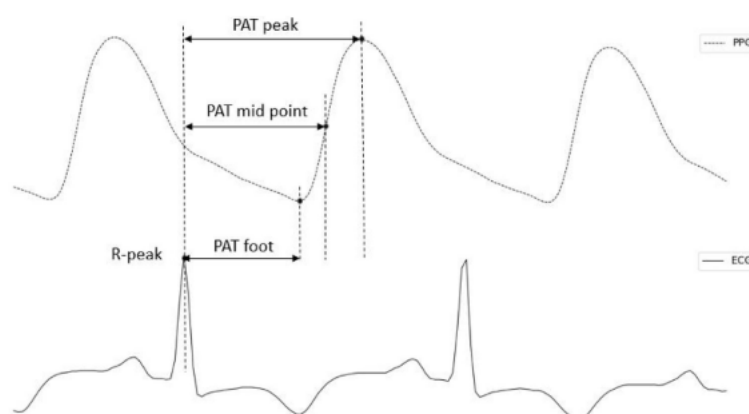
sinais de PPG. Além disso, o sinal de PPG está sujeito a diversas interferências que são causadas por conta do movimento do usuário, o que cria a necessidade de utilizar técnicas adicionais para tratamento dos sinais (EL-HAJJ; KYRIACOU, 2020).

3.1.2 Métodos baseados no tempo de chegada do pulso

O tempo de chegada do pulso (em inglês *Pulse Arrival Time (PAT)*) é definido como o intervalo entre a ativação elétrica do coração e a chegada da onda de pulso até uma localização do corpo, como o dedo do pé ou da mão. Em outras palavras, o PAT pode ser definido como a soma do PTT com o período de pré-ejeção (em inglês *Pre-ejection Period (PEP)*)(MUKKAMALA *et al.*, 2015). O PEP é o tempo necessário para converter o sinal elétrico em uma força de bombeamento mecânica e a contração isovolumétrica para abrir as válvulas aórticas (SHARMA *et al.*, 2017).

O PAT usualmente é medido por meio de dois sensores, um de ECG e um de PPG. Este parâmetro pode ser estimado pelo intervalo entre o ponto máximo do sinal de ECG (também conhecido como pico R) e alguns pontos do sinal de PPG, podendo ser o: ponto inicial, ponto médio e ponto máximo da borda de subida (EL-HAJJ; KYRIACOU, 2020). Na Figura 9, são apresentados os intervalos que podem ser utilizados para o cálculo do PAT.

Figura 9 – Intervalos que podem ser utilizados para o cálculo do PAT.



Fonte: (EL-HAJJ; KYRIACOU, 2020) pág. 4

Alguns estudos indicam que o PAT não é indicado para estimar a pressão sistólica e diastólica, quando comparado ao PTT. Em (ZHANG *et al.*, 2011) foi realizado um estudo comparativo entre o PTT e o PAT para estimar a pressão sistólica e diastólica,

no qual o método que utiliza o PAT apresentou um erro médio quadrático (do inglês *Root Mean Squared Error* (RMSE) mais elevado.

Por necessitar de dois sensores, este tipo de método apresenta desvantagens parecidas às do método que usa o PTT. Como são utilizados dois sensores de diferentes tipos, estes podem conter taxas de amostragem diferentes, o que dificulta o sincronismo entre os sinais. Além disso, os dois sensores também estão sujeitos a ruídos provenientes do movimento, o que cria a necessidade de etapas de processamento para ambos os sinais. E, por fim, os métodos com PAT necessitam de calibração (EL-HAJJ; KYRIACOU, 2020).

3.1.3 Métodos baseados na velocidade da onda do pulso

A velocidade da onda do pulso (do inglês *Pulse Wave Velocity* (PWV)) é a velocidade do fluxo sanguíneo (SLAPNIČAR; MLAKAR; LUŠTREK, 2019). Técnicas que utilizam PWV se baseiam no fato de que há uma relação bem estabelecida entre a velocidade da onda do pulso e a pressão arterial. Essa relação tem como motivação o fato de que o sangue é transportado com uma velocidade mais elevada quando os vasos estão mais contraídos, de modo a exercer uma pressão mais elevada nos vasos sanguíneos. De forma análoga, quando os vasos estão mais relaxados, o sangue apresenta uma velocidade menor e, com isso, uma pressão mais baixa é exercida (SLAPNIČAR; MLAKAR; LUŠTREK, 2019).

A PWV é medida por meio de dois sensores, que são posicionados em um mesmo ramo arterial e com uma distância conhecida entre eles. A PWV pode ser obtida através do cálculo da razão entre o comprimento da artéria e o PTT, conforme apresentado na equação 3.1 a seguir,

$$PWV = \frac{D}{PTT}, \quad (3.1)$$

em que:

- D é a distância da entre os dois sensores;
- PTT é o tempo de trânsito do pulso.

Em (MCCOMBIE; REISNER; ASADA, 2006) é apresentado um método para estimar a velocidade da onda do pulso com o uso de dois sensores de PPG. Nesse mesmo trabalho, também é proposto um método de calibração das medições da PWV para a estimativa da pressão arterial. Os resultados deste trabalho indicam que o método proposto é capaz de medir alterações no PWV que são provenientes de flutuações da pressão arterial média.

Esse método tem como dificuldade o fato de necessitar de uma intervenção invasiva, principalmente por conta da necessidade de estimar o comprimento da artéria. Além disso, também apresenta como desvantagens a necessidade do uso de dois sensores, a variação da elasticidade da artéria entre os indivíduos, que pode estar associada a diversos fatores, tais como a idade e dieta. Por fim, a técnica também necessita de calibração para o instrumento (EL-HAJJ; KYRIACOU, 2020).

3.1.4 Métodos baseados na análise da onda do pulso

A análise da onda do pulso (do inglês *Pulse Wave Analysis* (PWA)) utiliza técnicas de processamento de sinais e da extração de características temporais, morfológicas e espectrais do sinal de PPG. Uma das vantagens desse método é a necessidade de utilizar apenas um sensor de PPG (EL-HAJJ; KYRIACOU, 2020).

As desvantagens deste método estão diretamente relacionadas ao fato do sinal de PPG estar sujeito a ruídos por conta do movimento do indivíduo, que afeta o posicionamento do sensor de aferição e também por não existir uma relação bem estabelecida entre o sinal de PPG e a pressão arterial (ELGENDI, 2012).

Entretanto, existem técnicas que visam minimizar o efeito de fontes de ruído, como o movimento. Em (RAM *et al.*, 2011), é apresentado um método que é capaz de estimar o ruído proveniente de artefatos de movimento por meio da criação de um sinal de ruído sintético, que é posteriormente utilizado como entrada de um filtro adaptativo. Os resultados encontrados mostraram que a utilização deste método contribuiu para uma melhor estimativa dos valores da saturação do oxigênio.

Normalmente as técnicas PWA servem como uma etapa de preparação para o desenvolvimento de modelos de aprendizagem de máquina com o objetivo de modelar a relação entre o sinal de PPG e a pressão arterial (EL-HAJJ; KYRIACOU, 2020).

3.2 MÉTODOS BASEADOS NA ESTIMAÇÃO DA PRESSÃO ARTERIAL COM PPG E ALGORITMOS DE APRENDIZAGEM DE MÁQUINA

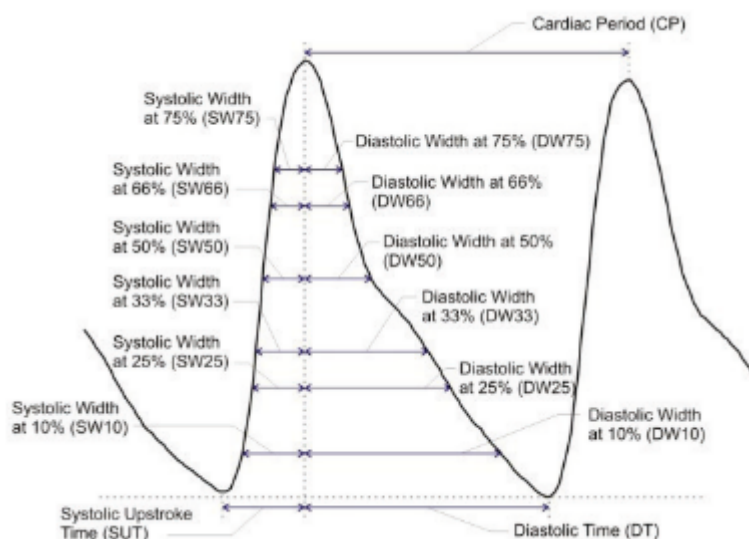
Recentemente, técnicas que utilizam algoritmos de aprendizagem de máquina vêm sendo propostas como uma nova alternativa para estimar a pressão arterial a partir de sinais de PPG. A motivação para essa abordagem está associada à versatilidade dessas técnicas para aprender modelos a partir de medições de sinais de PPG utilizados para o treinamento dos algoritmos, que demonstram resultados promissores no que se refere a métricas baseadas em padrões internacionais para avaliação de instrumentos de aferição da pressão arterial.

A seguir, são apresentados alguns trabalhos que utilizam algoritmos de aprendizagem de máquina para desenvolver modelos que realizam a estimativa da pressão arterial com base no sinal de PPG e suas características.

Em (TENG; ZHANG, 2003), foi investigada a possibilidade de realizar a estimativa da pressão arterial através da aquisição do sinal de PPG por meio de apenas um sensor de PPG conectado ao indivíduo. No experimento apresentado nesse trabalho, foi utilizado como base de dados os sinais de PPG e as medições de pressão arterial de 15 sujeitos do sexo masculino com idade entre 24 e 30 anos. Os parâmetros (também referenciados como *features*) extraídos dos sinais de PPG foram o tempo sistólico, tempo diastólico e a largura do pulso em $\frac{1}{3}$ e $\frac{2}{3}$ da amplitude total. Cada um desses parâmetros foi utilizado para criar um modelo de regressão linear para estimar a pressão arterial. Com isso, o coeficiente de correlação de cada modelo foi comparado ao valor real e foi observado que o tempo diastólico foi a *feature* que apresentou a maior correlação com os valores da pressão sistólica e diastólica.

Em (KURYLYAK; LAMONACA; GRIMALDI, 2013), foram propostas novas *features* além das apresentadas em (TENG; ZHANG, 2003). Tais *features* foram obtidas a partir da largura do pulso do PPG em diferentes amplitudes para a parte sistólica e diastólica do sinal, e também a razão entre as duas partes. Na Figura 10 são apresentadas algumas dessas *features*. No trabalho citado, foi proposto o uso de uma rede neural artificial para modelar a relação entre o sinal de PPG e a pressão arterial. Como resultado, o modelo encontrado satisfaz o critério proposto em (INSTRUMENTATION *et al.*, 1993) de apresentar medições com erro médio menor que 5 mmHg e desvio

Figura 10 – *Features* utilizadas para o modelo da rede neural artificial.




Fonte: (KURYLYAK; LAMONACA; GRIMALDI, 2013) pág. 3

padrão menor que 8 mmHg em testes com pelo menos 85 indivíduos. Dessa forma, foi possível mostrar que é possível estimar a pressão arterial por meio do sinal de PPG de modo a cumprir um dos padrões internacionais de qualidade de medição.

Em (LIU; PO; FU, 2017), é proposta a utilização da segunda derivada do sinal de PPG para extrair *features* do sinal de PPG. Essa proposta se dá por conta de estudos apresentarem que a segunda derivada do PPG contém informações a respeito da rigidez das artérias, que é um parâmetro relacionado a pressão arterial. Dessa forma, foram propostas 14 novas *features* extraídas a partir do sinal da segunda derivada em conjunto com as 21 *features* propostas em (KURYLYAK; LAMONACA; GRIMALDI, 2013) para desenvolver um modelo de *Support Vector Regression* (SVR). As *features* propostas são apresentadas na Figura 11. Os resultados obtidos em (LIU; PO; FU, 2017) apresentaram uma melhora de 40% de precisão na estimativa da pressão arterial em comparação ao modelo proposto em (KURYLYAK; LAMONACA; GRIMALDI, 2013).

Em (WANG *et al.*, 2018) é proposta uma abordagem de utilizar o método *Multi-taper* (MTM), utiliza as componentes espectrais do sinal para obter parte das *features*, em conjunto com duas outras *features* relacionadas à morfologia do sinal de PPG. O modelo utilizado se baseia em uma rede neural artificial. Na Figura 12, é apresentado um diagrama esquemático com as etapas propostas para realizar a estimativa da pressão arterial. Os resultados deste trabalho apresentaram um erro médio absoluto de

Figura 11 – *Features* obtidas a partir da segunda derivada do sinal de PPG.

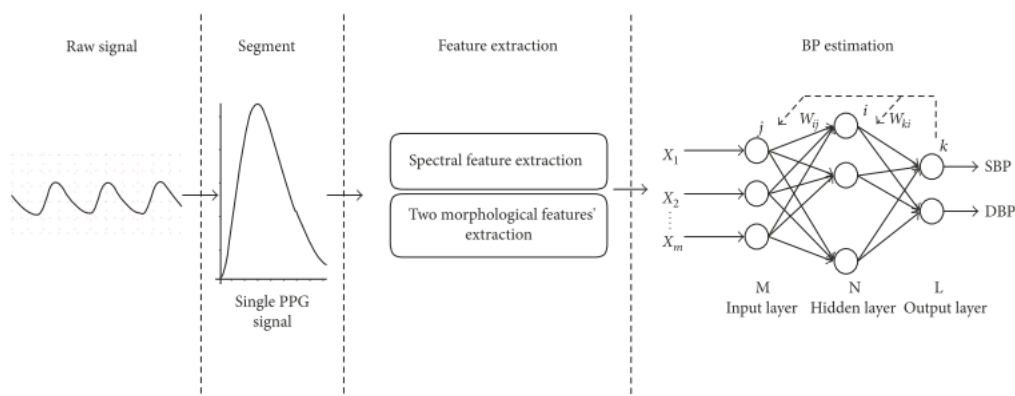


Fonte: (LIU; PO; FU, 2017) pág. 2

4.02 ± 2.79 mmHg para a pressão sistólica e 2.27 ± 1.82 mmHg para a pressão diastólica. Dessa forma, este método também cumpre com os critérios detalhados em (INSTRUMENTATION *et al.*, 1993) para a aplicação clínica.

Em (KHALID *et al.*, 2018) foram testados três diferentes algoritmos de aprendizagem de máquina com o objetivo de analisar qual apresentava o melhor desempenho na estimação a pressão arterial. Os algoritmos testados foram: Regressão Linear Múltipla (do inglês *Multiple Linear Regressor (MLR)*), Árvore de decisão (do inglês *Decision Tree (DT)*) e Máquinas de Vetor Suporte (do inglês *Support Vector Machine (SVM)*). Inicialmente foram propostas 5 *features*, das quais foram usadas apenas 3, por serem classificadas como mais representativas por meio do teste de multicolinearidade, que é uma medida de correlação entre as variáveis preditores (KHALID *et al.*, 2018). A árvore de decisão foi o algoritmo que apresentou o melhor resultado, com erro médio de -0.1 ± 6.5 mmHg para a pressão sistólica e -0.6 ± 5.2 mmHg para a pressão diastólica.

Figura 12 – Diagrama esquemático com as etapas propostas para a estimativa da pressão arterial, proposto em (WANG *et al.*, 2018)



Fonte: (WANG *et al.*, 2018) pág. 3

Em (KHALID *et al.*, 2020) é proposto um método inovador em duas etapas para estimar a pressão arterial por meio de sinais de PPG. Este método consiste em utilizar um modelo de classificação e de regressão em cascata. O classificador tem como objetivo classificar a pressão arterial em uma das três classes definidas. Após a classificação, os dados passam por um modelo de regressão treinado apenas para aquela classe em específico, o que o torna mais preciso. Para isso, foram utilizadas inicialmente 17 *features*, de modo que a partir do teste de multicolinearidade, foram escolhidas apenas 3. Em geral, o algoritmo em duas etapas atingiu os requisitos de (INSTRUMENTATION *et al.*, 1993), com erro médio de 0.07 ± 7.1 mmHg para a pressão sistólica e -0.08 ± 6.0 mmHg.

Em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) são propostos algoritmos para detecção dos pontos-chave do sinais de PPG. Tais pontos são fundamentais para a extração das *features* do sinal de PPG desse trabalho, uma vez que são *features* baseadas na morfologia do sinal. São avaliados o desempenho de 4 algoritmos de aprendizagem de máquina: Regressão Linear, Árvore de Decisão, *Random Forest* (RF) e *AdaBoost*. O modelo que apresentou o melhor resultado foi o *AdaBoost*, com erro médio absoluto de 8.22 ± 10.38 mmHg para a pressão sistólica e 4.17 mmHg ± 4.22 mmHg segundo os critérios da (INSTRUMENTATION *et al.*, 1993) e foram obtidas as notas A para a pressão diastólica e C para a pressão diastólica com base no critério de (O'BRIEN *et al.*, 1990).

A Tabela 2 a seguir apresenta um breve resumo sobre as bases de dados, os al-

goritmos de melhor desempenho e os resultados apresentados para esses algoritmos, quando considerados os trabalhos sobre aplicações de algoritmos de aprendizagem de máquina para estimação da pressão arterial, a partir de sinais de PPG. Como detalhado nesta seção e na tabela, os resultados atendem a padrões internacionais para definir se instrumentos são adequados para a aplicação real e também serviram como motivadores para a elaboração deste trabalho de conclusão de curso.

Tabela 2 – Resumo dos resultados dos trabalhos apresentados nesta seção

Trabalho	Base de dados	Algoritmo de melhor desempenho	Resultado obtido	
			SBP (mmHg)	DBP (mmHg)
1	Base de dados privada	Regressão Linear	0.21 ± 7.32 (ME ± STD)	0.02 ± 4.39 (ME ± STD)
2	MIMIC Database	Rede Neural Artificial	3.80 ± 3.46 (MAE ± STD)	2.21 ± 2.09 (MAE ± STD)
3	MIMIC II Database	Support Vector Regression	8.54 ± 10.9 (MAE ± STD)	4.34 ± 5.8 (MAE ± STD)
4	MIMIC Database	Rede Neural Artificial	4.02 ± 2.79 (ME ± STD)	2.27 ± 1.82 (ME ± STD)
5	Queensland Vital Signs	Árvore de Decisão	0.1 ± 6.5 (ME ± STD)	-0.6 ± 5.2 (ME ± STD)
6	Queensland Vital Signs + MIMIC II	Método em duas etapas Classificador e Regressor	0.07 ± 7.1 (ME ± STD)	-0.08 ± 6.0 (ME ± STD)
7	UCI Machine Learning Repository	AdaBoost	8.2 ± 10.38 (MAE ± STD)	4.17 ± 4.2 (MAE ± STD)

Fonte: Autor.

Na Tabela 2, os números de 1 a 7 identificam os seguintes trabalhos:

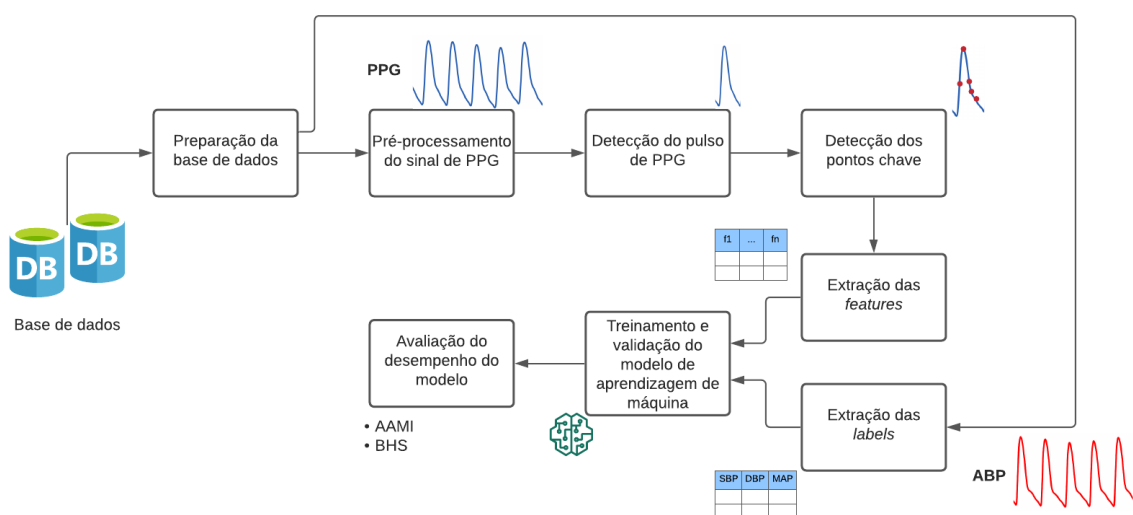
1. (TENG; ZHANG, 2003)
2. (KURYLYAK; LAMONACA; GRIMALDI, 2013)
3. (LIU; PO; FU, 2017)
4. (WANG *et al.*, 2018)
5. (KHALID *et al.*, 2018)
6. (KHALID *et al.*, 2020)
7. (HASANZADEH; AHMADI; MOHAMMADZADE, 2019)

4 METODOLOGIA

Nesta seção, serão descritas as etapas consideradas para o desenvolvimento do *framework* proposto. Para a elaboração da ferramenta, utilizou-se como referência principal o trabalho de (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), a partir do qual se elaborou a sequência de etapas para a realização do processamento do sinal de PPG e também a partir do qual foram definidos os algoritmos utilizados para a testagem e validação da proposta deste trabalho.

Na Figura 13 é apresentado um diagrama de blocos com as etapas propostas e que serão descritas nas seções a seguir.

Figura 13 – Diagrama de blocos das etapas propostas para a metodologia.



Fonte: Autor

4.1 SELEÇÃO DA BASE DE DADOS

Por se tratar de um trabalho que envolve algoritmos de aprendizagem de máquina, a base de dados deve ser o primeiro item a ser especificado, uma vez que será a partir dela que o modelo irá ser desenvolvido.

Para cumprir com um dos objetivos deste trabalho, que é estimar a pressão arterial por meio de sinais de fotopletismografia, definiu-se que a base de dados a ser escolhida precisaria cumprir com os seguintes requisitos:

- Conter gravações de sinais de PPG;
- Conter as gravações do sinal de pressão arterial, obtido através do método invasivo ou os valores de pressão sistólica, diastólica e média adquiridas no mesmo instante da aquisição do sinal de PPG.

Diante desses requisitos, optou-se por utilizar a base de dados disponível no repositório de aprendizagem de máquina da Universidade da Califórnia. Essa base de dados foi utilizada no trabalho de (KACHUEE *et al.*, 2015), que realizou etapas prévias de pré-processamento e validação e posteriormente também utilizada em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019).

A base de dados contém 12000 gravações dos seguintes sinais, que foram amostrados com uma frequência de 125 Hz e possuem tempo variável de duração:

- Sinal de fotopletismografia (PPG), obtido a partir da ponta do dedo;
- Sinal de pressão arterial (ABP, do inglês *Arterial Blood Pressure*), obtido por meio de medição invasiva;
- Sinal de eletrocardiografia (ECG).


Para este trabalho, foram utilizados somente as gravações dos sinais de PPG e de ABP.

4.2 PREPARAÇÃO DA BASE DE DADOS

Devido ao tempo de gravação variável observado nos sinais oriundos da base de dados escolhida, foi necessário realizar uma etapa de preparação dos sinais para garantir que apresentassem a mesma duração. Para realizar essa padronização, as gravações dos sinais de PPG e de ABP foram particionadas em gravações de duração de 5 segundos, conforme utilizado em (KHALID *et al.*, 2018).

Na Figura 14 é ilustrado o procedimento utilizado para obtenção de segmentos com duração de 5 segundos a partir de sinais disponíveis na base de dados.

Figura 14 – Separação da gravação de sinais de PPG em gravações de 5 segundos.



Fonte: Autor

4.3 PRÉ-PROCESSAMENTO DO SINAL DE PPG

A etapa de pré-processamento dos sinais é necessária para facilitar a identificação dos pontos-chave presentes no sinal de PPG. Na Figura 15, é apresentado um diagrama de blocos que contém as etapas de pré-processamento propostas, que serão detalhadas nas seções a seguir.

Figura 15 – Diagrama de blocos com as etapas de pré-processamento a serem realizadas.



Fonte: Autor

4.3.1 Remoção de ruídos de alta frequência

O sinal de PPG pode sofrer influência de alguns ruídos externos, principalmente por conta do movimento do usuário. Tais ruídos normalmente possuem componentes

de frequência mais elevadas, que dificultam a detecção dos pontos-chave. Por conta disso, como recomendado em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), foi utilizado um filtro passa-baixas de Chebyshev do tipo I com uma frequência de corte de 10 Hz. Com o intuito de evitar alterações na fase do sinal, o filtro foi implementado com o método *forward-backward*, conforme proposto em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019).

4.3.2 Remoção do *baseline wander*

Conforme apresentado no Capítulo 2, além da componente AC que contém a informação das variações de fluxo sanguíneo, o sinal de PPG também possui componente de baixa frequência (normalmente entre 0,15 e 0,5 Hz) chamada de *baseline wander*, que surge devido à respiração do paciente. (AWODEYI; ALTY; GHAVAMI, 2014). Para grande parte das etapas da metodologia proposta neste trabalho, esta componente deve ser desconsiderada. Por isso, faz-se necessário obter uma versão do sinal de PPG sem a influência do *baseline wander*. Para isso, foi utilizado o método em duas etapas proposto em (AWODEYI; ALTY; GHAVAMI, 2014), que utiliza dois estágios, cada um com um filtro de mediana móvel, de modo que o primeiro tem o tamanho de janela de 0,3 vezes a frequência de amostragem e o segundo com tamanho de janela de 0,6 vezes a frequência de amostragem. Uma vez que a saída final do método em duas etapas foi obtida, é realizada a diferença entre o sinal de PPG e o sinal de saída do filtro para obter-se o sinal sem o *baseline wander*.


4.3.3 Sobre-amostragem dos sinais

Após as etapas de filtragem, a etapa final de pré-processamento consiste em sobre-amostrar o sinal de 125 Hz para 500 Hz. Essa etapa é realizada com o objetivo de facilitar uma etapa futura de regressão polinomial e assim, melhorar a precisão da etapa de detecção de pontos chave, além de também tornar possível a utilização de pulsos de PPG que não possuíssem pontos suficientes para a etapa de regressão polinomial.

4.4 DETECÇÃO E NORMALIZAÇÃO DO PULSO DE PPG

Com o segmento de sinal de PPG devidamente pré-processado, a etapa seguinte consiste em obter um único pulso de PPG a partir desse sinal e normalizar a amplitude deste pulso. Como forma de ilustrar as etapas necessárias, na Figura 16 é apresentado um diagrama de blocos com os procedimentos que foram utilizados para obter o pulso central do segmento.

Figura 16 – Diagrama de blocos com as etapas para detecção do pulso de PPG.



Fonte: Autor

4.4.1 Detecção de picos do sinal

O sinal de PPG possui mínimos locais que podem ser usados para definir o início de um novo pulso. Dessa forma, cada pulso de PPG está contido entre dois mínimos locais do sinal. Para detectar os mínimos locais, foi utilizado o algoritmo de *Automatic Multiscale-based Peak Detection* (AMPD) desenvolvido em (SCHOLKMANN; BOSS; WOLF, 2012). Este algoritmo se mostra como uma boa opção para a detecção de mínimos locais por não depender de parâmetros como limites superiores para os máximos ou tamanhos de janela específicos. Além disso, esse método apresenta um bom desempenho em sinais periódicos e quase periódicos, que é o caso do sinal de PPG (HASANZADEH; AHMADI; MOHAMMADZADE, 2019).

4.4.2 Seleção do pulso central

Com os mínimos locais detectados, o pulso central é escolhido como sendo o pulso que se encontra entre os mínimos centrais do segmento de PPG. O pulso central é considerado para a análise por conta do sinal de PPG não apresentar grandes variações em um curto intervalo de tempo.

4.4.3 Detecção do pico sistólico

A detecção do pico sistólico é o primeiro procedimento a ser realizado, uma vez que esse ponto pode ser usado como referencial para dividir o sinal em duas seções, conforme será visto a seguir. A detecção desse ponto notável utiliza o fato de o pico sistólico ser o máximo global do pulso de PPG.

4.4.4 Normalização da amplitude do pulso

A normalização da amplitude necessita primeiramente da posição do pico sistólico do pulso de PPG. Com base na posição deste ponto, o pulso de PPG será dividido em duas partes, uma ascendente – que fica à esquerda do pico sistólico – e uma descendente – que fica à direita do pico sistólico. Cada uma dessas seções é normalizada de forma independente para o intervalo $[0, 1]$ e o sinal resultante da normalização é a junção dessas duas partes.

Com essas etapas devidamente realizadas, o próximo passo consiste em detectar os pontos-chave a partir do sinal normalizado.

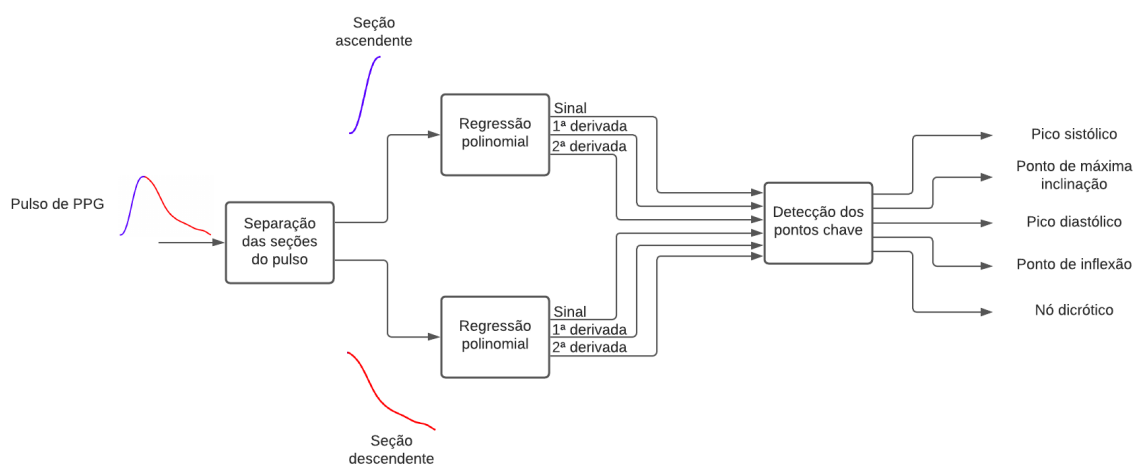
4.5 DETECÇÃO DOS PONTOS-CHAVE

A etapa de detecção dos pontos-chave consiste em encontrar a posição dos pontos específicos do sinal de PPG que carregam as informações morfológicas do sinal. Como forma de ilustrar os processos que estão contidos nessa seção, na Figura 17 é apresentado um diagrama de blocos com as etapas que foram realizadas.

4.5.1 Separação das seções do pulso

Utilizando o pico sistólico que já foi encontrado na etapa de normalização da amplitude do pulso, o pulso normalizado de PPG é separado em duas seções, uma seção ascendente, que vai do ponto inicial do pulso até o ponto do pico sistólico e uma seção descendente, que vai do ponto do pico sistólico até o ponto final do pulso. Essas seções servirão como ponto de partida para as próximas etapas de identificação de diversas *features*.

Figura 17 – Diagrama de blocos com as etapas para detecção dos pontos chave do sinal de PPG.



Fonte: Autor

4.5.2 Regressão polinomial

Os algoritmos de detecção dos pontos chave restantes (que não sejam o pico sistólico) se baseiam na primeira e na segunda derivada dos segmentos ascendente e descendente do pulso normalizado de PPG. Dessa forma, para facilitar a obtenção das derivadas, foi realizada uma etapa de regressão polinomial, com o objetivo de encontrar uma equação polinomial que represente cada uma das seções. Para a seção ascendente, foi utilizado um polinômio de grau 5. Já para a seção descendente, foi utilizado um polinômio de grau 7, conforme proposto em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019). Uma vez que os polinômios e suas derivadas foram obtidos, as etapas a seguir consistem em encontrar a localização dos pontos chave restantes.

4.5.3 Pontos-chave

Em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) foram propostos os métodos descritos abaixo para encontrar os pontos-chave do sinal de PPG:

- Ponto de máxima inclinação

O ponto de máxima inclinação é definido como o ponto máximo da primeira deri-

vada da seção ascendente.

- Pico diastólico

O pico diastólico pode não ser facilmente encontrado em alguns sinais de PPG, uma vez que o sinal de PPG pode ser um pouco diferente do sinal típico (apresentado na seção de fundamentação teórica), o que pode tornar a detecção do pico diastólico uma tarefa complexa. Por esse motivo, é necessário tomar a segunda derivada da seção descendente em conjunto à primeira derivada.

O ponto do pico diastólico é considerado como a posição em que a primeira derivada do segmento descendente é nula e a segunda derivada é negativa. Caso esse ponto não exista, então o pico diastólico é considerado na posição na qual a segunda derivada é um mínimo local.

- *Dicrotic notch*

O *dicrotic notch* é o ponto em que a segunda derivada da seção descendente é um máximo local e é localizado antes do pico diastólico.

- Ponto de inflexão

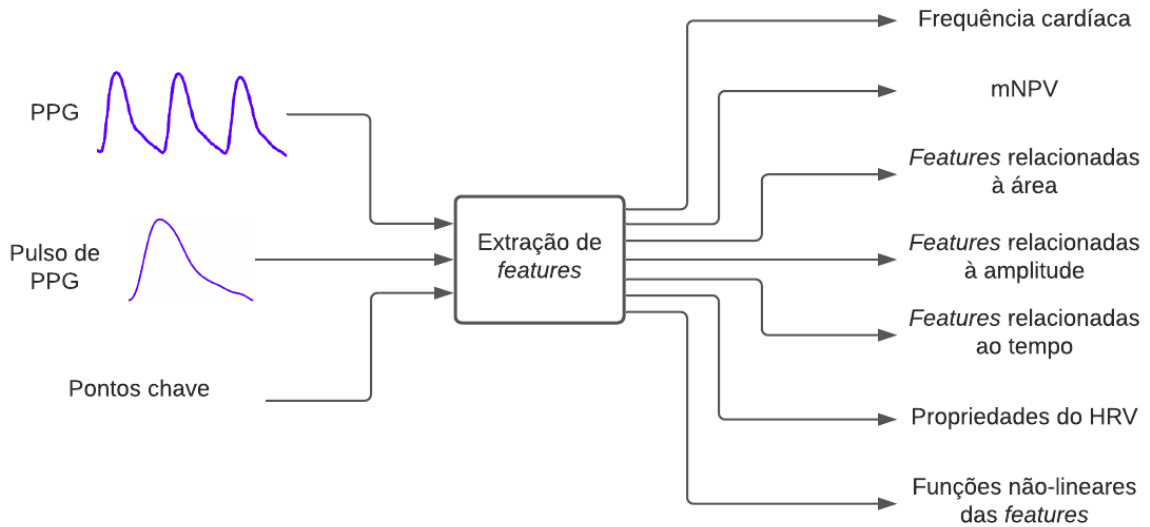
O ponto de inflexão se encontra entre o nó dicrotíco e o pico diastólico. Este ponto corresponde ao ponto em que a segunda derivada da seção descendente é igual a zero. Se este ponto não existir, o ponto de inflexão é considerado como o ponto central entre o nó dicrotíco e o pico diastólico.

4.6 EXTRAÇÃO DAS FEATURES

As *features* são os dados que servem como entrada para os algoritmos de aprendizagem de máquina, que irão contribuir para a elaboração de um modelo a partir do qual será possível estimar os valores de pressão arterial. Existem diversas *features* que podem ser extraídas a partir do sinal de PPG. Neste trabalho, foram utilizadas as *features* consideradas em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019).

Na Figura 18 são apresentadas as categorias das *features* consideradas e a seguir será detalhado o processo utilizado para extrair as *features* utilizadas.

Figura 18 – Diagrama de blocos para extração das *features* do sinal de PPG.



Fonte: Autor

4.6.1 Frequência cardíaca

A frequência cardíaca (em inglês *Heart Rate* (HR)) pode ser estimada com base em 4.1, isto é,

$$HR = \frac{60}{\text{Tempo do pulso de PPG}} \frac{[seg/min]}{[seg]}, \quad (4.1)$$

na qual o tempo do pulso de PPG deve ser fornecido em segundos e a unidade da frequência cardíaca é de batimentos por minuto.

4.6.2 Volume de pulso normalizado modificado

O volume de pulso normalizado modificado (do inglês *modified normalized pulse volume* (mNPV)) pode ser obtido a partir da eq. 4.2 a seguir (LEE *et al.*, 2013).

$$mNPV = \frac{I_{ac}}{I_{ac} + I_{dc}}, \quad (4.2)$$

em que I_{ac} e I_{dc} correspondem a:

- I_{ac} é a amplitude pico a pico do sinal de PPG;
- I_{dc} é o valor médio do sinal de PPG.

4.6.3 *Features* relacionadas à área

As áreas entre pontos chave consecutivos são consideradas como *features*. Como exemplo desse tipo de *feature*, podem ser citadas a área entre o ponto de máxima inclinação e o pico sistólico, bem como a área entre o pico sistólico e o nó dicrótico. Além dessas, também são consideradas como *features* a razão entre a área do início do pulso até o ponto de inflexão e a área do ponto de inflexão até o ponto final do pulso. Este valor é referenciado como a área do ponto de inflexão (tradução livre de *Inflection Point Area* (IPA)). Por fim, a área total abaixo do pulso também é considerada como uma *feature* dessa categoria.

4.6.4 *Features* relacionadas à amplitude

As *features* dessa categoria são obtidas com base no índice de reflexão, que é uma medida da reflexão do volume sanguíneo nas artérias.

O índice de reflexão pode ser estimado pela eq. 4.3, isto é,

$$IR = \frac{Y}{X}, \quad (4.3)$$

na qual:

- Y é a amplitude de um ponto-chave em específico;
- X é a amplitude do pico sistólico;

Como o valor da amplitude do pico sistólico foi normalizado para 1. Os índices de reflexão serão considerados como o valor do pulso de PPG em cada um dos pontos chave.

4.6.5 *Features* relacionadas ao tempo

Esta categoria de *features* se baseia na medida do *Large Artery Stiffness Index* (LASI) comentada em (MILLASSEAU *et al.*, 2002), que é uma medida da rigidez das artérias e que pode ser estimada com base na eq. 4.4,

$$LASI = \frac{h}{\Delta T}, \quad (4.4)$$

na qual:

- h é altura do indivíduo;
- ΔT é o intervalo entre dois pontos chave.

A LASI é originalmente estimada com base no intervalo entre o pico sistólico e o ponto de inflexão. Como o dado das alturas dos pacientes não está disponível na base de dados utilizada, foi considerado o valor de $h = 1$ para todos os pacientes, conforme utilizado em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019). Dessa forma, a LASI será considerada como o inverso do intervalo entre dois pontos chave.

Também são consideradas como *features* o inverso do intervalo entre os seguintes pontos:

- Pico sistólico e pico diastólico;
- Pico sistólico e ponto de inflexão;
- Pico sistólico e ponto de máxima inclinação;
- Pico sistólico e nó dicrótico.

Além dessas, a largura do pulso de PPG, que corresponde ao intervalo entre os pontos de 50% de amplitude, e o tempo de subida, que é o intervalo entre o ponto inicial e o pico sistólico, também são consideradas *features* desta categoria.

4.6.6 Propriedades da variabilidade da frequência cardíaca

A variabilidade da frequência cardíaca (tradução livre de *Heart Rate Variability* (HRV)) é considerada como o intervalo entre dois mínimos consecutivos do sinal de PPG. Dessa forma, é necessário utilizar o segmento de 5 segundos para calcular esta *feature*.

As *features* no domínio do tempo do HRV são a média e o desvio padrão.

Além dessas, também são consideradas algumas *features* relativas ao domínio da frequência, obtidas a partir da densidade espectral de potência do sinal de HRV, que descreve como a energia de um sinal temporal será distribuída em função da frequência (YATES; GOODMAN, 2014). Que são:

- Componente de baixa frequência (0,04 - 0,15 Hz): esta *feature* consiste na soma da potência das componentes de frequência neste intervalo;
- Componente de alta frequência (0,15 - 0,40): esta *feature* é obtida a partir da soma da potência das componentes de frequência neste intervalo;
- Razão entre a componente de baixa frequência e a de alta frequência;
- Potência total do sinal.

Esta *feature* é a soma de todas as componentes de frequência da densidade espectral de potência.

4.6.7 Funções não-lineares das *features*

Por fim, para levar em consideração as relações não-lineares entre as *features* extraídas e a pressão arterial, também são utilizadas funções não-lineares de algumas *features*, que são:


- $\ln(\text{HR})$;
- $\exp(\text{HR})$;
- $\ln(\text{mNPV})$;
- $\exp(\text{mNPV})$;
- $\ln(\text{HR} * \text{mNPV})$;
- $\ln(\text{IR do nó dicrótico})$;
- $\ln(\text{IR do ponto de inflexão})$.

4.7 EXTRAÇÃO DAS LABELS

As *labels* são as informações que o modelo de aprendizagem de máquina deve aprender a estimar tendo como base as *features* que são utilizadas como entrada do modelo. Neste trabalho, as *labels* são os valores da pressão sistólica (SBP), da pressão diastólica (DBP) e da pressão arterial média (MAP).

Na Figura 19, é apresentado um bloco que tem como objetivo calcular as *labels* propostas a partir do sinal de pressão arterial (ABP).

Figura 19 – Diagrama de blocos das etapas para extração das *labels* do sinal de ABP.



Fonte: Autor

O sinal de ABP utilizado para essa etapa se trata do segmento de 5 segundos que foi extraído a partir da base de dados original.

Para que a estimativa da pressão sistólica seja obtida, primeiramente são detectados os máximos do sinal de ABP e calculada a média desses valores: a pressão sistólica será considerada como a parte inteira do valor calculado. A pressão diastólica é obtida detectando-se os mínimos do sinal de ABP, realizando-se uma média desses valores e considerando-se apenas a parte inteira da média resultante. A pressão arterial média é calculada como o valor médio do sinal de ABP de entrada.

4.8 PÓS-PROCESSAMENTO

Antes de se realizar as etapas de treinamento e de teste dos modelos de aprendizagem de máquina, é necessário realizar uma curta etapa de pós-processamento, com o intuito de remover os *outliers* encontrados e também auxiliar o processo de treinamento para alguns algoritmos.

A primeira etapa de pós-processamento consiste na remoção de *outliers* com base nas *labels* obtidas. Para isso, são utilizados gráficos de *boxplot* para que os *outliers* sejam identificados e as *features* e *labels* referentes a eles sejam removidas dos conjuntos de dados de treinamento e de teste. Em seguida, as *features* são submetidas a um processo de *standardization*, que consiste em deixar as *features* com média nula e desvio padrão unitário. Esse processo é realizado com o intuito de melhorar a qualidade dos dados que serão utilizados como entrada nos modelos de aprendizagem

de máquina.

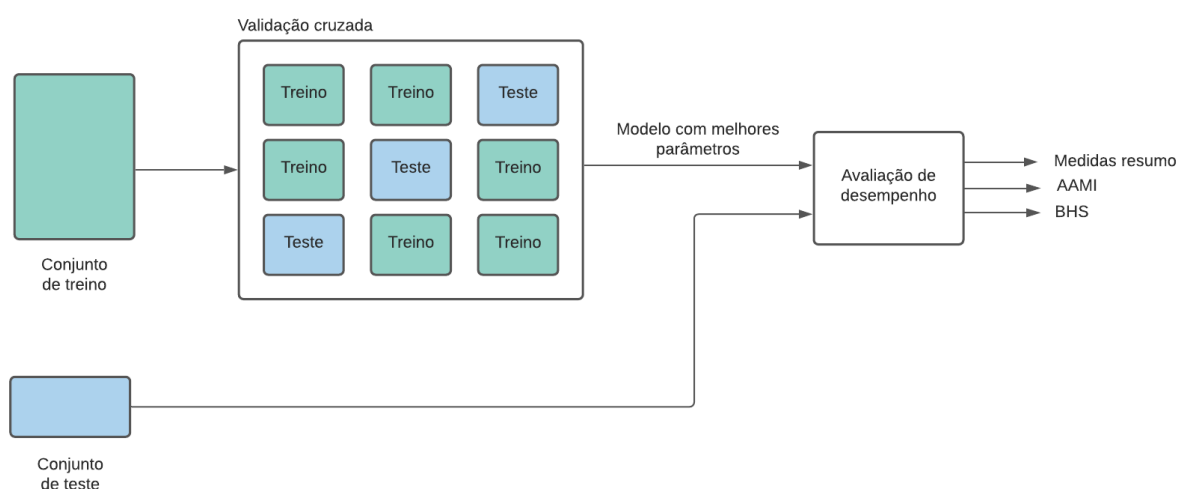
Uma vez que as etapas de pós-processamento foram realizadas, o conjunto de *features* e de *labels* pode ser utilizado para o processo de treinamento e validação dos modelos, detalhado a seguir.

4.9 TREINAMENTO E VALIDAÇÃO DOS MODELOS

Nesta seção, serão detalhadas as etapas que consistem em encontrar um modelo de aprendizagem de máquina que relaciona as *features* obtidas a partir do sinal de PPG com as *labels* do sinal de pressão arterial.

Na Figura 20 é apresentado um diagrama de blocos com os procedimentos a serem realizados nesta etapa.

Figura 20 – Diagrama de blocos das etapas para treinamento e validação do modelo de aprendizagem de máquina.



Fonte: Autor

Inicialmente, o conjunto de *features* e *labels* é dividido em dois subconjuntos: o subconjunto de treinamento e o subconjunto de teste. É recomendado que os dados presentes no subconjunto de teste apresentem as seguintes condições:

- Grande o suficiente para gerar medidas estatísticas significativas;
- Consiga representar o conjunto de dados como um todo. Ou seja, não deve ser escolhido um subconjunto de testes que apresente características diferentes do subconjunto de treino.

A fração dos dados totais que devem ser utilizados nos subconjuntos de treino e teste normalmente é feita de modo empírico. Em (GUYON *et al.*, 1997) é apresentado um estudo que indica que com mais dados no subconjunto de treinamento, tende-se a obter uma variância menor. Entretanto, ao se utilizar menos dados de teste, o viés do modelo pode aumentar. Uma boa prática consiste em iniciar com a proporção de 80/20 (Treino/Teste) para bases de dados com muitas amostras (mais de 100.000) e avaliar a representatividade do conjunto de teste.

Após a separação dos dados em um conjunto de treinamento e outro de teste, os dados de treinamento são utilizados no processo de validação cruzada. Este procedimento consiste em avaliar o modelo com diferentes parâmetros em diversos subconjuntos dos dados de treinamento. Após o término desse processo, é obtido o modelo com os parâmetros que apresentaram o melhor desempenho em relação a todo o conjunto de dados de treinamento. Para essa etapa, foram testados 4 tipos diferentes de modelos de aprendizagem de máquina, que foram: Regressão linear, Árvore de decisão, *Random Forest* com 100 estimadores e AdaBoost com 200 estimadores de Árvore de decisão.

4.9.1 Análise de desempenho

Uma vez que o modelo com os melhores parâmetros foi obtido, a última etapa consiste em avaliar seu desempenho com base nas métricas de avaliação normalmente utilizadas nos trabalhos utilizados como referência. Esta etapa é realizada usando apenas os dados do conjunto de teste, que são dados não conhecidos pelo modelo. Esse procedimento é realizado com o objetivo de simular o comportamento do modelo quando são utilizados dados de entrada desconhecidos.

4.9.1.1 Medidas resumo e de dispersão

As medidas resumo e de dispersão utilizadas foram as seguintes:

- Erro médio

$$ME = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (4.5)$$

O erro médio se refere à média de todos os erros em um conjunto de n elementos, em que y_i são os valores exatos e \hat{y}_i são as estimativas. Note que essa métrica auxilia na análise comparativa dos algoritmos, mas deve ser observada com cautela, uma vez que só permite avaliar se o modelo converge na média, sem que seja possível captar a dispersão dos valores dos erros, que podem levar a uma variância elevada.

- Erro médio absoluto

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.6)$$

O erro médio absoluto é calculado como a média das magnitudes dos erros observados entre os valores y_i e suas estimativas \hat{y}_i . Leva em conta o módulo do erro, de modo a fazer com que valores positivos e negativos não se anulem.

- Desvio padrão

$$STD = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}{n - 1}} \quad (4.7)$$

O desvio padrão é uma medida de dispersão que permite observar o quão dispersos os valores estão em relação à média, em que \hat{y}_i são as estimativas e $\bar{\hat{y}}$ é o valor médio das estimativas. O valor almejado para o desvio padrão é que ele seja próximo de zero, o que indica que os valores observados encontram-se próximos da média.

- Coeficiente de correlação

$$CORR = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (4.8)$$

O coeficiente de correlação mensura a forma como duas variáveis diferentes se relacionam, em que:

- n é o número de elementos presentes no conjunto avaliado;
- y_i são os valores exatos;
- \bar{y} é a média dos valores exatos;
- \hat{y}_i são os valores estimados;

- $\bar{\hat{y}}$ é a média dos valores estimados.

Neste trabalho, foi utilizado o coeficiente de correlação linear, que tem seus valores entre -1 e 1. Quando este coeficiente apresenta um valor próximo de -1, significa que as variáveis apresentam uma correlação inversa, isto é, conforme uma das variáveis aumenta, a outra diminui. Já quando o valor é próximo de 1, significa que existe uma correlação positiva, de modo que quando uma variável aumenta, a segunda também aumenta. Por fim, um coeficiente de correlação próximo de zero indica que as variáveis são pouco correlacionadas.

Essas medidas são utilizadas com o propósito de permitir uma comparação geral do desempenho dos algoritmos e são utilizadas em uma etapa anterior àquela em que os padrões de avaliação de instrumentos médicos são considerados. Como os padrões de avaliação são métricas que se baseiam em erro e desvio padrão, observar as medidas resumos e de dispersão facilita a identificação dos algoritmos que podem apresentar um melhor desempenho nas próximas etapas e ter seus resultados aprimorados.

4.9.1.2 Padrões internacionais de avaliação de instrumentos de medição de pressão arterial

Em conjunto com as medidas resumo e de dispersão, também como forma de avaliar o desempenho do modelo obtido, são utilizados os critérios de avaliação do AAMI e do BHS, com o intuito de entender se o modelo obtido cumpre com o critério AAMI e qual a classe obtida com base no critério BHS.

4.10 APRIMORAMENTO DOS MODELOS: HIPER PARÂMETROS

Além dos parâmetros que são aprendidos durante o processo de treinamento do modelo de aprendizagem de máquina, também existem outros tipos de que são definidos antes do início do treinamento. Esses parâmetros são conhecidos como hiper parâmetros e podem colaborar para a melhoria do desempenho de alguns modelos (HUTTER; KOTTHOFF; VANSCHOREN, 2019).

Os hiper parâmetros são definidos antes da etapa de treinamento do modelo. Dessa maneira, é necessário especificar previamente um conjunto de hiper parâmetros que devem ser testados seguindo alguma abordagem descrita na literatura. Uma das técnicas de busca exaustiva mais utilizadas para ajuste de hiper parâmetros é conhecida como *Grid Search* e consiste em treinar um novo modelo para cada combinação possível de hiper parâmetros, o que demanda um elevado custo computacional. Uma outra abordagem é técnica conhecida como *Random Search*, que testa combinações aleatórias de hiper parâmetros com base em um número máximo de iterações sugeridas. Embora essa abordagem não teste todas as combinações possíveis para o ajuste dos hiper parâmetros, ela permite uma melhoria de desempenho (que pode não ser a ótima) com um menor tempo de execução em relação à técnica de *Grid Search* (HUTTER; KOTTHOFF; VANSCHOREN, 2019).

Como exemplos de hiper parâmetros, podem ser citados alguns associados ao algoritmo *Random Forest*, que são a profundidade máxima das árvores a serem utilizadas e também a quantidade de árvores utilizadas (LUO, 2016), que serão utilizados neste trabalho.

Por se tratarem de testes extensivos e repetitivos, existem funções prontas de bibliotecas de algoritmos de aprendizagem de máquina que podem ser usadas para facilitar a realização desses testes para ajuste de hiper parâmetros. Para este trabalho, foi considerado o uso do teste do tipo *Grid Search*, que testa todas as combinações possíveis com base nos valores de hiper parâmetros definidos.

Para este trabalho, foram realizados experimentos de aprimoramento por meio da variação de apenas um dos hiper parâmetros que estão disponíveis para os algoritmos *Random Forest* e *AdaBoost* na biblioteca *Scikit-Learn* (Disponível em <https://scikit-learn.org/stable/>. Acesso em: 10/07/2021).

O hiper parâmetro escolhido se trata da profundidade máxima da árvore, que pode fazer com que o algoritmo seja capaz de descobrir mais relações contidas nos dados de treinamento.

5 RESULTADOS E DISCUSSÕES

Nesta seção serão apresentados os resultados obtidos com a ferramenta desenvolvida neste trabalho. Inicialmente, será detalhado como o *framework* pyCBPE foi desenvolvido e como pode ser utilizado para a realização de simulações com algoritmos de aprendizagem de máquina aplicados para a estimação da pressão arterial a partir de sinais de PPG. Em seguida, são apresentados resultados da utilização da ferramenta para comparação de desempenho de alguns algoritmos de aprendizagem de máquina.

5.1 FRAMEWORK OPEN-SOURCE

O *framework* pyCBPE foi desenvolvido com a linguagem de programação *Python*, devido à grande popularidade dessa linguagem entre pesquisadores e desenvolvedores, disponibilidade de material de suporte para dúvidas e utilização e também motivado pela existência de diversas bibliotecas que facilitam a realização de operações de processamento de sinais, manipulação de dados e a utilização de algoritmos de aprendizagem de máquina.

Como se trata de um *framework* de código aberto, a licença escolhida para orientar sua utilização por outros pesquisadores/desenvolvedores foi a *MIT License*. Com essa escolha, é permitido aos usuários a realização de modificações no código elaborado, desde que o arquivo de licença seja mantido em todas as cópias do código que incluam as alterações. O *framework* pode ser obtido a partir de sua página no *Github* conforme o diretório a seguir: <https://github.com/luigiluz/pyCBPE>.

O projeto foi desenvolvido de modo a servir como uma biblioteca que possa ser utilizada em conjunto com outros projetos. A sua estrutura é organizada conforme a árvore de diretórios apresentada abaixo:

```
/
├── files
├── pyCBPE
├── scripts
└── .gitignore
```

```
|  
|_ LICENSE  
|_ Makefile  
|_ README.md  
|_ requirements.txt  
|_ setup.py
```

A pasta `pyCBPE` contém os módulos escritos em *Python* disponíveis na biblioteca e que realizam as operações descritas no Capítulo 3. Os módulos são apresentados em arquivos distintos como forma de deixar as diferentes funcionalidades autocontidas.

A pasta *scripts*, agrega os códigos elaborados em linguagem Python, que realizam desde as etapas de preparação da base de dados até a etapa de treinamento e de validação do modelo de aprendizagem de máquina.

O *framework* também utiliza o recurso de ambiente virtual em *Python*, que permite que todos os usuários trabalhem com a mesma versão das bibliotecas, de modo a minimizar eventuais incompatibilidades com versões diferentes que estejam instaladas nos computadores dos usuários. Além disso, com o intuito de facilitar o uso do *framework*, foi desenvolvido um *Makefile* com comandos para inicializar o ambiente virtual e executar alguns dos *scripts* disponíveis.

5.1.1 Guia de uso

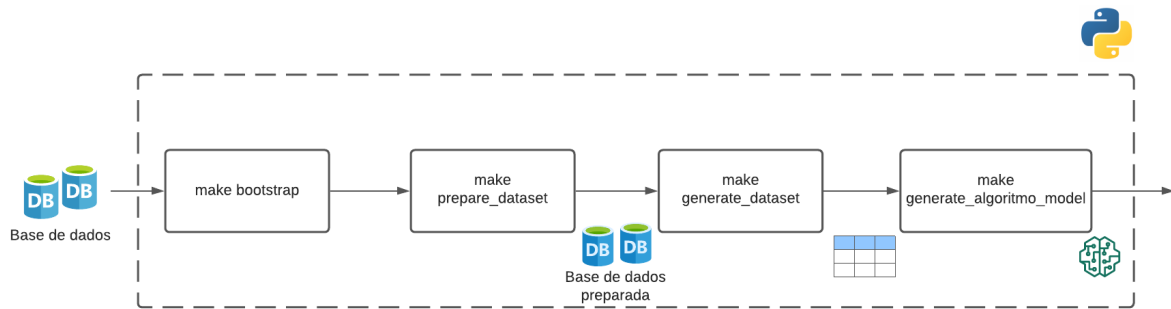
Uma vez que a estrutura do *framework* `pyCBPE` foi apresentada de forma generalista, a seguir será apresentado de forma mais detalhada como essa ferramenta pode ser utilizada para estudos e diferentes aplicações de modelos de aprendizagem de máquina na estimação da pressão arterial a partir de bancos de dados de sinais de PPG. Na Figura 21 é apresentado um diagrama de blocos que relaciona os *scripts* que encontram-se disponíveis no *framework*.

Sequência de passos para utilização do *framework* desenvolvido:

1. Obter a base de dados

O primeiro passo consiste em obter os arquivos da base de dados de medições de sinais de PPG, disponibilizados pelo *UCI Machine Learning Repository* no dire-

Figura 21 – Diagrama de blocos com a relação entre os *scripts* disponíveis para serem utilizados.



Fonte: Autor

tório a seguir: <https://archive.ics.uci.edu/ml/datasets/Cuff-Less+Blood+Pressure+Estimation>

2. Iniciar o ambiente virtual em *Python*

Este passo consiste em iniciar o ambiente virtual, que tem como objetivo garantir que os usuários utilizem as mesmas versões de bibliotecas, de modo a evitar problemas de compatibilidade entre versões. Para isso, é utilizado o seguinte comando:

```
make bootstrap
```

Este comando irá preparar o ambiente virtual com todas as bibliotecas que são utilizadas na ferramenta para a utilização pelo usuário.

3. Configurar o diretório raiz do projeto

O projeto tem seus diretórios elaborados com base no diretório raiz indicado pela constante **ROOT_PATH** que se encontra no arquivo **constants.py**.

Dessa forma, essa constante deve ser atualizada para o diretório raiz em que o projeto se encontra no seu computador.

4. Preparar a base de dados

A próxima etapa consiste em separar as gravações dos sinais de PPG e de ABP em segmentos de 5 segundos, para que estes possam ser utilizados para gerar a base de dados de *features* e *labels*.

Para isso, basta executar o comando abaixo>


```
make prepare_dataset
```

5. Gerar a base de dados de *features* e *labels*

Para gerar a base de dados de *features* e *labels* basta utilizar o comando a seguir:

```
make generate_dataset
```

Esse comando irá gerar 4 arquivos .csv com o seguinte prefixo:

features_and_labels_df_split_x

em que "x" indica o número do arquivo.

Esses arquivos serão utilizados pelos *scripts* que treinam e validam os algoritmos de aprendizagem de máquina.

6. Treinamento e avaliação do modelo

Com a base de dados de *features* e *labels* pronta, o próximo passo é gerar o modelo de aprendizagem de máquina. Atualmente, encontram-se disponíveis *scripts* para quatro algoritmos: Regressão Linear, Árvore de Decisão, *Random Forest* e *AdaBoost*.

Para executar o *script* escolhido, basta utilizar o seguinte comando:

```
make generate_algoritmo_model
```

Na estrutura atual do *framework*, encontram-se disponíveis os seguintes comandos para a utilização de algoritmos de aprendizagem de máquina, embora exista a possibilidade (e o interesse) de se agregar outros algoritmos posteriormente:

```
make generate_linear_regression_model
make generate_decision_tree_model
make generate_random_forest_model
make generate_adaboost_model
```

Dentro do diretório **file/estimators/sigla-algoritmo**, encontram-se disponíveis os arquivos obtidos com base no comando executado. Estes arquivos consistem nas métricas de avaliação do modelo de aprendizagem de máquina e também nos parâmetros obtidos para o modelo gerado (com a extensão .joblib), de tal

forma que seja possível replicar esse modelo em outras aplicações, caso seja de interesse do usuário.

5.2 EXPERIMENTOS

Para exemplificar a aplicação da ferramenta desenvolvida, alguns resultados de sua aplicação para a comparação entre modelos obtidos com algoritmos de aprendizagem de máquina são apresentados. Para isso, foram considerados os algoritmos atualmente disponibilizados na ferramenta: Regressão Linear, Árvore de Decisão, *Random Forest* e *AdaBoost*, considerando as *features* e *labels* descritas anteriormente na metodologia deste trabalho.

As tabelas 3, 4, 5 e 6, apresentadas a seguir, detalham os resultados obtidos com os algoritmos de Regressão Linear, Árvore de Decisão, *Random Forest* e *AdaBoost*, respectivamente. Os desempenhos dos modelos obtidos são comparados segundo as métricas ME, MAE, STD e CORR. As tabelas também apresentam as classificações segundo os padrões AAMI e BHS.

Tabela 3 – Métricas obtidas para o algoritmo de Regressão Linear.

Label / Métrica	Regressão Linear			CORR	AAMI	BHS
	ME (mmHg)	MAE (mmHg)	STD (mmHg)			
SBP	0,06	17,30	5,58	0,25	Sim	D
DBP	0,08	8,41	2,63	0,23	Sim	D
MAP	0,08	10,46	4,07	0,30	Sim	D

Fonte: Autor

Tabela 4 – Métricas obtidas para o algoritmo de Árvore de Decisão.

Label / Métrica	Árvore de Decisão			CORR	AAMI	BHS
	ME (mmHg)	MAE (mmHg)	STD (mmHg)			
SBP	-0,05	16,23	22,37	0,46	Não	D
DBP	-0,13	8,15	11,68	0,40	Não	D
MAP	-0,10	9,67	14,02	0,47	Não	D

Fonte: Autor

Como forma de facilitar a comparação entre os resultados descritos nas tabelas, provendo uma interpretação adicional sob forma gráfica, na Figura 22 são apresentadas as variáveis resumo para todos os modelos. Note que no eixo das abcissas são apresentados os algoritmos e no eixo das ordenadas, o valor associado à métrica de

Tabela 5 – Métricas obtidas para o algoritmo de *Random Forest*.

<i>Label / Métrica</i>	<i>Random Forest</i>					
	ME (mmHg)	MAE (mmHg)	STD (mmHg)	CORR	AAMI	BHS
SBP	0,01	15,01	9,55	0,52	Não	D
DBP	0,0	7,44	4,28	0,46	Sim	C
MAP	0,03	8,92	6,31	0,54	Sim	D

Fonte: Autor

Tabela 6 – Métricas obtidas para o algoritmo de *AdaBoost*.

<i>Label / Métrica</i>	<i>AdaBoost</i>					
	ME (mmHg)	MAE (mmHg)	STD (mmHg)	CORR	AAMI	BHS
SBP	-3,89	16,03	7,46	0,55	Sim	D
DBP	-6,57	10,12	4,47	0,46	Não	D
MAP	-5,27	10,61	5,28	0,57	Não	D

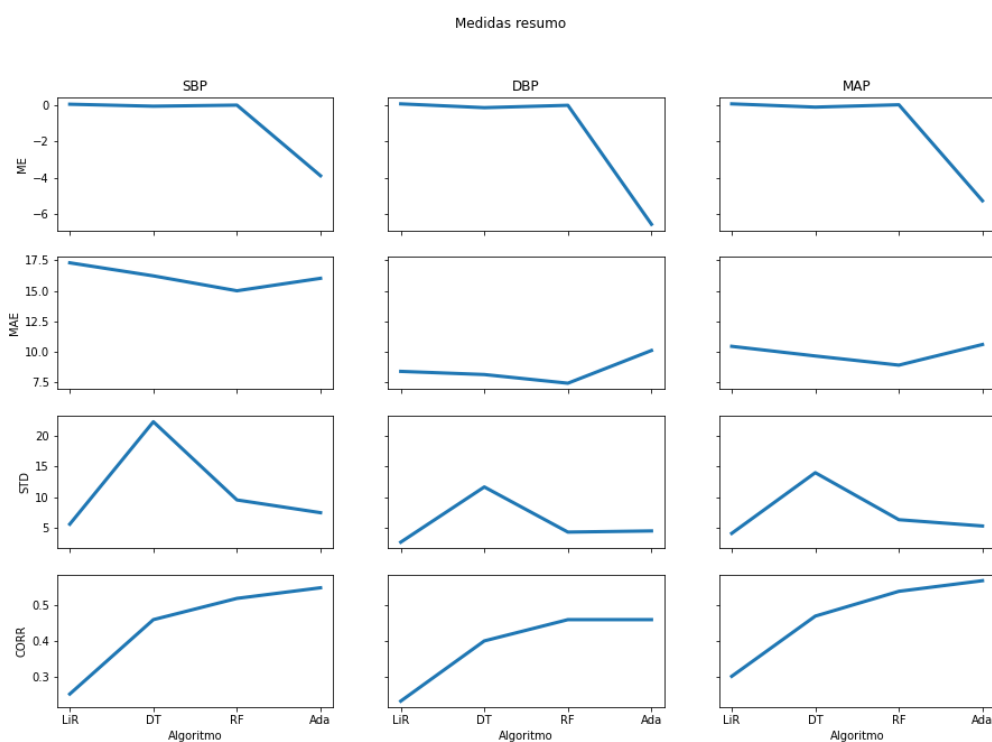
Fonte: Autor

comparação avaliada. Na figura, as siglas utilizadas identificam os seguintes algoritmos:

- LiR corresponde aos resultados obtidos pelo algoritmo de Regressão Linear;
- DT corresponde aos resultados obtidos pelo algoritmo de Árvores de decisão;
- RF corresponde aos resultados obtidos pelo algoritmo *Random Forest*;
- Ada corresponde aos resultados obtidos pelo algoritmo *AdaBoost*.

Com base na Figura 22 e nas tabelas apresentadas, é possível perceber que os algoritmos *Random Forest* e *AdaBoost* apresentaram de forma geral os melhores desempenhos entre os quatro algoritmos testados, quando se consideram as métricas MAE e STD, que apresentam valores mais baixos que os demais algoritmos, e quando se considera o índice de correlação, que é mais elevado. Entretanto, com base nos valores apresentados na tabela 5, pode-se notar que o algoritmo *Random Forest* não atende aos padrões da BHS, uma vez que o melhor resultado por ele obtido, segundo esse padrão, é apenas uma nota C para a pressão diastólica, o que não permite sua aplicação para fins clínicos. Além disso, o *Random Forest* atende apenas parcialmente os padrões da AAMI, como observado na tabela 5. Por outro lado, observando-se a tabela 6, nota-se que o algoritmo *AdaBoost* atendeu o padrão da AAMI apenas para a SBP, mas apresentou valores do coeficiente de correlação próximos ao do *Random*

Figura 22 – Análise comparativa entre as medidas resumo dos quatro algoritmos avaliados.



Fonte: Autor

Forest. Nota-se, ainda, que o algoritmo de Regressão Linear atende somente aos padrões da AAMI e que o algoritmo de Árvore de Decisão não atende a nenhum dos padrões.

Uma vez que os algoritmos *Random Forest* e *AdaBoost* apresentaram os melhores resultados no conjunto das métricas MAE, STD e CORR, buscou-se realizar o aprimoramento dos resultados dos modelos através de uma abordagem de ajuste dos hiper parâmetros associados a esses modelos, visando melhorar os valores associados a essas métricas e também melhorar os resultados em relação aos padrões AAMI e BHS. Na próxima seção, a abordagem realizada será detalhada.

5.3 APRIMORAMENTO DOS RESULTADOS

Uma vez que os modelos foram obtidos, pode-se aplicar um ajuste dos hiper parâmetros dos algoritmos de aprendizagem de máquina para buscar uma versão aprimorada dos modelos iniciais.

Nos *scripts* que geram os modelos do *framework* proposto, existe uma variável chamada *parameters* que pode receber diferentes conjuntos de hiper parâmetros para serem testados. Como forma de explorar este recurso, foram realizados experimentos variando-se um destes hiper parâmetros para os algoritmos *AdaBoost* e *Random Forest*. Por ambos os algoritmos *Random Forest* e *AdaBoost* serem baseados em árvores de decisão, seus hiper parâmetros são similares.

Para estes experimentos, foram utilizados os valores de referência obtidos em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) e apresentados na tabela 7. Note que o trabalho de (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) não apresenta os resultados para os padrões BHS de todos os algoritmos apresentados na tabela 7. Somente os resultados para o algoritmo que os autores indicaram como o mais promissor, o *AdaBoost*, foram apresentados, a saber: classe A para a DBP, classe B para o MAP e classe C para o SBP.

Tabela 7 – Métricas obtidas pelos modelos usados no artigo (HASANZADEH; AHMADI; MOHAMMADZADE, 2019)

Algoritmo	Label	ME (mmHg)	MAE (mmHg)	STD (mmHg)	CORR	AAMI
LIR	SBP	0,17	16,12	10,03	0,37	Não
	DBP	-0,11	7,04	5,81	0,35	Sim
	MAP	0,13	8,89	6,25	0,34	Sim
DT	SBP	-0,71	13,87	15,29	0,54	Não
	DBP	0,17	6,82	8,91	0,44	Não
	MAP	0,02	8,18	9,02	0,49	Não
RF	SBP	-0,17	10,29	10,35	0,75	Não
	DBP	-0,14	5,77	5,43	0,69	Sim
	MAP	0,07	6,38	6,62	0,72	Sim
Ada	SBP	0,09	8,22	10,38	0,78	Não
	DBP	0,23	4,17	4,22	0,72	Sim
	MAP	-0,02	4,58	5,53	0,75	Sim

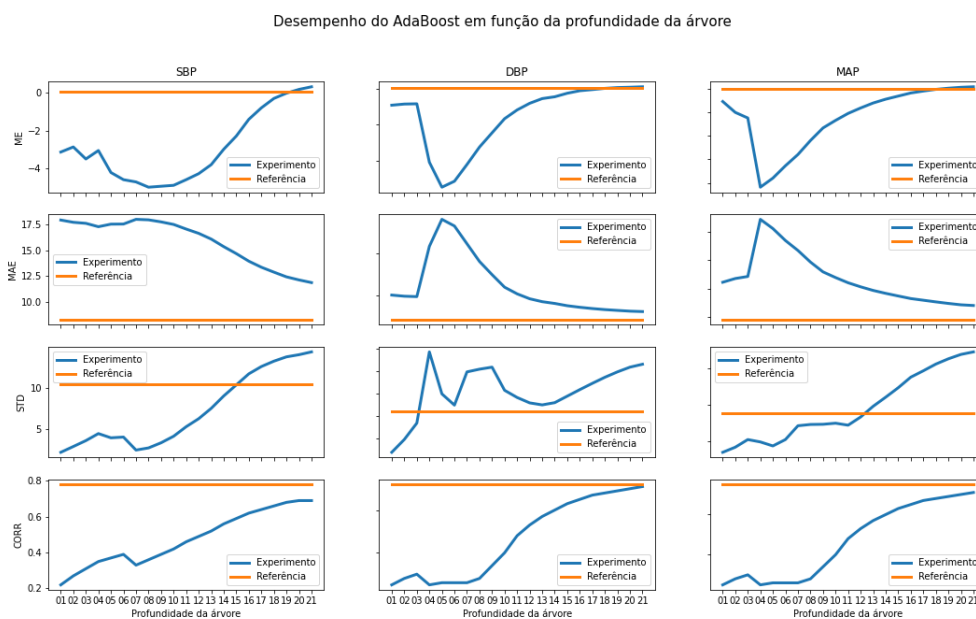
Fonte: (HASANZADEH; AHMADI; MOHAMMADZADE, 2019)

Para os experimentos a seguir, optou-se por testar apenas o hiper parâmetro da profundidade máxima da árvore, com o intuito de compreender o comportamento dos algoritmos mediante a variações neste parâmetro. Este hiper parâmetro auxilia o algoritmo na descoberta de mais relações contidas nos dados de treinamento (MANTOVANI *et al.*, 2018). Entretanto, este parâmetro deve ser ajustado com cautela, pois ele aumenta o risco de *overfit* do modelo conforme seu valor cresce. O *overfit* pode ser observado quando o modelo aprende muito bem os padrões do conjunto de treinamento mas apresenta um desempenho ruim em dados desconhecidos (DIETTERICH,

1995).

A Figura 23 e a tabela 8 apresentam as métricas de interesse ME, MAE, STD e CORR obtidas para o algoritmo *AdaBoost*, após o ajuste do modelo com o auxílio do hiper parâmetro de profundidade da árvore, que é variado de 1 até 21.

Figura 23 – Experimento que considera o desempenho do *AdaBoost* em função da profundidade da árvore.



Fonte: Autor

Os valores de referência utilizados para comparação na Figura 23 são os valores obtidos com o algoritmo *AdaBoost* em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019).

Analisando a Figura 23 e a tabela 8, é possível perceber que o coeficiente de correlação (CORR) do modelo resultante aumenta, de modo a se aproximar cada vez mais do valor de referência, conforme a profundidade da árvore também cresce. Entretanto, ao mesmo tempo, o valor do desvio padrão (STD) se afasta do valor de referência para as três *labels* (SBP, DBP e MAP), conforme a profundidade da árvore ultrapassa o valor 15. Em relação às demais medidas resumo, observa-se uma tendência de se aproximarem dos valores de referência à medida que a profundidade da árvore é aumentada.

Além disso, observa-se também que conforme a profundidade da árvore aumenta, há também um aumento do valor do STD, o que afeta os cálculos que definem

Tabela 8 – Métricas obtidas para a variação da profundidade da árvore com o algoritmo de *AdaBoost*.

Profundidade	Label	ME (mmHg)	MAE (mmHg)	STD (mmHg)	CORR	AAMI	BHS
5	SBP	-4,23	17,56	3,96	0,37	Sim	D
	DBP	-27,48	28,01	5,0	0,1	Sim	D
	MAP	-18,99	20,51	3,73	0,26	Sim	D
10	SBP	-4,91	17,53	4,15	0,42	Sim	D
	DBP	-8,29	11,9	5,16	0,22	Sim	D
	MAP	-6,7	11,95	4,98	0,4	Sim	D
15	SBP	-2,29	14,68	10,35	0,59	Não	D
	DBP	-1,16	7,5	4,9	0,54	Sim	D
	MAP	-1,53	8,73	6,93	0,63	Sim	D
20	SBP	0,19	12,11	14,0	0,69	Não	D
	DBP	0,52	6,21	6,19	0,64	Sim	B
	MAP	0,34	7,19	8,76	0,7	Não	C

Fonte: Autor

o padrão AAMI, tal que o modelo deixa de satisfazer esse critério. Em contrapartida, o aumento na profundidade da árvore parece estar associado à diminuição no valor do MAE, de tal forma que o modelo tende a obter melhores classificações no critério do BHS nessa situação.

A tabela 9 mostra a comparação entre as métricas obtidas nos dois trabalhos, com o propósito de facilitar a comparação com os resultados obtidos para o *AdaBoost* com profundidade máxima da árvore 20.

Tabela 9 – Comparação entre as métricas obtidas com o *AdaBoost* com profundidade máxima 20 e com o artigo de referência.

Modelo	Label	ME (mmHg)	MAE (mmHg)	STD (mmHg)	CORR	AAMI	BHS
Ada PM 20	SBP	0,19	12,11	14,0	0,69	Não	D
	DBP	0,52	6,21	6,19	0,64	Sim	B
	MAP	0,34	7,19	8,76	0,70	Não	C
Referência	SBP	0,09	8,22	10,38	0,78	Não	C
	DBP	0,23	4,17	4,22	0,72	Sim	A
	MAP	-0,02	4,58	5,53	0,75	Sim	B

Fonte: Autor

Na tabela, note que:

- ADA PM 20 indica os resultados referentes ao modelo com o algoritmo *AdaBoost* com profundidade máxima da árvore 20;
- Referência indica os resultados obtidos em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) com o algoritmo *AdaBoost*.

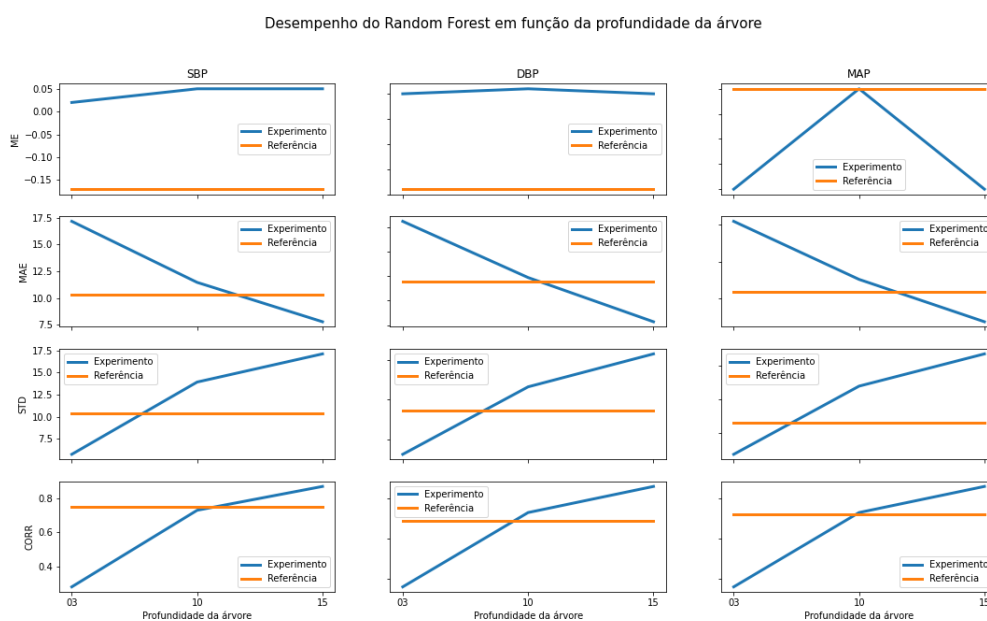
Comparando-se os resultados obtidos para a profundidade de máxima de 20 com o resultado obtido para o algoritmo *AdaBoost* em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), é possível perceber que as métricas obtidas com o *framework* proposto neste trabalho encontram-se na mesma ordem de grandeza daquelas apresentadas na referência, embora ainda existam algumas diferenças entre elas (os valores de ME, MAE e STD são um pouco mais elevados em relação aos apresentados no artigo e o índice de correlação é um pouco menor). Ressalte-se que, embora o *framework* proposto se baseie na metodologia proposta em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), há algumas diferenças entre sua proposta e aquela descrita neste texto, que potencialmente contribuem para as diferenças observadas, conforme será discutido posteriormente nesta seção.

Quando se analisa o resultado do modelo obtido quanto ao critério de avaliação do AAMI, o modelo do *AdaBoost* com profundidade de árvore 20 cumpre este critério apenas para a pressão diastólica, enquanto que o modelo de referência cumpre para a pressão diastólica e a pressão média. Em relação ao critério do BHS, foi obtida a classe B para a pressão diastólica, classe C para a pressão média e classe D para a pressão sistólica. Para as três *labels*, os resultados obtidos se encontram uma classe abaixo as obtidas no modelo de referência, que obteve classe A para a DBP, classe B para a MAP e classe C para a SBP. Contudo, essa comparação também deve ser considerada com cuidado, uma vez que não fica explícito no trabalho de referência quais foram as abordagens para ajustes do modelo, o que torna a reprodução dos resultados desafiadora.

Para o modelo obtido com o algoritmo *Random Forest*, um experimento semelhante foi realizado, no qual se considerou o aumento da profundidade da árvore e seu impacto nas métricas de desempenho do modelo. Neste experimento, avaliou-se o desempenho do modelo obtido pelo algoritmo para profundidades de 3, 10 e 15. Os resultados são apresentados na Figura 24 e na tabela 10 a seguir.

Conforme observado na Figura 24, há um aumento dos valores do coeficiente da correlação e do desvio padrão conforme a profundidade da árvore é aumentada. Note ainda que o valor do ME, embora seja diferente do valor de referência para SBP, DBP e MAP, é em magnitude menor (ou igual) ao valor do ME de referência. Além disso, embora o MAE exiba uma variação em seus valores conforme a profundidade

Figura 24 – Experimento que considera o desempenho do algoritmo *Random Forest* em função da profundidade da árvore.



Fonte: Autor

Tabela 10 – Métricas obtidas para a variação da profundidade da árvore com o algoritmo *Random Forest*.

Profundidade	Label	ME (mmHg)	MAE (mmHg)	STD (mmHg)	CORR	AAMI	BHS
3	SBP	0,02	17,17	5,75	0,28	Sim	D
	DBP	0,05	8,23	3,24	0,3	Sim	D
	MAP	0,06	10,18	4,71	0,36	Sim	D
10	SBP	0,05	11,46	13,91	0,73	Não	D
	DBP	0,06	5,94	6,64	0,67	Sim	B
	MAP	0,07	7,04	8,77	0,73	Não	C
15	SBP	0,05	7,78	17,09	0,87	Não	C
	DBP	0,05	4,14	8,3	0,83	Não	A
	MAP	0,06	4,75	10,69	0,86	Não	A

Fonte: Autor

da árvore aumenta, a figura dá indícios de que há um intervalo em que o MAE está próximo do valor de referência (para a profundidade da árvore em torno de 10 e 12). Para valores de MAE em profundidades da árvore acima de 12, os valores assumidos por essa métrica se tornam inferiores em comparação aos valores de referência, o que sugere uma melhoria no desempenho do modelo segundo essa métrica.

Na tabela 11, com o intuito de realizar uma análise comparativa, são apresentadas as métricas obtidas para o modelo com o algoritmo *Random Forest* com profundidade máxima de 10, 15 e os resultados obtidos pelo artigo de referência com este

mesmo algoritmo.

Tabela 11 – Comparação entre as métricas obtidas com o *Random Forest* com profundidade máxima 10, 15 e com o artigo de referência.

Modelo	Label	ME (mmHg)	MAE (mmHg)	STD (mmHg)	CORR	AAMI	BHS
RF PM 10	SBP	0,05	11,46	13,91	0,73	Não	D
	DBP	0,06	5,94	6,64	0,67	Sim	B
	MAP	0,07	7,04	8,77	0,73	Não	C
RF PM 15	SBP	0,05	7,78	17,09	0,87	Não	C
	DBP	0,05	4,14	8,3	0,83	Não	A
	MAP	0,06	4,75	10,69	0,86	Não	A
Referência	SBP	-0,17	10,29	10,35	0,75	Não	-
	DBP	-0,14	5,77	5,43	0,69	Sim	-
	MAP	-0,07	6,38	6,62	0,72	Sim	-

Fonte: Autor

Na tabela, note que:

- RF PM 10 indica os resultados referentes ao modelo com o algoritmo *Random Forest* com profundidade máxima da árvore 10;
- RF PM 15 indica os resultados referentes ao modelo com o algoritmo *Random Forest* com profundidade máxima da árvore 15;
- Referência indica os resultados obtidos em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) com o algoritmo *Random Forest*.

É possível perceber que o desempenho do algoritmo *Random Forest* com a profundidade máxima igual a 15 alcançou duas notas A do critério BHS para a DBP e a MAP. Entretanto, devido ao valor mais elevado do desvio padrão (STD), não foi possível atingir o padrão AAMI. Na Tabela 10, observa-se também uma tendência de uma relação inversamente proporcional entre a melhoria na classificação do padrão BHS e do padrão AAMI, conforme a profundidade da árvore é aumentada: o primeiro apresenta um ganho de classificação, enquanto o segundo passa a não ser atendido. Comparando-se os resultados obtidos com os apresentados em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) para o algoritmo *Random Forest*, é possível perceber que para a profundidade máxima 15, os resultados obtidos para o ME, MAE e CORR são melhores (os dois primeiros apresentam magnitudes menores do que as relatadas no trabalho de referência e o índice de correlação apresenta valores mais próximos da unidade), enquanto que o STD obtido é mais elevado. Em relação aos critérios de

avaliação dos padrões internacionais, para o padrão BHS foram obtidas as classes A, A e C para as *labels* DBP, MAP e SBP, respectivamente. Já o critério do AAMI não foi atingido para nenhuma das *labels*, devido ao valor mais elevado do desvio padrão. Para esse caso, não é realizada uma comparação das classes dos padrões obtidos por (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), uma vez que essas informações não estão disponíveis.

Ainda levando em consideração os resultados da variação da profundidade da árvore em relação ao desempenho do modelo do algoritmo *Random Forest*, pode-se considerar o modelo obtido para profundidade 10 como uma situação intermediária em relação aos padrões internacionais, uma vez que parte das *labels* atinge resultados que contemplam os padrões AAMI e BHS simultaneamente. Nessa situação, a pressão diastólica (DBP) atinge classe B no padrão BHS e atende ao padrão AAMI, o que permitia a aplicação clínica desse modelo para a obtenção dessa *label* segundo os dois padrões. Para as demais *labels*, ainda seria necessário melhorar o modelo.

Com base nas discussões sobre a utilização do *framework* proposto, detalhada ao longo deste capítulo, foi possível avaliar que os resultados obtidos com o ferramenta desenvolvida se aproximam dos resultados da literatura, indicando que ela pode ser aplicada para estudos sobre a aplicação de algoritmos de aprendizagem de máquina para estimar a pressão arterial a partir de sinais de PPG. Contudo, cabe destacar alguns pontos sobre a ferramenta e sobre a comparação de seus resultados com aqueles obtidos na literatura, que refletem na interpretação dos resultados apresentados:

1. Embora a metodologia utilizada no escopo deste trabalho tenha sido a proposta por (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), as etapas lá apresentadas para a realização da adequação dos sinais de PPG para a extração de *features* não foram apresentadas em grande detalhamento, assim como a especificação de diversos parâmetros associados ao cálculo dessas grandezas, como por exemplo: o tamanho da janela do filtro de mediana móvel, a janela de média móvel utilizada para remover possíveis erros na detecção dos pontos chave e a duração dos segmentos de PPG utilizados para análise. Dessa forma, foi necessário recorrer a diversas outras referências bibliográficas para a construção do *framework*, preenchendo essas lacunas com abordagens que podem não ser

aquelas utilizadas no artigo de referência.

2. Não fica claro no escopo do trabalho (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) se foram utilizados hiper parâmetros para melhorar os modelos. Além disso, se eles foram utilizados, também não é possível saber quais forem considerados na proposta. Dessa maneira, essa é uma outra diferença deste trabalho para (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), que também afeta a comparação entre os resultados.
3. Embora o artigo de referência (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) apresente diversas *features* ao longo do trabalho, não fica claro se todas foram utilizadas para os modelos lá apresentados. Por conta disso, para este trabalho, optou-se por utilizar todas as *features* propostas, de modo a possibilitar futuras análises de importância de *features*, com o intuito de simplificar o modelo, de modo a manter ou a melhorar seu desempenho.

Dessa forma, espera-se que o *framework* possa dar suporte a outros pesquisadores e estudantes para o estudo da estimação de pressão arterial a partir de sinais de PPG, usando algoritmos de aprendizagem de máquina. Como se trata de uma ferramenta que será distribuída de forma livre, espera-se que melhorias inseridas pelo próprio autor e por outros colaboradores a tornem mais robusta e completa futuramente.

6 CONCLUSÃO

Neste trabalho, foi proposto desenvolver um *framework* que possibilitasse realizar estudos comparativos sobre o desempenho de algoritmos de aprendizagem de máquina, aplicados para a estimação da pressão arterial a partir de sinais de PPG. A motivação para isso foi a possibilidade de contribuir para o desenvolvimento futuro de técnicas que permitissem monitorar a pressão arterial de forma contínua, de uma maneira mais confortável e não invasiva, auxiliando no diagnóstico de doenças associadas ao coração.

Como resultado deste trabalho, foi desenvolvido e disponibilizado o *framework* pyCBPE. A ferramenta foi estruturada como um conjunto de etapas de pré-processamento e de extração de *features* e *labels*, implementadas segundo abordagens descritas na literatura, e permite realizar uma análise comparativa entre diversos algoritmos, utilizando para isso métricas consolidadas dessa área (ME, MAE, STD e CORR) e padrões internacionais de validação para aplicações médicas (AAMI e BHS). Para o desenvolvimento do PyCBPE, tomou-se como base a metodologia proposta por (HASANZADEH; AHMADI; MOHAMMADZADE, 2019) para sua estruturação, bem como considerou-se os resultados dos algoritmos lá referenciados para comparações de desempenho com a nova ferramenta elaborada.

Utilizando a ferramenta pyCBPE e uma base pública internacional de sinais de PPG, foram realizadas simulações que possibilitaram a análise comparativa do desempenho de modelos obtidos com os algoritmos Regressão Linear, Árvore de Decisão, *Random Forest* e *AdaBoost*. Após uma comparação inicial entre os desempenhos desses algoritmos, foi realizado o ajuste dos modelos associados aos algoritmos *Random Forest* e *AdaBoost*, uma vez que os desempenhos dessas técnicas se destacaram em relação às demais. Para isso, considerou-se um ajuste via o hiper parâmetro profundidade da árvore, que é comum às duas técnicas.

Após a ajuste, observou-se que os algoritmos *Random Forest* e *AdaBoost* obtiveram resultados próximos aos reportados no trabalho de (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), tanto no que se refere às métricas ME, MAE, STD e CORR, quanto em relação aos padrões AAMI e BHS. De fato, para o algoritmo *AdaBoost*, ajus-

tado para profundidade de árvore 20, apenas a *label* (MAP) apresentou resultado distinto em relação ao padrão AAMI e, embora o padrão BHS não tenha sido igual ao artigo de referência, para todas as *labels* as classes obtidas foram uma classe inferior daquelas relatadas por (HASANZADEH; AHMADI; MOHAMMADZADE, 2019). No que se refere às métricas objetivas (ME, MAE, STD, CORR), os valores obtidos apresentaram a mesma ordem de grandeza daqueles detalhados na referência. Em relação ao algoritmo *Random Forest*, os resultados obtidos foram mais promissores: para profundidade de árvore 15, no que se refere aos *labels* DBP e MAP, foi possível atingir a classe A e para a *label* SBP, atingiu-se a classe C, com diversos valores de métricas objetivas superando os resultados de (HASANZADEH; AHMADI; MOHAMMADZADE, 2019). Apesar disso, observou-se que o padrão AAMI não foi atingido nesse caso. Por outro lado, para a profundidade de árvore 10, o modelo obtido com o algoritmo *Random Forest* conseguiu atingir para *label* DBP a classe B do padrão BHS e também atendeu ao padrão AAMI.

É importante ressaltar que, embora a abordagem deste trabalho tenha se baseado na metodologia apresentada em (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), há diferenças entre ambos trabalhos: como não havia grande detalhamento da abordagem de (HASANZADEH; AHMADI; MOHAMMADZADE, 2019), foi necessário utilizar outras referências da literatura para elaborar algumas etapas dessa estrutura, de tal forma que uma comparação direta entre os resultados deste trabalho e daqueles apresentados na referência base precisam ser considerados com cautela. De toda forma, os resultados obtidos com o *framework* proposto sinalizam que poderá auxiliar no estudo de aplicações de algoritmos de aprendizagem de máquina para a estimação da pressão arterial utilizando sinais de PPG.

O *framework* pyCBPE foi documentado e disponibilizado de forma aberta em um repositório no Github, com o propósito de funcionar como um facilitador para que outros estudantes e pesquisadores possam se valer dessa estrutura em suas pesquisas. O código fonte encontra-se disponível para livre utilização e eventuais modificações. Espera-se, com isso, facilitar a reprodutibilidade de trabalhos relacionados ao tema, auxiliando na realização de futuras análises comparativas com diferentes conjuntos de *features*, bases de dados e algoritmos de aprendizagem de máquina.

7 TRABALHOS FUTUROS

Neste capítulo, são apresentadas algumas possibilidades para continuidade, melhoria e desenvolvimento de um protótipo embarcado dos resultados deste trabalho.

7.1 EXPANSÃO DA BASE DE DADOS

Inicialmente foi utilizada apenas a base de dados do UCI Machine Learning Repository neste trabalho. Entretanto, existem outras bases de dados que também foram utilizadas em trabalhos anteriores. Como o *script* de extração de *features* utiliza como ponto de entrada uma gravação de 5 segundos de um sinal de PPG, novas bases de dados podem ser facilmente adicionadas desde que os sinais se encontrem nessas condições. Com isso, seria possível aumentar o conjunto de dados de treinamento e eventualmente melhorar o desempenho dos modelos obtidos.

7.2 ESTUDO PARA FAVORECER A SELEÇÃO DE *FEATURES*

Como pôde ser visto no Capítulo 1, os trabalhos que envolvem a utilização de sinais de PPG para realizar a estimativa da pressão arterial normalmente propõem o uso de diferentes *features*, não havendo uma uniformidade entre as diversas propostas, uma vez que cada autor define um determinado conjunto de *features* como sendo mais adequado à sua utilização. Dessa forma, um potencial trabalho futuro seria realizar a adição de novos conjuntos de *features* ao *framework* e com elas realizar estudos para tentar definir um conjunto de *features* mais significativas para esse problema. Com isso, seria possível otimizar o desempenho dos modelos obtidos em relação ao número de *features* utilizadas, diminuir o tempo de treinamento e diminuir a complexidade do modelo.

7.3 DEEP LEARNING

Uma das grandes dificuldades na extração de *features* que se baseiam na morfologia dos sinais de PPG é a detecção dos pontos chave. Para algumas medições de PPG, pontos chave como o pico diastólico não são facilmente detectáveis, o que leva ao descarte de algumas medições, reduzindo a quantidade de sinais disponíveis para treinamento e validação.

Esse tipo de acontecimento pode ser minimizado ao considerar uma abordagem de *Deep learning*, que normalmente considera as próprias amostras dos sinais como parâmetros de entrada para os modelos, eliminando a necessidade da extração de *features*.

Além disso, os trabalhos relacionados ao tema que utilizam esse tipo de abordagem vêm apresentando resultados promissores em relação aos padrões de avaliação internacional. Em (ATHAYA; CHOI, 2021) foi proposta uma abordagem que obteve nota A no critério do *BHS* para todas as três *labels* propostas (SBP, DBP e MAP). Já em (IBTEHAZ; RAHMAN, 2020) é proposto o uso de uma rede neural convolucional que obteve nota A no critério *BHS* para a DBP e MAP e nota B para a SBP.

7.4 EMBEDDED MACHINE LEARNING

Dispositivos de computação de borda estão cada vez mais populares nos dias atuais e já é comum a disponibilidade de dispositivos com uma elevada capacidade de processamento no nosso dia-a-dia, por exemplo, os relógios inteligentes. Por conta disso, uma outra possibilidade de trabalho futuro seria embarcar o modelo de aprendizagem de máquina em um dispositivo como um relógio inteligente ou no próprio celular do usuário, para que assim seja possível realizar o monitoramento contínuo e não-invasivo da pressão arterial com um dispositivo acessível e de simples manuseio.

REFERÊNCIAS

- ALPAYDIN, E. *Introduction to Machine Learning*. [S.l.]: MIT press, 2020.
- ATHAYA, T.; CHOI, S. An estimation method of continuous non-invasive arterial blood pressure waveform using photoplethysmography: A u-net architecture-based approach. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 21, n. 5, p. 1867, 2021. Disponível em: <https://www.mdpi.com/1424-8220/21/5/1867>. Acesso em: 8 de jun. de 2021.
- AWODEYI, A. E.; ALTY, S. R.; GHAVAMI, M. Median based method for baseline wander removal in photoplethysmogram signals. In: IEEE. *2014 IEEE International Conference on Bioinformatics and Bioengineering*. 2014. p. 311–314. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7033598>. Acesso em: 18 de jun. de 2021.
- DIETTERICH, T. Overfitting and undercomputing in machine learning. *ACM computing surveys (CSUR)*, ACM New York, NY, USA, v. 27, n. 3, p. 326–327, 1995. Disponível em: <https://dl.acm.org/doi/pdf/10.1145/212094.212114>. Acesso em: 26 de jun. de 2021.
- EL-HAJJ, C.; KYRIACOU, P. A. A review of machine learning techniques in photoplethysmography for the non-invasive cuff-less measurement of blood pressure. *Biomedical Signal Processing and Control*, Elsevier, v. 58, p. 101870, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809420300264>. Acesso em: 24 de mai. de 2021.
- ELGENDI, M. On the analysis of fingertip photoplethysmogram signals. *Current cardiology reviews*, Bentham science publishers, v. 8, n. 1, p. 14–25, 2012. Disponível em: <https://www.ingentaconnect.com/content/ben/ccr/2012/00000008/00000001/art00003>. Acesso em: 4 de jun. de 2021.
- GUYON, I. *et al.* A scaling law for the validation-set training-set size ratio. *AT&T Bell Laboratories*, Citeseer, v. 1, n. 11, 1997. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.33.1337&rep=rep1&type=pdf>. Acesso em: 25 de jun. de 2021.
- HASANZADEH, N.; AHMADI, M. M.; MOHAMMADZADE, H. Blood pressure estimation using photoplethysmogram signal and its morphological features. *IEEE Sensors Journal*, IEEE, v. 20, n. 8, p. 4300–4310, 2019. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8938751>. Acesso em: 2 de jun. de 2021.
- HUTTER, F.; KOTTHOFF, L.; VANSCHOREN, J. *Automated Machine Learning: Methods, Systems, Challenges*. [S.l.]: Springer Nature, 2019.
- IBTEHAZ, N.; RAHMAN, M. S. Ppg2abp: Translating photoplethysmogram (ppg) signals to arterial blood pressure (abp) waveforms using fully convolutional neural networks. *arXiv preprint arXiv:2005.01669*, 2020. Disponível em: <https://arxiv.org/abs/2005.01669>. Acesso em: 11 de jun. de 2021.

INSTRUMENTATION, A. for the Advancement of M. *et al.* American national standard for electronic or automated sphygmomanometers. *ansi. AAMI SP10-1993*, 1993. Disponível em: <https://ci.nii.ac.jp/naid/10024828510/>. Acesso em: 18 de mai. de 2021.

KACHUEE, M. *et al.* Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time. *In: IEEE. 2015 IEEE international symposium on circuits and systems (ISCAS)*. 2015. p. 1006–1009. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7168806>. Acesso em: 15 de mar. de 2021.

KHALID, S. G. *et al.* Cuffless blood pressure estimation using single channel photoplethysmography: A two-step method. *IEEE Access*, IEEE, v. 8, p. 58146–58154, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9042315>. Acesso em: 2 de abr. de 2021.

KHALID, S. G. *et al.* Blood pressure estimation using photoplethysmography only: Comparison between different machine learning approaches. *Journal of healthcare engineering*, Hindawi, v. 2018, 2018. Disponível em: <https://www.hindawi.com/journals/jhe/2018/1548647/>. Acesso em: 21 de mar. de 2021.

KURYLYAK, Y.; LAMONACA, F.; GRIMALDI, D. A neural network-based method for continuous blood pressure estimation from a ppg signal. *In: IEEE. 2013 IEEE International instrumentation and measurement technology conference (I2MTC)*. 2013. p. 280–283. Disponível em: <https://ieeexplore.ieee.org/abstract/document/6555424>. Acesso em: 6 de abr. de 2021.

LEE, J. *et al.* Validation of normalized pulse volume in the outer ear as a simple measure of sympathetic activity using warm and cold pressor tests: Towards applications in ambulatory monitoring. *Physiological measurement*, IOP Publishing, v. 34, n. 3, p. 359, 2013. Disponível em: <https://iopscience.iop.org/article/10.1088/0967-3334/34/3/359/meta>. Acesso em: 14 de jun. de 2021.

LIU, M.; PO, L.-M.; FU, H. Cuffless blood pressure estimation based on photoplethysmography signal and its second derivative. *International Journal of Computer Theory and Engineering*, IACSIT Press, v. 9, n. 3, p. 202, 2017. Disponível em: <http://www.ijcte.org/vol9/1138-AF016.pdf>. Acesso em: 2 de mai. de 2021.

LUO, G. A review of automatic selection methods for machine learning algorithms and hyper-parameter values. *Network Modeling Analysis in Health Informatics and Bioinformatics*, Springer, v. 5, n. 1, p. 1–16, 2016. Disponível em: <https://link.springer.com/article/10.1007/s13721-016-0125-6>. Acesso em: 21 de jun. de 2021.

MANTOVANI, R. G. *et al.* An empirical study on hyperparameter tuning of decision trees. *arXiv preprint arXiv:1812.02207*, 2018. Disponível em: <https://arxiv.org/abs/1812.02207>. Acesso em: 26 de jun. de 2021.

MAULUD, D.; ABDULAZEEZ, A. M. A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, v. 1, n. 4, p. 140–147, 2020. Disponível em: <https://jastt.org/index.php/jasttpath/article/download/57/20>. Acesso em: 14 de mai. de 2021.

MCCOMBIE, D. B.; REISNER, A. T.; ASADA, H. H. Adaptive blood pressure estimation from wearable ppg sensors using peripheral artery pulse wave velocity measurements and multi-channel blind identification of local arterial dynamics. *In: IEEE. 2006 International Conference of the IEEE Engineering in Medicine and Biology Society.* 2006. p. 3521–3524. Disponível em: <https://ieeexplore.ieee.org/abstract/document/4462556>. Acesso em: 14 de mai. de 2021.

MILLASSEAU, S. C. *et al.* Determination of age-related increases in large artery stiffness by digital pulse contour analysis. *Clinical science*, Portland Press Ltd., v. 103, n. 4, p. 371–377, 2002. Disponível em: <https://portlandpress.com/clinsci/article/103/4/371/67379>. Acesso em: 18 de jun. de 2021.

MITCHELL, T. M. *et al. Machine Learning.* [S.l.]: McGraw-hill New York, 1997.

MORAES, J. L. *et al.* Advances in photoplethysmography signal analysis for biomedical applications. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 18, n. 6, p. 1894, 2018. Disponível em: <https://www.mdpi.com/1424-8220/18/6/1894>. Acesso em: 14 de abr. de 2021.

MUKKAMALA, R. *et al.* Toward ubiquitous blood pressure monitoring via pulse transit time: Theory and practice. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 62, n. 8, p. 1879–1901, 2015. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7118672>. Acesso em: 5 de mai. de 2021.

NARA, S.; KAUR, M.; VERMA, K. L. Novel notch detection algorithm for detection of diastolic notch in ppg signals. *International Journal of Computer Applications*, Foundation of Computer Science, v. 86, n. 17, p. 36–39, 2014.

NYE, R.; ZHANG, Z.; FANG, Q. Continuous non-invasive blood pressure monitoring using photoplethysmography: A review. *In: IEEE. 2015 International Symposium on Bioelectronics and Bioinformatics (ISBB).* 2015. p. 176–179. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7344952>. Acesso em: 25 de mai. de 2021.

O'BRIEN, E. *et al.* The british hypertension society protocol for the evaluation of automated and semi-automated blood pressure measuring devices with special reference to ambulatory systems. *Journal of hypertension*, v. 8, n. 7, p. 607–619, 1990. Disponível em: <https://europepmc.org/article/med/2168451>. Acesso em: 20 de mai. de 2021.

ORGANIZATION, W. H. *et al. A Global Brief on Hypertension: Silent Killer, Global Public Health Crisis: World Health Day 2013.* [S.l.], 2013. Disponível em: https://apps.who.int/iris/bitstream/handle/10665/79059/WHO_DCO_WHD_2013.2_eng.pdf?sequence=1&isAllowed=y. Acesso em: 10 de mar. de 2021.

ORGANIZATION, W. H. *et al. Global Status Report on Noncommunicable Diseases 2014.* World Health Organization, 2014. Disponível em: http://apps.who.int/iris/bitstream/handle/10665/148114/9789241564854_eng.pdf?sequence=1. Acesso em: 11 de mar. de 2021.

RAM, M. R. *et al.* A novel approach for motion artifact reduction in ppg signals based on an adaptive filter. *IEEE Transactions on Instrumentation and*

Measurement, IEEE, v. 61, n. 5, p. 1445–1457, 2011. Disponível em: <https://ieeexplore.ieee.org/abstract/document/6111474>. Acesso em: 3 de jun. de 2021.

RAY, S. A quick review of machine learning algorithms. In: IEEE. *2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon)*. 2019. p. 35–39. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8862451/>. Acesso em: 17 de mai. de 2021.

SCHOLKMANN, F.; BOSS, J.; WOLF, M. An efficient algorithm for automatic peak detection in noisy periodic and quasi-periodic signals. *Algorithms*, Multidisciplinary Digital Publishing Institute, v. 5, n. 4, p. 588–603, 2012. Disponível em: <https://www.mdpi.com/1999-4893/5/4/588>. Acesso em: 5 de jun. de 2021.

SHARMA, M. *et al.* Cuff-less and continuous blood pressure monitoring: A methodological review. *Technologies*, Multidisciplinary Digital Publishing Institute, v. 5, n. 2, p. 21, 2017. Disponível em: <https://www.mdpi.com/2227-7080/5/2/21>. Acesso em: 28 de mai. de 2021.

SIMEONE, O. A very brief introduction to machine learning with applications to communication systems. *IEEE Transactions on Cognitive Communications and Networking*, IEEE, v. 4, n. 4, p. 648–664, 2018. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8542764>. Acesso em: 21 de mai. de 2021.

SLAPNIČAR, G.; MLAKAR, N.; LUŠTREK, M. Blood pressure estimation from photoplethysmogram using a spectro-temporal deep neural network. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 19, n. 15, p. 3420, 2019. Disponível em: <https://www.mdpi.com/1424-8220/19/15/3420>. Acesso em: 27 de abr. de 2021.

SUN, Y.; THAKOR, N. Photoplethysmography revisited: From contact to noncontact, from point to imaging. *IEEE transactions on biomedical engineering*, IEEE, v. 63, n. 3, p. 463–477, 2015. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7268900>. Acesso em: 22 de abr. de 2021.

SUWA, K. Pulse oximetry, by jtb moyle (bmj, london, uk, 2002. 174 pp.£ 19.95. isbn 0-7279-1740-4). *Journal of Anesthesia*, Springer, v. 17, n. 1, p. 74–74, 2003. Disponível em: <https://link.springer.com/article/10.1007/s005400300018>. Acesso em: 17 de abr. de 2021.

TENG, X.; ZHANG, Y. Continuous and noninvasive estimation of arterial blood pressure using a photoplethysmographic approach. In: IEEE. *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No. 03CH37439)*. 2003. v. 4, p. 3153–3156. Disponível em: <https://ieeexplore.ieee.org/abstract/document/1280811>. Acesso em: 19 de abr. de 2021.

WANG, L. *et al.* A novel neural network model for blood pressure estimation using photoplethysmography without electrocardiogram. *Journal of healthcare engineering*, Hindawi, v. 2018, 2018. Disponível em: <https://www.hindawi.com/journals/jhe/2018/7804243/>. Acesso em: 4 de mai. de 2021.

YATES, R. D.; GOODMAN, D. J. *Probability and Stochastic Processes: A Friendly Introduction for Electrical and Computer Engineers*. [S.l.]: John Wiley & Sons, 2014.

ZHANG, G. *et al.* Pulse arrival time is not an adequate surrogate for pulse transit time as a marker of blood pressure. *Journal of applied physiology*, American Physiological Society Bethesda, MD, v. 111, n. 6, p. 1681–1686, 2011. Disponível em: <https://journals.physiology.org/doi/full/10.1152/jappphysiol.00980.2011>. Acesso em: 5 de mai. de 2021.

ZHAO, D. *et al.* Sfst: A robust framework for heart rate monitoring from photoplethysmography signals during physical activities. *Biomedical Signal Processing and Control*, Elsevier, v. 33, p. 316–324, 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809416302178>. Acesso em: 23 de abr. de 2021.