



Universidade de Brasília – UnB
Campus Gama – FGA
Programa de Pós-Graduação em Engenharia Biomédica

**ESTIMATIVA CONTÍNUA E NÃO INVASIVA DA PRESSÃO ARTERIAL
COM BASE NA ANÁLISE DO TEMPO DE TRÂNSITO DE PULSO
EM SINAIS DE ELETROCARDIOGRAFIA E FOTOPLETISMOGRAFIA**

RODRIGO AMARAL

Orientador: Dr. CRISTIANO JACQUES MIOSSO



UNB – UNIVERSIDADE DE BRASÍLIA

FGA – FACULDADE GAMA



**ESTIMATIVA CONTÍNUA E NÃO INVASIVA DA PRESSÃO ARTERIAL
COM BASE NA ANÁLISE DO TEMPO DE TRÂNSITO DE PULSO EM
SINAIS DE ELETROCARDIOGRAFIA E FOTOPLETISMOGRAFIA**

RODRIGO AMARAL

ORIENTADOR: CRISTIANO JACQUES MIOSSO

DISSERTAÇÃO DE MESTRADO EM
ENGENHARIA BIOMÉDICA

PUBLICAÇÃO: 126A/2020

BRASÍLIA/DF, AGOSTO DE 2020

UNB – UNIVERSIDADE DE BRASÍLIA

FGA – FACULDADE GAMA

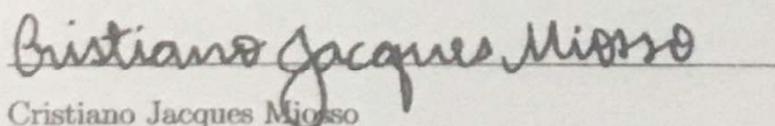
PROGRAMA DE PÓS-GRADUAÇÃO

ESTIMATIVA CONTÍNUA E NÃO INVASIVA DA PRESSÃO ARTERIAL
COM BASE NA ANÁLISE DO TEMPO DE TRÂNSITO DE PULSO EM
SINAIS DE ELETROCARDIOGRAFIA E FOTOPLETISMOGRAFIA

RODRIGO AMARAL

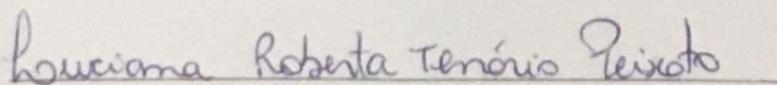
DISSERTAÇÃO DE MESTRADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA BIOMÉDICA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS RE-
QUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA
BIOMÉDICA

APROVADA POR:



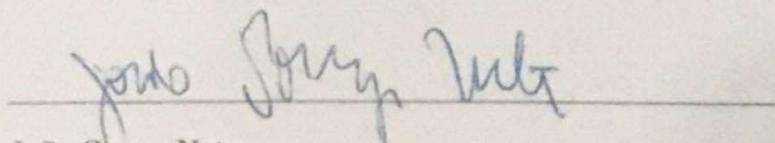
Cristiano Jacques Miorso

(Orientador)



Dr^a Luciana Roberta Tenório Peixoto

(Examinadora interna)



João Souza Neto

(Examinador externo)

FICHA CATALOGRÁFICA

AMARAL, RODRIGO

Estimativa Contínua e não Invasiva da Pressão Arterial com Base na Análise do Tempo de Trânsito de Pulso em Sinais de Eletrocardiografia e Fotopleletismografia.

[Distrito Federal], 2020.

63p., 210 × 297 mm (FGA/UnB Gama, Mestrado em Engenharia Biomédica, 2020).

Dissertação de Mestrado em Engenharia Biomédica, Faculdade UnB Gama, Programa de Pós-Graduação em Engenharia Biomédica.

- | | |
|-----------------------|------------------------------|
| 1. Pressão Arterial | 2. Fotopleletismografia |
| 3. Eletrocardiografia | 4. <i>Pulse Transit Time</i> |
| I. FGA UnB/UnB. | II. Título (série) |

REFERÊNCIA

AMARAL, RODRIGO (2020). Estimativa Contínua e não Invasiva da Pressão Arterial com Base na Análise do Tempo de Trânsito de Pulso em Sinais de Eletrocardiografia e Fotopleletismografia. Dissertação de mestrado em engenharia biomédica, Publicação 126A/2020, Programa de Pós-Graduação, Faculdade UnB Gama, Universidade de Brasília, Brasília, DF, 63p.

CESSÃO DE DIREITOS

AUTOR: Rodrigo Amaral

TÍTULO: Estimativa Contínua e não Invasiva da Pressão Arterial com Base na Análise do Tempo de Trânsito de Pulso em Sinais de Eletrocardiografia e Fotopleletismografia

GRAU: Mestre

ANO: 2020

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

rodrigo.com2@gmail.com

Brasília, DF – Brasil

RESUMO

A hipertensão é caracterizada por níveis elevados da Pressão Arterial (PA). É considerada um “assassino silencioso”, pois na maioria dos casos não há manifestações da doença. Métodos de monitoramento contínuo de forma não invasiva são desejados tanto pelos profissionais de saúde quanto pelos pacientes que precisam realizar o monitoramento contínuo da PA. Atualmente o método utilizado para realizar um monitoramento de 24 horas é a Monitorização Ambulatorial de Pressão Arterial (MAPA); no entanto esse método realiza uma amostragem pouco densa da PA, pois geralmente o equipamento realiza uma medida a cada 15 minutos. Atualmente, o método de se medir a PA de forma mais densa (denominada contínua) é por meio do cateter; no entanto este método pode trazer complicação.

Diante do exposto, fica clara a necessidade de aperfeiçoar as técnicas de medição não invasiva da PA. Pesquisas recentes têm investigado o uso de técnicas de regressão e de classificação em sinais de Eletrocardiograma (ECG) e Fotopletismografia (PPG). Basicamente este método analisa o tempo da onda de pressão que sai do coração e chega a um membro periférico. Essa técnica é conhecida com Tempo de Trânsito de Pulso (PTT).

O principal objetivo desta pesquisa é implementar e avaliar diferentes abordagens de classificações e regressão e extrair novas características dos sinais de ECG e PPG com o intuito de verificar o desempenho no processo de estimar os valores da Pressão Arterial Diastólica (PAD) e Pressão Arterial Sistólica (PAS).

No processo de estimar a PA, foram testados os seguintes regressores: Regressão por Vetor de Suporte (SVR), Regressão com *Bagging Predictors*, Modelo de Regressão Linear, Modelo Linear de Regressão Generalizado, LSboost, Regressão por Árvore de Decisão e Regressão por *Stepwise Linear Model*. Já no teste da classificação foi utilizada a Máquina de Vetor de Suporte (SVM) e o *Robust boosting*.

Para os testes dos algoritmos foram extraídas características temporais e característica no domínio da frequência. As características temporais são as seguintes: o intervalo entre o pico da onda R do sinal de ECG e o pico do sinal de PPG; o intervalo entre o pico da onda R do sinal de ECG e o vale do sinal de PPG; e o intervalo R-R do sinal de ECG. Já as características no domínio da frequência, são 5 bandas de energia do sinal de ECG e 5 bandas de energia do sinal de PPG.

Nos resultados obtidos durante os testes, o algoritmo de Regressão por Árvore de Decisão, teve o melhor resultado na PAD com erro Desvio Padrão (STD) = 2.80 e Erro Absoluto Médio (MAE) = 1.89, já os resultados em PAS, com erro STD = 3.26 e MAE = 2.24. Já nos testes de classificação direta, utilizando o classificador *Robust boosting*, o classificador teve um desempenho, com uma acurácia de 99%, sensibilidade de 94%, medida-F de 95% e uma precisão de 96%.

Assim, pode-se verificar que houve uma melhora significativa ao utilizar a Regressão por Árvore de Decisão com calibração. Em trabalhos futuros será interessante realizar novos teste sem o processo de calibração, para ver se o desempenho se mantém consistente.

Palavras-chave: Pressão Arterial, Fotopletismografia, Eletrocardiografia, *Pulse Transit Time*.

ABSTRACT

Hypertension is characterized by high levels of Blood Pressure (BP). It is considered a “silent killer” because in most cases there are no manifestations of the disease. Methods of continuous monitoring in a non-invasive way are desired both by health professionals and by patients who need to perform continuous monitoring of BP. Currently the method used to perform 24-hour monitoring is Ambulatory Blood Pressure Monitoring (ABPM); however, this method performs a little dense sampling of BP, as the equipment generally performs a measurement every 15 minutes. Currently, the method of measuring the BP in a more dense form (called continuous) is through the catheter; however, this method can cause complications.

In view of the above, it is clear the need to improve the non-invasive measurement techniques of BP. Recent research has investigated the use of regression and classification techniques in Electrocardiogram (ECG) and Photoplethysmography (PPG) signals. Basically this method analyzes the time of the pressure wave that leaves the heart and reaches a peripheral member. This technique is known as Pulse Transit Time (PTT).

The main objective of this research is to implement and evaluate different approaches of classifications and regression and to extract new characteristics of the ECG and PPG signals in order to verify the performance in the process of estimating the values of Diastolic Blood Pressure (DBP) and Systolic Blood Pressure (SBP).

In the process of estimating BP, the following regressors were tested: Support Vector Regression (SVR), Regression with Bagging Predictors, Linear Regression Model, Generalized Linear Regression Model, LSboost, Decision Tree Regression and Regression by Stepwise Linear Model. In the classification test, the Support Vector Machine (SVM) and Robust boosting were used.

For the tests of the algorithms, temporal characteristics and characteristic in the frequency domain were extracted. The temporal characteristics are as follows: the interval between the peak of the R wave of the ECG signal and the peak of the PPG signal; the interval between the peak of the R wave of the ECG signal and the valley of the PPG signal; and the R-R interval of the ECG signal. The characteristics in the frequency domain, are 5 energy bands of the ECG signal and 5 energy bands of the PPG signal.

In the results obtained during the tests, the Decision Tree Regression algorithm had the best results in DBP with error Standard Deviation (STD) = 2.80 and Mean Absolute Error (MAE) = 1.89, whereas the results in SBP, with error STD = 3.26 and MAE = 2.24. In the direct classification tests, using the classifier Robust boosting, the classifier had a performance, with an accuracy of 99%, sensitivity of 94%, F-measure of 95% and an accuracy of 96%.

Thus, it can be seen that there was a significant improvement when using the Decision Tree Regressor with calibration. In future research it will be interesting to carry out new tests without the calibration process, to see if the performance remains consistent.

Keywords: Blood Pressure, Photoplethysmography, Electrocardiography, Pulse Transit Time.

SUMÁRIO

1	Introdução	1
1.1	Contextualização	1
1.2	Definição do problema científico e proposta	4
1.3	Objetivos	5
1.3.1	Objetivo geral	5
1.3.2	Objetivos específicos	5
1.4	Justificativa	5
1.5	Estrutura da dissertação	6
2	Fundamentação teórica	8
2.1	Pressão arterial	8
2.2	Métodos de medida da pressão arterial	9
2.2.1	Métodos invasivos de medição contínua de pressão	9
2.2.2	Métodos não invasivos de medição de pressão a intervalos espaçados (medição não contínua)	10
2.3	Eletrocardiograma	11
2.4	Fotopletismografia	14
2.5	Medição contínua e não invasiva da pressão sanguínea	15
2.5.1	Parede arterial	15
2.5.2	Propagação da onda de pressão nas artérias	15
2.6	Classificações de sinais	16
2.6.1	Máquina de vetor de suporte (SVM)	16
2.6.2	Robust boosting	17
2.7	Regressão não-linear de sinais	17

2.7.1	Regressão por vetores de suporte (SVR)	17
2.7.2	Regressão por árvore de decisão	17
2.7.3	Regressão baseado em bagging predictors	18
2.7.4	Modelo de regressão linear	18
2.7.5	Modelo linear de regressão generalizado	18
2.7.6	LSboost	18
2.7.7	Stepwise Linear Model	18
3	Metodologia	19
3.1	Banco de dados	19
3.2	Processamento de sinais de eletrocardiografia e de fotopletismografia	23
3.2.1	Filtragem do sinal de ECG	27
3.2.2	Filtragem do sinal de PPG	28
3.3	Desenvolvimento dos algoritmos de extração de características de estimação da PA	29
3.3.1	Extração de características dos sinais de ECG e PPG	29
3.3.2	Uso dos algoritmos de regressão para a estimação da PA	32
3.3.3	Uso dos algoritmos de regressão para a estimação da PA e classificação indireta de pré-hipertensão	33
3.3.4	Uso de algoritmos de classificação para diagnóstico direto da pré-hipertensão	33
3.4	Procedimentos experimentais	33
3.5	Avaliação de desempenho a partir das estimações da PA e das classificações direta e indireta de pré-hipertensão	34
4	Resultados	36
4.1	Regressão e avaliação para estimar a PA	36
4.1.1	Teste com calibração realizado com 1 registro	36
4.1.2	Teste sem calibração realizado com 42 registros	40
4.1.3	Teste com calibração realizado com 1 registro e com a inclusão das bandas de energia	46

4.1.4	Teste sem calibração realizado com 42 registros e com a inclusão das bandas de energia	50
4.1.5	Teste com calibração realizado com 42 registros	50
4.1.6	Comparação e desempenhos entre os algoritmos	51
4.2	Classificação e avaliação do diagnóstico da pré-hipertensão	52
4.2.1	Classificação da PA após a regressão	52
4.2.2	Classificação direta da PA	54
4.3	Contribuições do Trabalho	55
5	Conclusão	57
	Lista de Referências	58

LISTA DE TABELAS

1.1	Classificação da PA de acordo com a Sociedade Europeia de Hipertensão [50].	1
3.1	Critérios de inclusão e exclusão para os sinais de ECG, PPG e PA.	20
3.2	Diferença entre a amostragem a 600Hz e 120Hz. Em cada caso é apresentado o número da amostra e o tempo em segundos da localização do pico da onda R do sinal de ECG. No final da tabela é mostrado a diferença em <i>ms</i> entre a localização do pico da onda R de ambos os sinais amostrados em 600Hz e 120Hz.	21
3.3	Diferença entre a amostragem a 600Hz e 120Hz. Em cada caso é apresentado o número da amostra e o tempo em segundos da localização do pico da onda R do sinal de ECG. No final da tabela é mostrado a diferença em <i>ms</i> entre a localização do pico da onda R de ambos os sinais amostrados em 600Hz e 120Hz.	22
4.1	Avaliação de desempenho do regressor SVR para estimar a PAD, em que são analisados os erros de STD. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG.	36
4.2	Avaliação de desempenho do regressor SVR para estimar a PAD, em que são analisados os erros de MAE. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG.	36
4.3	Avaliação de desempenho do regressor SVR para estimar a PAS, em que são analisados os erros de STD. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG.	38
4.4	Avaliação de desempenho do regressor SVR para estimar a PAS, em que são analisados os erros de MAE. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG.	38

4.5	Avaliação de desempenho do regressor SVR para estimar a PAD, em que são analisados os erros de MAE e STD. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG. Foram realizados 5000 seções de treinamento e foram utilizados diferentes porcentagens dos dados para treinamento e teste.	40
4.6	Avaliação de desempenho do regressor SVR para estimar a PAS, em que são analisados os erros de MAE e STD. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG. Foram realizados 5000 seções de treinamento e foram utilizados diferentes porcentagens dos dados para treinamento e teste.	40
4.7	Avaliação de desempenho do regressor SVR para estimar a PAD, em que são analisados os erros de MAE e STD. Neste teste foram incluídas as características de bandas de energia. Foram realizadas 5000 seções de treinamento e foi utilizado 70% dos dados para treinamento e 30% dos dados para teste.	46
4.8	Avaliação de desempenho do regressor SVR para estimar a PAS, em que são analisados os erros de MAE e STD. Neste teste foram incluídas as características de bandas de energia. Foram realizadas 5000 seções de treinamento e foi utilizado 70% dos dados para treinamento e 30% dos dados para teste.	48
4.9	Avaliação de desempenho do regressor SVR para estimar a PA, em que são analisados os erros de MAE e STD, para as ambas pressões PAD e a PAS. Neste teste foram incluídas as características de bandas de energia. Foram realizadas 5000 seções de treinamento e foi utilizado 70% dos dados para treinamento e 30% dos dados para teste.	50
4.10	Avaliação de desempenho de diferentes tipos de regressores para estimar a PA, em que são analisados os erros de MAE e STD, para as ambas pressões PAD e PAS. Os resultados são de testes que foram realizados com o processo de calibração. Em todos os casos foram realizadas 10 seções de treinamento e foram utilizados 70% dos dados para treinamento e 30% dos dados para teste.	51
4.11	Avaliação de desempenho de diferentes tipos de regressores para estimar a PA, em que são analisados os erros de MAE e STD, para as ambas pressões PAD e PAS. São apresentados testes que foram realizados com calibração e testes que foram realizados sem calibração, e no final são apresentados os dados do artigo [21]	51

4.12	Avaliação de desempenho do classificador por <i>Stepwise Linear Model</i> para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.	52
4.13	Avaliação de desempenho do classificador por Regressão por Árvore de Decisão para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.	52
4.14	Avaliação de desempenho do classificador por <i>LSboost</i> para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.	53
4.15	Avaliação de desempenho do classificador por Modelo Linear de Regressão Generalizado para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.	53
4.16	Avaliação de desempenho do classificador por Modelo de Regressão Linear para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.	53
4.17	Avaliação de desempenho do classificador por Regressão Baseado em <i>Bagging Predictors</i> para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.	54
4.18	Avaliação de desempenho do classificador por Regressão por Vetores de Suporte (SVR) para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.	54
4.19	Avaliação de desempenho do classificador <i>Robust boosting</i> para diagnóstico de pré-hipertensão com base nos sinais de ECG e PPG, realizando a classificação direta em comparação com o método de classificação indireto proposto por [21].	55

LISTA DE FIGURAS

- 1.1 Relação entre o sinal de eletrocardiografia (ECG, na parte superior) e o sinal de pletismografia (PPG, na parte inferior). O PTT é medido entre o pico R do sinal de ECG e o ponto de máxima no PPG, e se relaciona com os valores instantâneos de PAD e PAS. O L é o comprimento da artéria e o PWV é a velocidade da onda de pulso. Adaptado de [11]. 3
- 2.1 Esquema de utilização do cateter para medição contínua da pressão arterial, com o cateter introduzido diretamente na artéria radial. O cateter é conectado a um coluna líquida e pressurizada. Já o transdutor de pressão realiza as leituras da PAS, PAD e PAM, que são mostrados no monitor. O suporte é utilizado para fixação do transdutor e da bolsa de heparina. Adaptado de [39]. 9
- 2.2 Na parte superior da imagem é mostrado um braço envolvido por um manguito, que inicialmente está pressurizado com uma pressão maior que a PAS. Na representação das oscilações é mostrado que aos poucos a pressão do manguito vai sendo reduzida até abaixo da PAD. Na parte inferior da imagem é mostrado as oscilações da pressão no manguito, bem como as marcações da PAS, PAM e PAD. Adaptado de [7]. 11
- 2.3 No lado esquerdo da imagem é mostrado um coração humano, onde está destacado o sistema de condução. No lado direito da imagem é mostrado a relação das atividades elétricas do sistema de condução de cada músculo do coração, ou seja, a formação do registro de ECG. Adaptado de [3]. . . 12
- 2.4 Sinal de ECG, onde é mostrado a localização das ondas (P, Q, R, S e T), os segmentos PR e ST e os intervalos PR e QT. Adaptado de [29]. 12
- 2.5 Na parte superior da imagem é mostrado o esquema de ligação dos eletrodos para o registro das derivações (I, II e III). Na parte inferior esquerda é mostrado o local dos eletrodos para registro das derivações precordiais (V1, V2, V3, V4, V5 e V6). E na parte inferior direita é mostrado o local dos eletrodos para a formação do terminal central de Wilson. Adaptado de [4]. 13

2.6	Em (a) é mostrado a fotopletismografia transmissiva. O LED emissor e o fotoreceptor de luz, são fixados um na frente do outro, de modo que os componentes fiquem posicionados na extremidade do dedo. Em (b) é mostrado a fotopletismografia reflexiva. O LED emissor e o fotoreceptor de luz, são fixados um ao lado outro, mas separados por um invólucro. Adaptado de [33].	14
2.7	Relação entre o sinal de Eletrocardiograma (ECG) (Linha contínua) e o sinal de Fotopletismografia, do inglês <i>Photoplethysmography</i> (PPG) (Linha tracejada). Observe que o Tempo de Trânsito de Pulso, do inglês <i>Pulse Transit Time</i> (PTT) é o tempo entre o pico da onda R do sinal de ECG e o ponto máximo do sinal de PPG. Adaptado de [14].	16
3.1	Diagrama de blocos, onde é mostrado a entrada dos sinais, filtragem dos sinais e treinamento e teste do algoritmo de classificação e regressão. . . .	19
3.2	Em vermelho o sinal de ECG amostrado em 600Hz e em azul o mesmo sinal de ECG amostrado em 120Hz. Em (a) é mostrado o sinal de ECG completo e em (b) é mostrado um <i>zoom</i> do sinal, onde é possível ver detalhes entre os dois sinais.	22
3.3	Em vermelho o sinal de ECG amostrado em 600Hz e em azul o mesmo sinal de ECG amostrado em 120Hz. Em (a) é mostrado o sinal de ECG completo e em (b) é mostrado um <i>zoom</i> do sinal, onde é possível ver detalhes entre os dois sinais.	23
3.4	Em (a) é mostrado a resposta em frequência do filtro passa-alto do tipo FIR, com corte em 0.25Hz, e com um destaque nas baixas frequências. E em (b) é mostrado a fase do filtro.	24
3.5	Em (a) é mostrado a resposta em frequência do filtro passa-alto do tipo FIR, com corte em 0.5Hz, e com um destaque nas baixas frequências. E em (b) é mostrado a fase do filtro.	25
3.6	Em (a) é mostrado a resposta em frequência do filtro rejeita-faixa do tipo FIR, com corte em 60Hz. E em (b) é mostrado a fase do filtro.	26

3.7	Sinal de eletrocardiograma, onde é mostrado: (a) no domínio do tempo o sinal bruto, com variações na linha de base; (b) no domínio da frequência, em magnitude, com uma componente em 60Hz e outra próxima a 0Hz. Observe que em (c) no domínio do tempo, com o sinal já filtrado com um filtro FIR passa-alto e outro rejeita-faixa, não há uma linha de base tão intensa no domínio do tempo como no caso de (a). No domínio da frequência (d), observa-se a eliminação dos picos em torno de 60 hertz, presentes em (b) e a redução das componentes próximo a 0 hertz.	27
3.8	Sinal de fotopletismografia, onde é mostrado: (a) no domínio do tempo o sinal bruto, com variações na linha de base; (b) no domínio da frequência, em magnitude, com uma componente próxima a 0Hz. Observe que em (c) no domínio do tempo, com o sinal já filtrado com um filtro FIR passa-alto, não há uma linha de base tão intensa no domínio do tempo como no caso de (a). No domínio da frequência (d), observa-se a redução das componentes próximo a 0 hertz.	28
3.9	Sinal de ECG em azul e o sinal de PPG em vermelho. Observe que está faltando a marcação do segundo pico de PPG.	29
3.10	Sinal de ECG em azul e o sinal de PPG em vermelho. Observe que após a utilização do algoritmo de correção, foi adicionada uma marcação de um X verde no pico do sinal de PPG.	30
3.11	Sinal de ECG linha contínua e sinal de PPG linha tracejada. Note que está marcado o local da onda R do ECG e o pico do PPG, que corresponde ao intervalo PTT_P . Adaptado de [14].	30
3.12	Sinal de ECG linha contínua e sinal de PPG linha tracejada. Note que está marcado o local da onda R do ECG e o vale do PPG, que corresponde ao intervalo PTT_V . Adaptado de [14].	31
3.13	Sinal de ECG linha contínua. Note que estão marcados os locais da onda R do sinal de ECG, ou seja, o intervalo R-R do sinal de ECG. Adaptado de [14].	32
4.1	Histograma mostrando o erro STD para estimar a PAD com cada porcentagem utilizada para treinamento (a) - 60%, (b) - 70%, (c) - 80%, (d) - 90% e (e) - 95%) e com a quantidades de seções de treinamento realizadas (100, 5000, 10000, 50000 e 100000).	37

4.2	Histograma mostrando o erro STD para estimar a PAS com cada porcentagem utilizada para treinamento (a) - 60%, (b) - 70%, (c) - 80%, (d) - 90% e (e) - 95%) e com a quantidades de seções de treinamento realizadas (100, 5000, 10000, 50000 e 100000).	39
4.3	Histograma mostrando do STD e MAE com 60% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS. . .	41
4.4	Histogramas do STD e MAE com 70% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.	42
4.5	Histogramas do STD e MAE com 80% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.	43
4.6	Histogramas do STD e MAE com 90% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.	44
4.7	Histogramas do STD e MAE com 95% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.	45
4.8	Histograma mostrando o erro STD para estimar a PAD. Onde é mostrado diferentes porcentagem de dados utilizados para treinamento (a) - 60%, (b) - 70%, (c) - 80%, (d) - 90% e (e) - 95% e em cada caso o restante dos dados foram utilizado para teste.	47
4.9	Histograma mostrando o erro STD para estimar a PAS. Onde é mostrado diferentes porcentagem de dados utilizados para treinamento (a) - 60%, (b) - 70%, (c) - 80%, (d) - 90% e (e) - 95% e em cada caso o restante dos dados foram utilizado para teste.	49

LISTA DE NOMENCLATURAS E ABREVIACÕES

AAMI Associação para o Avanço da Instrumentação Médica, do inglês *Association for the Advancement of Medical Instrumentation*

AC Corrente Alternada, do inglês *Alternating Current*

AV Atrioventricular

AVC Acidente Vascular Cerebral

BD Braço Direito

BE Braço Esquerdo

CC Com Calibração

DC Corrente Contínua, do inglês *Direct Current*

ECG Eletrocardiograma

FC Frequência Cardíaca

FIR Resposta ao Impulso Finita, do inglês *Finite Impulse Response*

HA Hipertensão Arterial

IBP Medição Invasiva da Pressão Arterial, do inglês *Invasive Blood Pressure*

LED Diodo Emissor de Luz, do inglês *Light Emitting Diode*

MAE Erro Absoluto Médio, do inglês *Mean Absolute Error*

MAPA Monitorização Ambulatorial de Pressão Arterial

mmHg Milímetros de Mercúrio

MS Ministério da Saúde

mV Milivolts

NIBP Medição Não Invasiva da Pressão Arterial, do inglês *Non-Invasive Blood Pressure*

OMS Organização Mundial de Saúde

PA Pressão Arterial

PAD Pressão Arterial Diastólica

PAM Pressão Arterial Média

PAS Pressão Arterial Sistólica

PE Perna Esquerda

PPG Fotopletismografia, do inglês *Photoplethysmography*

PTT Tempo de Trânsito de Pulso, do inglês *Pulse Transit Time*

PWV Velocidade da Onda de Pulso, do inglês *Pulse Wave Velocity*

SA Sinoatrial

SC Sem Calibração

SUS Sistema Único de Saúde

SVM Máquina de Vetor de Suporte, do inglês *Support Vector Machine*

SVR Regressão por Vetores de Suporte, do inglês *Support Vector Regression*

STD Desvio Padrão, do inglês *Standard Deviation*

UTI Unidade de Terapia Intensiva

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Com base em pesquisas realizadas pela Organização Mundial de Saúde (OMS), estima-se que a hipertensão é responsável por 12,8% de todas as mortes no mundo, o que representa aproximadamente 7,5 milhões de mortes [51]. Segundo o Ministério da Saúde (MS), em 2013 o Brasil possuía 21,4% de indivíduos maiores de 18 anos diagnosticados com hipertensão, o que representa 31,3 milhões de pessoas [27].

A hipertensão é caracterizada por níveis elevados da Pressão Arterial (PA), constituindo uma doença crônica controlável mas que pode levar a doenças cardiovasculares [27]. É considerada um “assassino silencioso”, pois na maioria dos casos não há manifestações da doença, mas ela pode levar a ataques cardíacos, Acidente Vascular Cerebral (AVC), doença renal, doença ocular e outros problemas graves [45]. Atualmente, as diretrizes da Sociedade Europeia de Hipertensão propõem classificar os níveis da Pressão Arterial Diastólica (PAD) e Pressão Arterial Sistólica (PAS) de acordo com os grupos ótimo, normal, pré-hipertenso e hipertenso, utilizando como limiar os valores fornecidos pela Tabela 1.1.

Tabela 1.1. Classificação da PA de acordo com a Sociedade Europeia de Hipertensão [50].

Classificação da PA	PAS (mmHg)		PAD (mmHg)
Ótima	< 120	e	< 80
Normal	120 – 129	e/ou	80 – 84
Pré-hipertenso	130 – 139	e/ou	85 – 89
Hipertensão de grau 1	140 – 159	e/ou	90 – 99
Hipertensão de grau 2	160 – 179	e/ou	100 – 109
Hipertensão de grau 3	≥ 180	e/ou	≥ 110
Hipertensão sistólica isolada	≥ 140	e	< 90

Pressão Arterial (PA); Pressão Arterial Diastólica (PAD);
Pressão Arterial Sistólica (PAS); Milímetros de Mercúrio (mmHg).

A PA é definida pela pressão que o sangue exerce nos vasos sanguíneos, que oferecem uma resistência causada pelas paredes internas. Durante o funcionamento do coração, é ejetado sangue do ventrículo esquerdo para a aorta, onde é produzido um impulso

no sangue que cria uma pressão fazendo o sangue se deslocar do coração para todo o sistema circulatório. Esse fluxo depende das propriedades arteriais como elasticidade e rigidez das paredes de cada artéria [35]. A PA pode variar no decorrer de um dia, em virtude de exercícios físicos, estresse ou condição psicológica [16]. É um importante parâmetro para diferenciar o estado de saúde de pacientes em ambiente clínico. Em pacientes hospitalizados, a PA é medida de 3 a 4 vezes por dia, ou quando há algum sintoma, e antes ou depois de alguns exames importantes. No caso de pacientes que estejam em uma Unidade de Terapia Intensiva (UTI), a PA é verificada a intervalos de tempos regulares [52].

Stephen Halls, em 1733, realizou os primeiros experimentos que deram origem às medições da PA. Para tanto, utilizou um longo tubo de vidro que canulava a artéria de um cavalo e com isso era possível observar a pulsação do sangue. Em 1847, o alemão Carl Ludwig desenvolveu o quimógrafo, que é um dispositivo mecânico e hidráulico que proporcionou um grande avanço para a obtenção de registro contínuo da PA [11]. Em 1949, Perterson utilizou pela primeira vez o cateter intra-arterial para medir PA em um cenário clínico [36].

O método de Medição Invasiva da Pressão Arterial, do inglês *Invasive Blood Pressure* (IBP), é fundamentado no uso de um cateter, um transdutor e alguns outros componentes, que permitem medir a PA diretamente em um vaso sanguíneo. Embora a medição da PA realizada pelo método invasivo ofereça uma monitorização contínua da PA, ela é usada restritivamente devido à dificuldade de operação e à possibilidade de dor, sangramento e infecção.

Já para os métodos de Medição Não Invasiva da Pressão Arterial, do inglês *Non-Invasive Blood Pressure* (NIBP), existem várias abordagens. O método mais popular é o auscultatório, que se baseia no som de Korotkoff, gerado a partir da mudança de pressão em um braço envolvido por um manguito e auscultado por meio de um estetoscópio. Outro método bastante conhecido é o oscilométrico, usualmente utilizado em aparelhos automáticos e que permite determinar a PAD e a PAS com base na oscilação máxima, que corresponde à Pressão Arterial Média (PAM). Um outro método é o da onda ultra-sônica, que utiliza um sensor ultrassônico na região da artéria para medir a PA. Finalmente, o método da Velocidade da Onda de Pulso, do inglês *Pulse Wave Velocity* (PWV), também bastante pesquisado, utiliza sinais de ECG e de PPG para inferir a PA por meio da conversão de distância e tempo que o sangue bombeado de um coração leva para chegar ao vaso sanguíneo periférico [52].

Um método muito consolidado para medir a PA por grandes períodos se baseia na Monitorização Ambulatorial de Pressão Arterial (MAPA). As medições com esse equipamento fornecem informações adequadas e precisas para muitas aplicações médicas [43],

têm a vantagem de serem não invasivas [49], são consideradas o padrão ouro para diagnóstico da hipertensão crônica [15]. No entanto, existem algumas desvantagens que limitam o uso da MAPA. A primeira é que ela não permite registrar a PA de forma contínua [43, 22]. De fato, trata-se de um processo de amostragem pouco densa [48], sendo que geralmente os registros são realizados a cada 15 minutos, e assim é possível obter apenas 100 leituras de PA num período de 24 horas [32]. Isso pode ocasionar perda de eventos que acontecem entre um registro e outro [49]. As outras desvantagens da MAPA estão relacionadas ao comportamento do paciente durante o exame. Se durante as medidas da PA o braço do paciente não permanecer em repouso ou se o braço não estiver posicionado de maneira adequada, isso pode influenciar a exatidão da medida [30, 31].

A PA contínua não pode ser obtida por métodos baseados em manguito, pois com o uso do manguito é necessária uma pausa de pelo menos 1 a 2 minutos entre cada medição da PA. Além disso, o paciente pode ser perturbado pela insuflação do manguito e esse distúrbio pode causar uma elevação súbita da PA. Uma medição contínua da pressão arterial é desejável em diversas configurações clínicas e domésticas [46, 43]. Por exemplo, nos cuidados perioperatórios, a Sociedade Americana de Anestesiologia exige uma monitorização contínua da PA em pacientes com doença sistêmica grave [19].

Na literatura tem havido muita atenção para o monitoramento contínuo não invasivo da PA sem o uso de manguito. Uma alternativa muito abordada é a utilização da PWV [35]. Esse método se baseia na teoria de propagação da onda de fluidos em tubos elásticos [21], e na observação do tempo de chegada da onda de pressão que se propaga pela árvore arterial. O método depende de parâmetros fisiológicos como as propriedades das paredes arteriais, que variam com a pressão e com o comprimento da artéria. Depende ainda de procedimentos de calibrações para oferecer medidas confiáveis [11]. Na Figura 1.1 é mostrado o sinal de ECG juntamente com o sinal de PPG, que são utilizados para o cálculo do PWV.

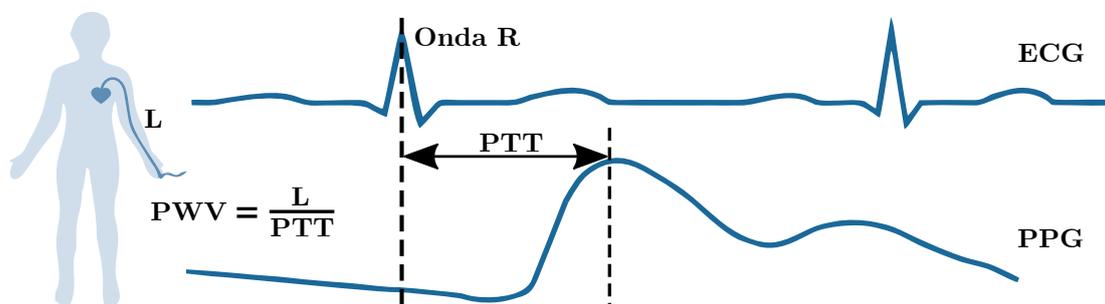


Figura 1.1. Relação entre o sinal de eletrocardiografia (ECG, na parte superior) e o sinal de pletismografia (PPG, na parte inferior). O PTT é medido entre o pico R do sinal de ECG e o ponto de máxima no PPG, e se relaciona com os valores instantâneos de PAD e PAS. O L é o comprimento da artéria e o PWV é a velocidade da onda de pulso. Adaptado de [11].

1.2 DEFINIÇÃO DO PROBLEMA CIENTÍFICO E PROPOSTA

Diante do exposto, fica clara a necessidade de aperfeiçoar as técnicas de medição não invasiva da PA. Pesquisas recentes têm investigado o uso de técnicas de regressão e de classificação aplicadas a sinais de ECG e PPG. Essas pesquisas analisam os intervalos de tempos medidos entre esses dois sinais, e os correlacionam aos valores da PA obtida por cateter. As características extraídas dos sinais de ECG e PPG permitem treinar um sistema de classificação ou de regressão, com intuito de prever os valores da PAD e da PAS.

Um método muito pesquisado se baseia na análise do PTT, que é o tempo em que a onda de pressão leva para se propagar pelo sistema arterial central. Este método não requer manguito ou comprimento da artéria e pode ser usado para monitoramento contínuo da PA. O PTT é derivado do atraso de tempo entre a onda R do ECG e a chegada da onda ao um membro periférico, que pode ser verificada pelo PPG. A onda R ocorre no início da sístole do coração, quando o sangue ejetado do coração para a aorta cria uma onda de pressão que se move para os membros periféricos. Portanto, a onda R é a referência para o início do ciclo de pressão, além de ser comparativamente simples de detectar [35].

No entanto, nos estudos observados, não foram encontradas análises definindo a PA em faixa de valores utilizando classificadores mais recentes da literatura, para tentar enquadrar as características observadas dos sinais de ECG e PPG em temas dessas classes. Os estudos observados utilizaram técnicas atuando diretamente sobre os valores numéricos de pressão e com base em modelos de regressão linear, árvores de decisão, Regressão por Vetores de Suporte, do inglês *Support Vector Regression* (SVR), *Adaptive Boosting* (*AdaBoost*) e *Random Forest Regression* (*RFR*) [21]. Outros aspectos a serem explorados incluem a utilização de técnicas mais avançadas de aprendizagem de máquina, e a utilização de outras características que podem ser extraídas dos sinais de ECG e PPG.

Neste contexto, este trabalho propõe investigar o uso de diferentes técnicas de classificação e outros conjuntos de características a serem extraídas dos sinais, com intuito de verificar um possível aumento da acurácia ou precisão no processo de avaliação da PA a partir dos sinais de ECG e PPG. Propõe ainda avaliar a classificação de pré-hipertensão com base na aplicação direta de um classificador às características extraídas, em oposição ao diagnóstico feito a partir dos valores de PA estimados com base nos regressores aplicados àquelas características. A escolha do diagnóstico de pré-hipertensão foi baseada nos resultados encontrados na literatura. Foi o tipo de classificação com pior desempenho, representando aparentemente um maior desafio quando comparado à classificação de hipertensão ou pressão normal.

1.3 OBJETIVOS

1.3.1 Objetivo geral

O objeto desta pesquisa é avaliar combinações de diferentes regressores e conjuntos de características extraídas dos sinais de ECG e PPG com o intuito de verificar o desempenho no processo de estimar os valores da PAD e PAS. Objetiva ainda avaliar se o uso de um classificador aplicado diretamente às características permite detectar pré-hipertensão com melhor desempenho do que estratégias encontradas na literatura, que se baseiam em geral na aplicação da definição de pré-hipertensão aos valores de PA estimados com os regressores.

1.3.2 Objetivos específicos

- Implementar e avaliar algoritmos de regressão para estimação da pressão diastólica e sistólica utilizando características extraídas dos sinais de ECG e PPG.
- Utilizar classificadores de padrões para estimar faixas em que se encontram a PA diastólica e sistólica, dentro de um conjunto de faixas previamente definidas em treinamento e assim comparar o resultado de classificação dessas faixas com os erros de regressão obtidos nos métodos já avaliados na literatura.
- Comparar os resultados dos métodos avaliados com o métodos existentes na literatura, tanto em termos de métricas de desempenho para estimação da PA, como no sentido de utilizar como uma possível ferramenta para auxiliar no diagnóstico de hipertensão.

1.4 JUSTIFICATIVA

A falta de um diagnóstico prévio da Hipertensão Arterial (HA) pode causar diversas complicações como ataques cardíacos, AVC, doença renal, doença ocular e outros problemas graves [45]. Além disso, está entre os principais fatores que levam a óbito [8].

No sistema público de saúde no Brasil, o custo anual estimado para o tratamento da HA é de aproximadamente US\$ 398,9 milhões o que representa 1,43% dos gastos totais do Sistema Único de Saúde (SUS). No setor privado, o gasto anual atinge cerca de US\$ 272,7 milhões, representando 0,83% do total de gastos [10]. Já as estimativas de custo anual com medicamentos para tratamento da HA correspondem a 52,3% dos gastos no SUS e de 27,3% no setor privado [10].

A presente pesquisa propõe utilizar novas técnicas para estimar a PAD e a PAS

utilizando características extraídas dos sinais de ECG e PPG, de modo a estimar a PA continuamente. Este tipo de investigação pode viabilizar o desenvolvimento de novos dispositivos vestíveis capazes de estimar a PA apenas com os sinais de ECG e PPG.

Outro caso em que esse estudo pode ser útil diz respeito a pacientes que estão na UTI, pois não seria necessária a utilização do cateter para medir a PA continuamente, assim evitando infecções ou outras complicações causadas pelo uso do cateter.

Segundo Peter, os médicos necessitam de métodos confiáveis e que sejam capazes de coletar informações durante longos períodos para obter um melhor diagnóstico [35]. Já os pacientes desejam que os métodos para medição de PA sejam automatizados e que não dependam de manguito inflável, que é desconfortável quando utilizado por longos períodos [35].

Em recém-nascidos há uma dificuldade de se medir a PA com exatidão, pois existem inúmeros fatores de difícil controle que interferem na leitura correta da PA [23]. Um desses fatores é a dificuldade de escolher o manguito correto para as mais variadas larguras de braço; uma escolha errada pode influenciar na exatidão da PAD e da PAS, tanto para mais como para menos [38]. Outro fator é a dificuldade de obtenção da PA em crianças com pouca idade gestacional, com pouco peso, ou chorosas tornando sons de Korotkoff quase inaudíveis pela baixa amplitude do pulso e baixa Frequência Cardíaca (FC) [23, 38].

1.5 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está dividida em cinco capítulos.

No primeiro capítulo, é feita uma introdução à motivação da dissertação. São apresentados os conceitos básicos e a importância de se monitorar a PA, expondo as vantagens e desvantagem de se utilizar os diversos métodos de medir a pressão. São ainda definidos os objetivos desta pesquisa, diante do contexto apresentado.

No capítulo 2, é apresentada a fundamentação teórica, que descreve os métodos de medir a PA em modo invasivo e não invasivo, seguidos das suas vantagens e desvantagens. O capítulo também abrange os sinais de ECG e PPG, bem como a aquisição, condicionamento e processamentos de cada sinal. E finalmente o capítulo descreve o método utilizado para estimar PA com base nos sinais de ECG e PPG.

No capítulo 3, são apresentados os procedimentos utilizados para avaliar e selecionar sinais válidos em uma base de dados, bem como as técnicas para extrair as características de cada sinal. O capítulo detalha os métodos desenvolvidos para analisar o desempenho do sistema e comparar os resultados obtidos com os resultados já existentes na literatura.

O capítulo 4 apresenta os resultados e as interpretações dos testes realizados com o

uso de regressores para a estimação da PA, e de classificadores para avaliar o diagnóstico da pré-hipertensão

Finalmente, o capítulo 5 apresenta a conclusão da dissertação com uma compilação dos resultados alcançados, limitações encontradas e propostas para a continuação da pesquisa.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os conceitos e resultados da literatura científica que fundamentam a técnica utilizada para estimar a PA por meio dos sinais de ECG e PPG. Inicialmente, são apresentados os mecanismos fisiológicos relacionados à PA, seguidos dos principais métodos utilizados hoje para sua medição, incluindo as modalidades invasiva na forma contínua e não-invasiva na forma discreta. Em seguida, são brevemente analisados os sinais de PA, eletrocardiografia e fotopletismografia. O entendimento desses sinais viabiliza a discussão seguinte, referente à medição contínua e não-invasiva da PA. Finalmente, o capítulo discute ainda técnicas de classificação e de regressão de sinais, que são usadas para a construção dos métodos propostos no Capítulo 3.

2.1 PRESSÃO ARTERIAL

A PA é considerada um dos sinais vitais mais importantes [8]. É diretamente relacionada à força resultante que o coração exerce no sangue para que ele circule pelos vasos sanguíneos. A medida da PA é dada em Milímetros de Mercúrio (mmHg), e pode ser dividida em três valores, denominados de PAS, PAD e PAM, que são respectivamente o valor máximo, mínimo e médio da PA. Segundo a Sociedade Brasileira de Cardiologia [8], os valores de PAS e PAD considerados normais são em torno de 120 mmHg e 80 mmHg, respectivamente. Já valores da PAS sistematicamente maiores do que 140 mmHg e da PAD sistematicamente maiores do que 90 mmHg, levam a um diagnóstico de hipertensão.

Com os valores da PAS e da PAD pode-se determinar o valor aproximado da PAM [9], dado por

$$PAM = PAD + \frac{1}{3}(PAS - PAD), \quad (2.1)$$

em que PAD é a pressão arterial diastólica, e PAS é a pressão arterial sistólica. Por ser um método simples, esta aproximação é usada na maioria das situações clínicas [9], mas vale ressaltar que há abordagens mais precisas.

De fato, para se obter a PAM efetiva, é necessário calcular a integral da curva de

pressão, conforme registrado por um período de tempo. Assim,

$$PAM = \frac{\int_{t_i}^{t_f} PA dt}{t_f - t_i}, \quad (2.2)$$

em que PA é a pressão arterial, t_i é tempo inicial, t_f é o tempo final.

2.2 MÉTODOS DE MEDIDA DA PRESSÃO ARTERIAL

2.2.1 Métodos invasivos de medição contínua de pressão

O cateter intra-arterial é o principal instrumento utilizado para medir a PA continuamente, em um método conhecido como IBP. O cateter é um tubo de plástico de alta pressão, que é preenchido com um fluido e conectado diretamente ao sistema arterial que permite realizar a leitura da PA. A forma de onda da PA é transmitida da coluna de fluido para um transdutor, onde é convertida em um sinal elétrico. O sinal elétrico da PA é processado e exibido em um monitor. Na Figura 2.1 é mostrado o esquema de medição da PA usando de um cateter. Os principais locais para canulação podem ser nas artérias periféricas, como a aórtica radial, ulnar, braquial, femoral ou radicular [11]. A IBP é amplamente utilizada para medir a mudança dinâmica súbita de sangue. No entanto, esse método é utilizado de forma restrita, devido à dificuldade de operação e à possibilidade de dor e sangramento, além de infecção [52].

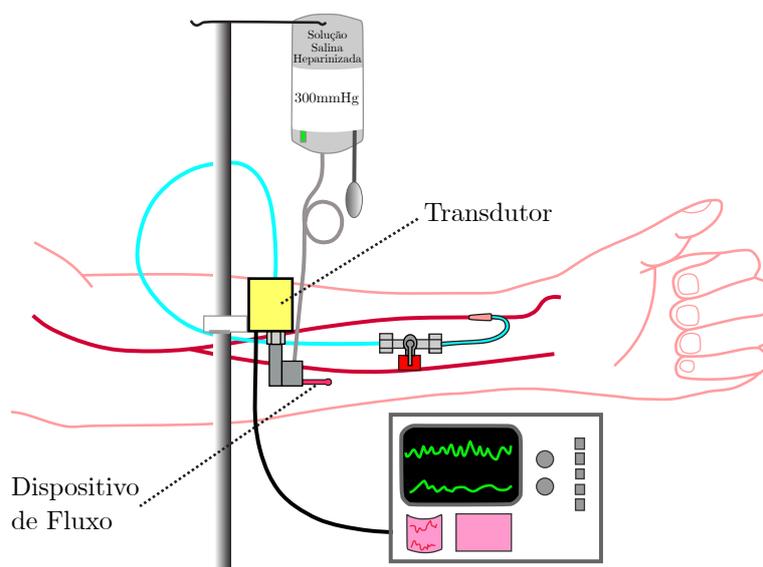


Figura 2.1. Esquema de utilização do cateter para medição contínua da pressão arterial, com o cateter introduzido diretamente na artéria radial. O cateter é conectado a um coluna líquida e pressurizada. Já o transdutor de pressão realiza as leituras da PAS, PAD e PAM, que são mostrados no monitor. O suporte é utilizado para fixação do transdutor e da bolsa de heparina. Adaptado de [39].

2.2.2 Métodos não invasivos de medição de pressão a intervalos espaçados (medição não contínua)

2.2.2.1 Método Auscultatório

O método auscultatório é baseado nos sons de Korotkoff [32]. Trata-se de observar o ciclo do fluxo sanguíneo na artéria ocluída por um manguito, que é posicionado na parte superior do braço. Um estetoscópio é utilizado para auscultar os sons gerados pelo fluxo sanguíneo até o desaparecimento dos sons, quando a oclusão é completamente removida por dilatação do manguito e o fluxo sanguíneo restaurado. Os sons audíveis são causados pelo fluxo de sangue que circula pelo vaso parcialmente ocluído, fluxo este que causa turbulência no vaso e provoca as vibrações auscultadas por meio do estetoscópio [2, 32]. Com o início e o fim dos sons de korotkoff, é possível avaliar qual é a PAD e a PAS. Este método tem a desvantagem de apertar o braço do paciente e a necessidade de fazer cálculos para encontrar a PAM.

2.2.2.2 Método oscilométrico

O método oscilométrico registra as oscilações de pressão em um manguito durante a deflação gradual. As oscilações começam próxima da PAS e continuam até abaixo da PAD. Este método estima a PAD e a PAS de forma indireta. Basicamente um algoritmo encontra a oscilação máxima no manguito, que corresponde à PAM, e utiliza um outro algoritmo para estimar os valores da PAS e PAD [2]. Na Figura 2.2 são mostradas as oscilações de pressão no manguito.

Esse método possui algumas desvantagens, a primeira é o fato de que o sinal adquirido das oscilações da pressão no manguito depende da pressão na parede das artérias, e qualquer variação no estado do paciente pode induzir a erros na medição. Ainda há o fato de que a PAD e a PAS são resultados de cálculos realizados por algoritmos ajustados para um grupo de indivíduos, considerados com batimento cardíaco normal. Por este motivo, o método oscilométrico apresenta limitações em indivíduos com arritmias, taquicardia, diabetes, entre outros estados de saúde que impliquem um batimento cardíaco irregular [32, 2].

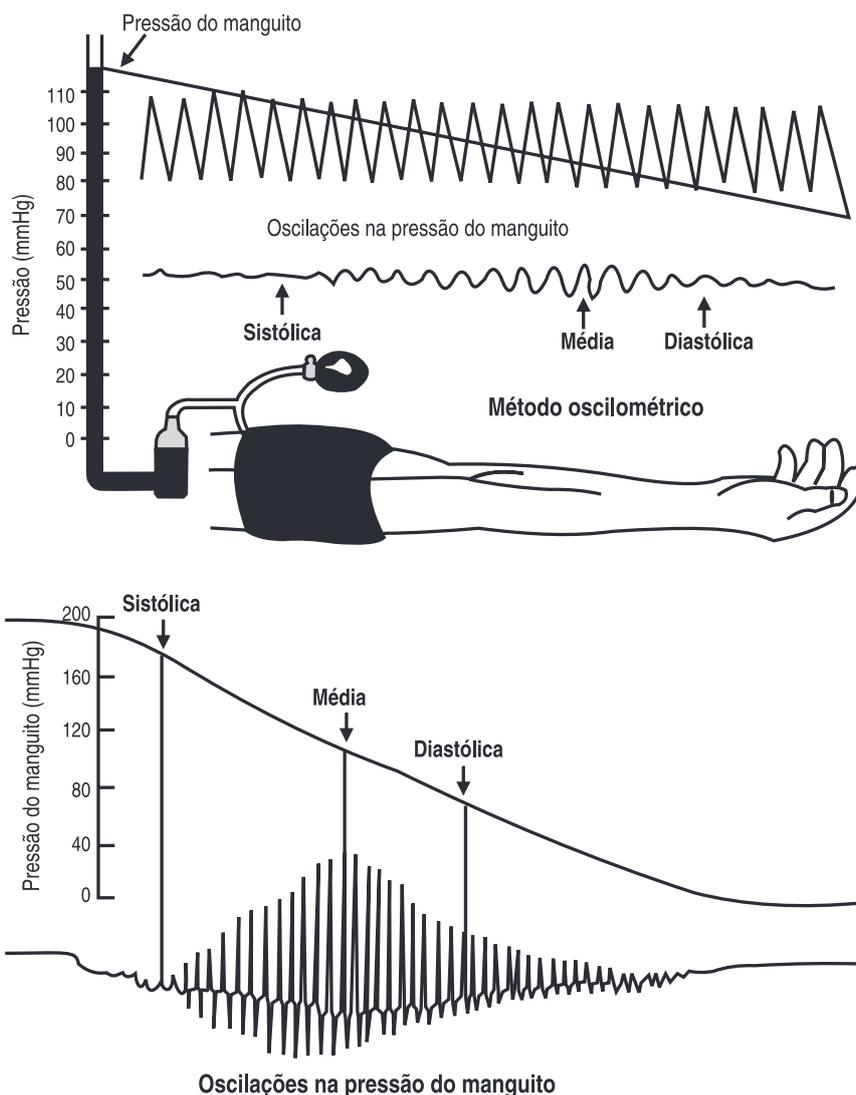


Figura 2.2. Na parte superior da imagem é mostrado um braço envolvido por um manguito, que inicialmente está pressurizado com uma pressão maior que a PAS. Na representação das oscilações é mostrado que aos poucos a pressão do manguito vai sendo reduzida até abaixo da PAD. Na parte inferior da imagem é mostrado as oscilações da pressão no manguito, bem como as marcações da PAS, PAM e PAD. Adaptado de [7].

2.3 ELETROCARDIOGRAMA

O sistema cardiovascular tem o coração como um órgão muscular formado por quatro câmaras. Sua principal função é bombear sangue oxigenado para todas as partes do corpo. Um coração de uma pessoa hígida normalmente mantém um ritmo cardíaco constante. No processo de bombear sangue, primeiramente acontece a contração dos átrios (sístole atrial), que é seguida pela contração dos ventrículos (sístole ventricular) e finalmente durante a diástole todas as quatro câmaras são relaxadas. Para a ativação das câmaras, o coração tem um sistema de condução cardíaca que se espalha por todas as partes

do miocárdio. As estruturas de condução do coração são mostradas na Figura 2.3, em que é apresentado o feixe de His e seus ramos, vias atriais, o Sinoatrial (SA), o nó Atrioventricular (AV) [3, 17].

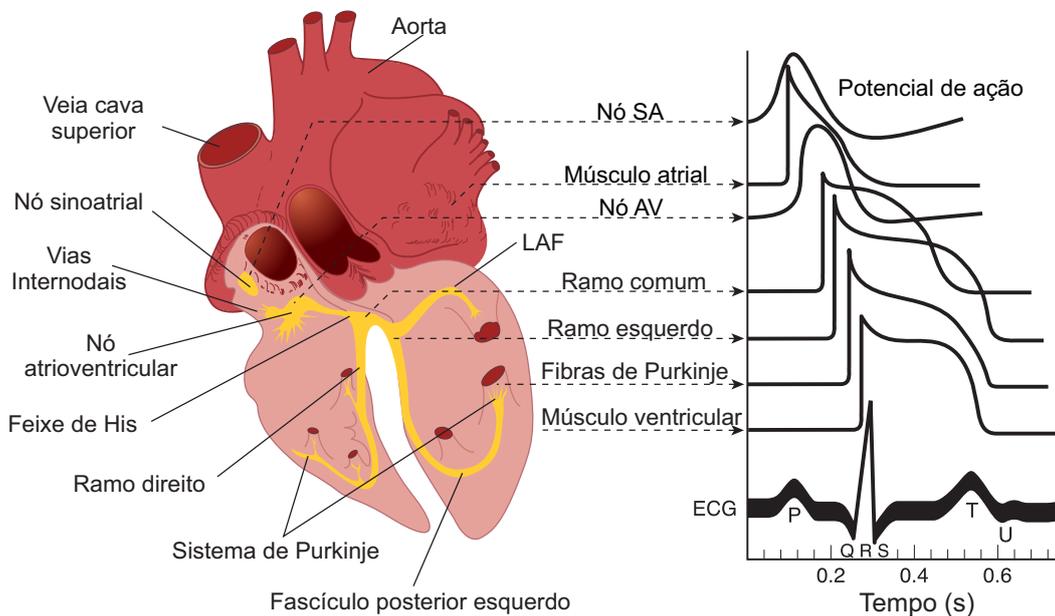


Figura 2.3. No lado esquerdo da imagem é mostrado um coração humano, onde está destacado o sistema de condução. No lado direito da imagem é mostrado a relação das atividades elétricas do sistema de condução de cada músculo do coração, ou seja, a formação do registro de ECG. Adaptado de [3].

O sinal de ECG é formado por ondas de despolarização e repolarização, ou seja, pela soma de várias ondas. A primeira é a onda P, que corresponde à despolarização atrial; em seguida, há o complexo QRS, que corresponde à despolarização ventricular; e finalmente, há a onda T, que corresponde à repolarização ventricular. Na Figura 2.4 é mostrado um sinal de ECG, com cada um dos segmentos e ondas [17].

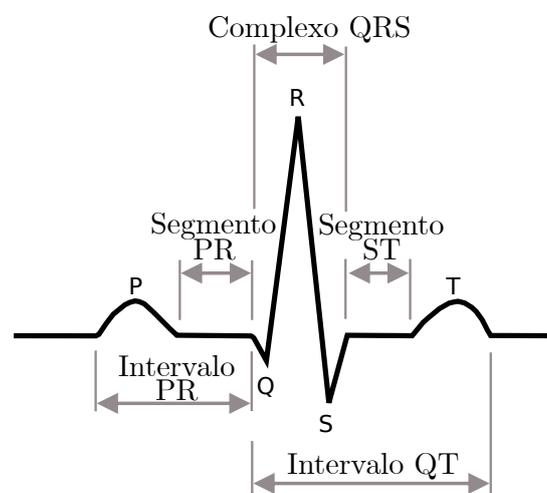


Figura 2.4. Sinal de ECG, onde é mostrado a localização das ondas (P, Q, R, S e T), os segmentos PR e ST e os intervalos PR e QT. Adaptado de [29].

Para aquisição dos sinais de ECG, vários eletrodos são colocadas na superfície da pele para formar as derivações, cada derivação registra a diferença de potencial entre dois eletrodos, desta forma é possível medir a magnitude total do potencial elétrico do coração. Esses sinais são obtidos por um equipamento conhecido como eletrocardiógrafo, que tem a função de adquirir, amplificar, filtrar e registrar os sinais de ECG, que são da ordem de Milivolts (mV) [4].

Geralmente os eletrocardiógrafos comerciais são capazes de registrar 12 derivações. Onde três derivações (I, II e III) são dos membros convencionais, com mais seis derivações precordiais (V1, V2, V3, V4, V5 e V6) e finalmente três derivações aumentadas dos membros (aVR, aVL e aVF). Na Figura 2.5 é mostrado as configurações para formação das derivações. Os eletrodos ligados ao Braço Direito (BD), Braço Esquerdo (BE) e Perna Esquerda (PE), formão o triângulo de Willson, que serve como referência para as derivações precordiais. A derivação I é formada pelo BD, BE, a derivação II é formada pelo BD, PE e a derivação III é formada pelo BE, PE.

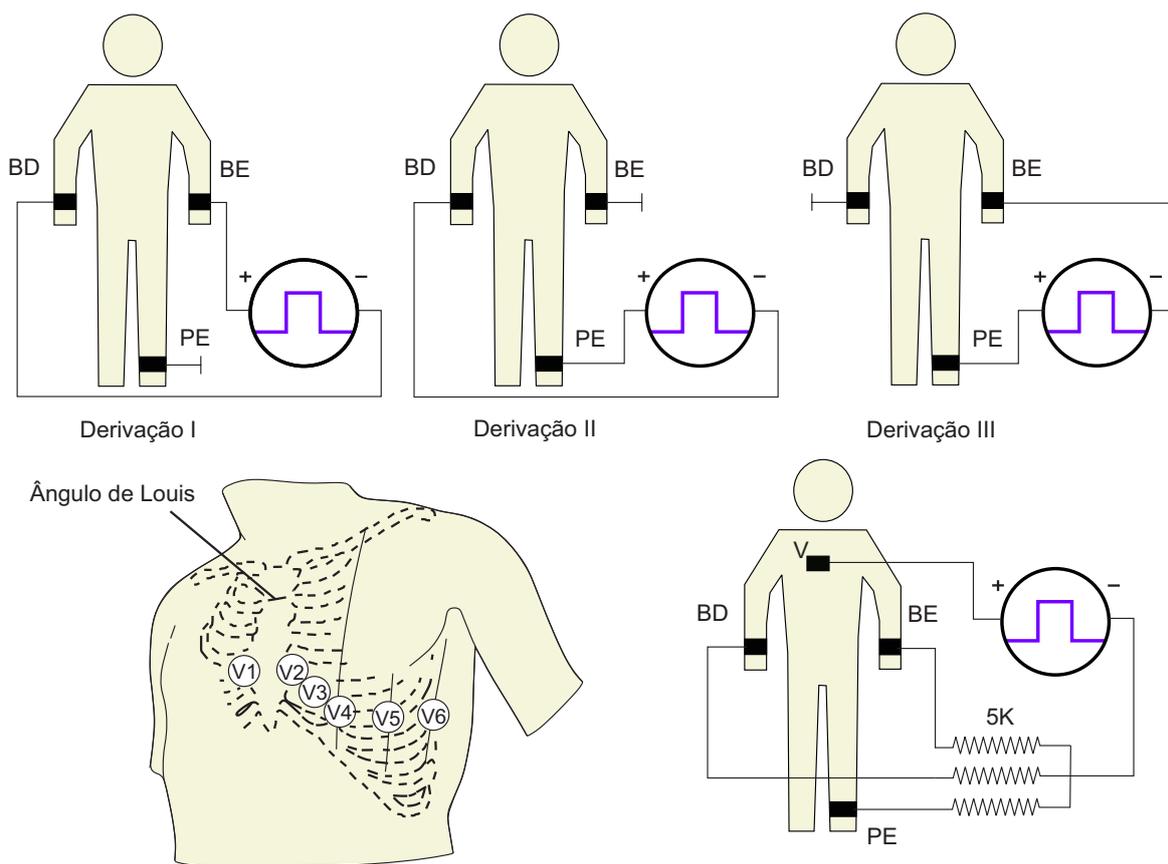


Figura 2.5. Na parte superior da imagem é mostrado o esquema de ligação dos eletrodos para o registro das derivações (I, II e III). Na parte inferior esquerda é mostrado o local dos eletrodos para registro das derivações precordiais (V1, V2, V3, V4, V5 e V6). E na parte inferior direita é mostrado o local dos eletrodos para a formação do terminal central de Wilson. Adaptado de [4].

2.4 FOTOPLETISMOGRAFIA

Pletismografia fotoelétrica (PPG), é um método não invasivo capaz de detectar mudanças no volume sanguíneo em determinadas partes do corpo [44]. O equipamento que adquire o sinal de PPG utiliza basicamente dois componentes: um Diodo Emissor de Luz, do inglês *Light Emitting Diode* (LED) e um fotoreceptor (receptor de luz), que podem ser configurados de duas maneiras. A primeira configuração é colocar o LED na frente do fotoreceptor, fazendo que a luz atravesse todos os tecidos do paciente, essa configuração é conhecida como pletismografia transmissiva. A outra configuração é colocar o LED ao lado do fotoreceptor, desta forma a luz emitida pelo LED é refletida pelos tecidos e capturada pelo fotoreceptor, essa configuração é conhecida como pletismografia reflexiva. Na Figura 2.6 é mostrado um representação dos dois sistemas.

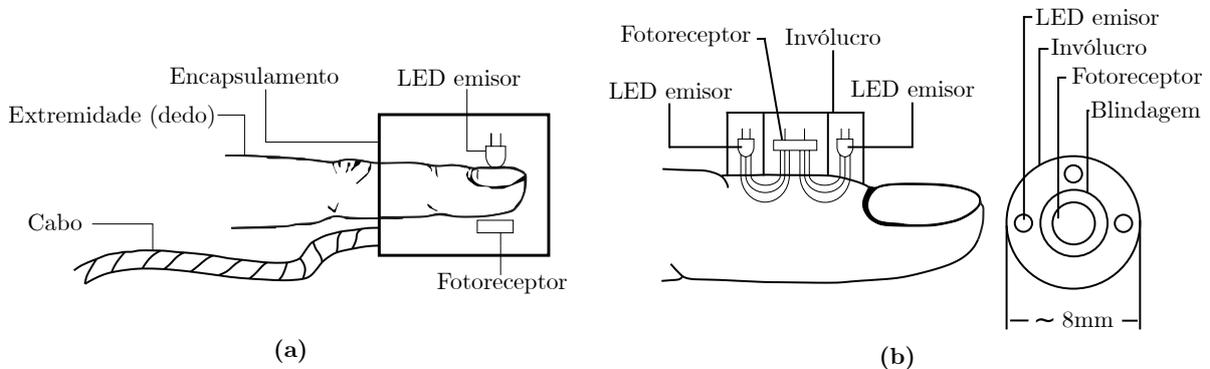


Figura 2.6. Em (a) é mostrado a fotopletismografia transmissiva. O LED emissor e o fotoreceptor de luz, são fixados um na frente do outro, de modo que os componentes fiquem posicionados na extremidade do dedo. Em (b) é mostrado a fotopletismografia reflexiva. O LED emissor e o fotoreceptor de luz, são fixados um ao lado outro, mas separados por um invólucro. Adaptado de [33].

Cada configuração tem características diferentes, a fotopletismografia transmissiva necessita de uma fonte de luz forte, pois, tem de atravessar os tecidos e chegar ao receptor, esse método funciona melhor em parte finas do corpo, como por exemplo, nas ponta dos dedos ou no lóbulo da orelha [33]. Enquanto a fotopletismografia reflexiva, pode ser usada em qualquer parte do corpo, ou seja, em parte mais espessas, e com a vantagem de fornecer a mesma qualidade de sinal, usando uma fonte de luz com menor potência [49].

Como o PPG representa a quantidade de luz infravermelha que o sangue absorve ou reflete, é possível observar uma variações na quantidade de luz que pode ultrapassar o tecido durante o ciclo cardíaco, essa mudança é causada pela variação de pressão do sangue nos vasos sanguíneos [33].

Segundo Jones, o princípio do método inventivo deriva da lei de Beer-Lambert, fornece a relação entre a absorção da luz por uma concentração de um material em função do caminho através da solução. Pela lei de Beer-Lambert, a intensidade de luz transmitida

é dada por [20]

$$I = I_0 e^{-\varepsilon(\lambda)cx}, \quad (2.3)$$

em que I_0 é a intensidade da luz incidente, o $\varepsilon(\lambda)$ é o coeficiente da extinção da luz monocromática no comprimento de onda λ , c é a concentração do material, e o x é a distância.

Ao adquirir um sinal de PPG é possível observar que existe duas componentes, uma Corrente Contínua, do inglês *Direct Current* (DC) e outra Corrente Alternada, do inglês *Alternating Current* (AC). A componente DC está relacionada com a espessura dos tecidos e cor da pele. Como essa estrutura não muda no decorrer do tempo, ela sempre vai absorver a mesma quantidade de luz. Já a componente AC está relacionada com a variação do sangue no tecido e tem uma associação com a frequência cardíaca [49].

2.5 MEDIÇÃO CONTÍNUA E NÃO INVASIVA DA PRESSÃO SANGUÍNEA

2.5.1 Parede arterial

Nesse item é descrito apenas algumas informações importantes sobre as paredes arteriais. Basicamente a parede arterial é formada pelas seguintes estruturas: endotélio, elastina, colágeno e o músculo liso. O endotélio tem a função de produzir uma parede lisa para o fluxo sanguíneo no interior dos vasos, não tendo nenhum efeito considerável nas propriedades mecânicas da parede arterial. A elastina tem a função de produzir tensão no início da expansão da parede arterial e é altamente extensível. O colágeno tem a função de exercer tensão na parede arterial e é muito mais rígido que a elastina, seu efeito acontece apenas após o início do esticamento da artéria. O músculo liso tem a função de produzir tensão para modular a elasticidade arterial. Ao observar as propriedades das paredes arteriais, os efeitos inerciais podem ser desprezíveis, pois, as propriedades dessas camadas é diferente em vários pontos da árvore arterial. A elastina é mais abundante nas artérias centrais e exerce sua elasticidade em valores baixos da PA. Já em valores mais altos da PA, o colágeno determina a elasticidade da parede arterial. E o músculo liso tem uma atuação maior nas artérias periféricas [21, 28].

2.5.2 Propagação da onda de pressão nas artérias

Com algumas das propriedades das paredes arteriais descritas no item anterior, é possível modelar a propagação da onda de pressão do sistema vascular, utilizando um tubo cilíndrico estático, com propriedades semelhantes as das paredes arteriais, é empregado modelos de propagação em tubos, e assim relacionando a elasticidade da parede arterial com o PTT [21, 28]. Desta forma a pressão (P) nos tubos está relacionada com o módulo

elástico (E), que é dada por

$$E = E_0 \cdot e^{\alpha(P-P_0)}, \quad (2.4)$$

em que E_0 , P_0 e α são parâmetros inerentes a cada indivíduo [18, 21]. A onda de pressão que tem início em uma extremidade proximal, leva um tempo para se propagar através de um tubo e assim atingir a extremidade distal. Esse tempo é chamado de PTT, que é baseado no período em que a onda de pulso sai do coração e chega a um membro periférico. Esse tempo pode ser medido por meio de um ECG e de um PPG. A onda R do ECG, é um bom parâmetro, pois ocorre no início da sístole do coração, isso quando o sangue é ejetado do coração para a aorta e assim é criado a onda de pressão de pulso [35]. Na Figura 2.7 é ilustrado a relação entre os sinais de ECG e PPG.

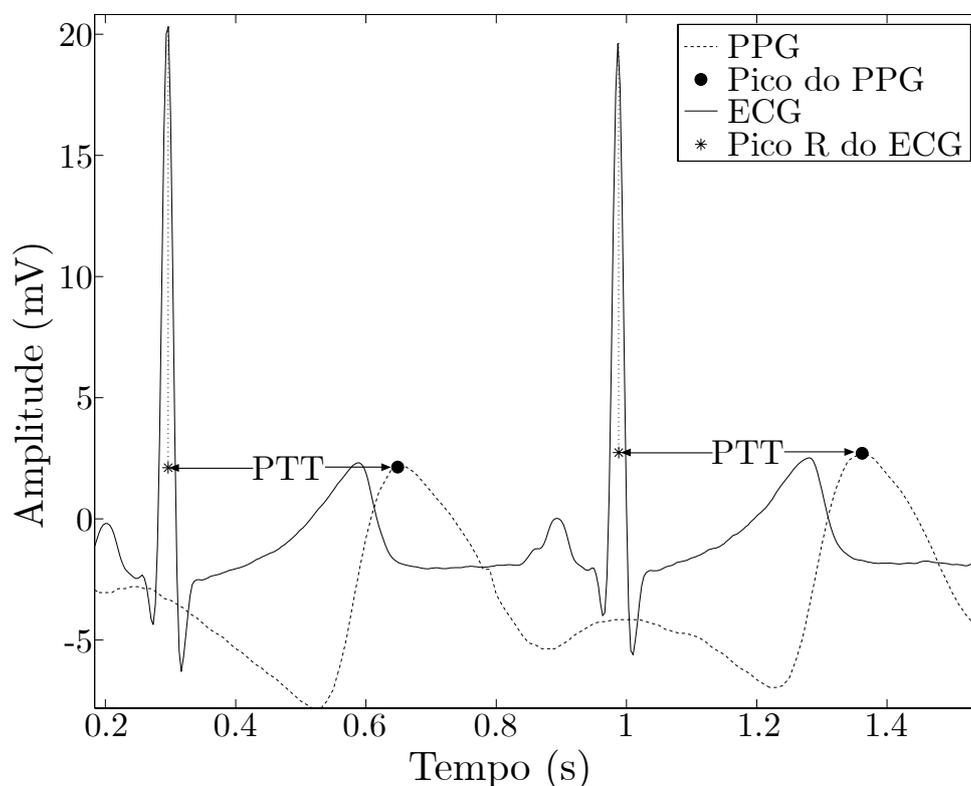


Figura 2.7. Relação entre o sinal de ECG (Linha contínua) e o sinal de PPG (Linha tracejada). Observe que o PTT é o tempo entre o pico da onda R do sinal de ECG e o ponto máximo do sinal de PPG. Adaptado de [14].

2.6 CLASSIFICAÇÕES DE SINAIS

2.6.1 Máquina de vetor de suporte (SVM)

A Máquina de Vetor de Suporte, do inglês *Support Vector Machine* (SVM) é um algoritmo de aprendizagem de máquina supervisionado, é considerado um dos algoritmos de aprendizagem de máquina mais poderosos, quando se trata de criação de modelos fortes,

com um nível de esforço computacional razoável [21]. É capaz de reconhecer padrões de acordo com os dados de entrada. Inicialmente é necessário realizar um treinamento do algoritmo. Nesse ponto é fornecido um conjunto de dados, onde se tem os dados de entrada e a saída esperada para cada caso, ou seja, separando os dados em classes. A SVM faz uso de funções *Kernel* para classificar problema não lineares, onde são criados hiperplanos com dimensões superiores.

2.6.2 Robust boosting

O *Robust boosting* é uma extensão do *AdaBoosting*, só que com algumas melhorias, como por exemplo redução a sensibilidade ao ruído. O *AdaBoosting* tem o problema que é a rápida deterioração quando um ruído aleatório é adicionado ao conjunto de treinamento [13]. O algoritmo *Robust boosting* é significativamente mais robusto contra ruído quando comparado como o *AdaBoosting* e tem a vantagem de exigir menos dados de treinamento [13].

2.7 REGRESSÃO NÃO-LINEAR DE SINAIS

2.7.1 Regressão por vetores de suporte (SVR)

A SVR usa os mesmos princípios que a SVM, com algumas poucas diferenças, a principal diferença é que a SVR retorna um número real em vez de uma classificação como acontece na SVM [41]. A SVR utiliza *kernels* para resolver problemas não lineares, tem a vantagem de não depender de otimização em espaços de alta dimensionalidades [26, 47].

2.7.2 Regressão por árvore de decisão

A regressão por árvore de decisão cria modelos em um formato de árvores, que consiste em um certo número de nós de decisão, cada nó possui duas ou mais ramificações, ou seja, esse modelo divide um conjunto de dados em subconjunto cada vez menor. No início do processo, cada entrada segue um caminho na árvores até chegar no valor final, todas as decisões são baseadas no processo de treinamento. Basicamente esse modelo tenta encontrar o menor valor de desvio padrão para calcular a homogeneidade de uma amostra numérica [21, 40].

2.7.3 Regressão baseado em bagging predictors

O algoritmo *Bagging Predictors* é baseado em outro algoritmo conhecido como *Bootstrap*, que utiliza árvores de classificação e regressão. Basicamente o algoritmo *Bagging Predictors* realiza uma amostragem e gera vários outros algoritmos, em seguida utiliza todos os algoritmos gerados para obter um novo algoritmo de classificação ou regressão aprimorado. Durante o processo é realizado cálculos da média de cada um dos algoritmos para prever o valor numérico de cada classe [5].

2.7.4 Modelo de regressão linear

O modelo de regressão linear tem como principal característica a linearidade dos coeficientes dos preditores. Esse algoritmo descreve a relação entre as respostas e os preditores, que incluem informações sobre estimativas de coeficiente, estatísticas resumidas, método de ajuste e dados de entrada [25].

2.7.5 Modelo linear de regressão generalizado

O modelo linear de regressão generalizado é baseado no modelo de regressão linear descrito anteriormente, no entanto utiliza respostas exponenciais de distribuições, como distribuições binomial, poisson, normal, gama e normal inversa entre outras [12].

2.7.6 LSboost

O algoritmo *LSboost* é baseado em um outro algoritmo *Random forests*, no qual utiliza uma combinação de preditores em árvores, de modo que cada uma das árvores dependa de um vetor aleatório amostrado independente e com a mesma distribuição para todas as outras árvores [6].

2.7.7 Stepwise Linear Model

A regressão *stepwise linear model* realiza a escolha de variáveis para o modelo preditivo, a fim de encontrar o melhor modelo que reduz o erro de previsão dos dados. Existem três estratégias de regressão gradual: seleção direta, seleção para trás e a seleção gradual [24].

3 METODOLOGIA

Neste capítulo são apresentadas as técnicas utilizadas para estimar a PA a partir dos sinais de ECG e PPG, previamente adquiridos do banco de dados MIMIC-III do site Physionet [37]. Na Figura 3.1 é mostrado um diagrama de blocos resumindo todo processo de processamento dos sinais.

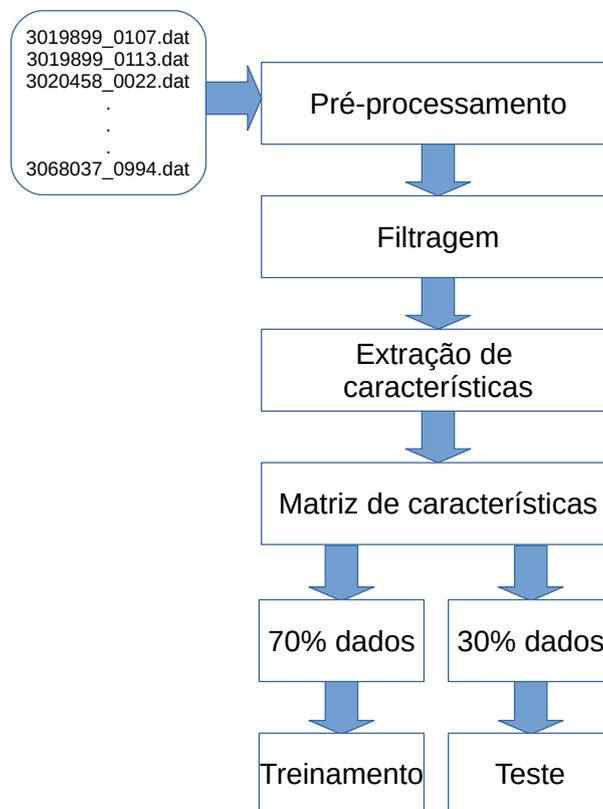


Figura 3.1. Diagrama de blocos, onde é mostrado a entrada dos sinais, filtragem dos sinais e treinamento e teste do algoritmo de classificação e regressão.

3.1 BANCO DE DADOS

Os sinais de ECG, PPG e PA foram adquiridos do banco de dados *The MIMIC-III Waveform Database* [37], que é um banco de dados gratuito, que contém inúmeros sinais fisiológicos de pacientes que se encontravam na UTI. Cada conjunto de sinais foram

adquiridos por um único monitor de paciente. Cada registro pode conter até oito formas de ondas simultaneamente, incluindo as ondas de ECG, PPG e PA, que são os sinais de interesse para este trabalho. Cada registro possui um arquivo de cabeçalho que contém informações de taxa de amostragem, tamanho do sinal, quantidade de sinais dentro do registro, unidades de medida e o nome de cada sinal. Todos os sinais de ECG, PPG e PA estão amostrados a uma taxa de 125Hz e com resolução de 8, 10 ou 12 bits [37].

No banco de dados *The MIMIC-III Waveform Database*, não se tem informações disponíveis sobre os pacientes como: idade, sexo, dados clínicos. Estas informações são restritas ao público em geral. Para se obter esses dados é necessário solicitar o acesso ao banco de dados *MIMIC-III Clinical Database* no site *Physionet* e participar de um curso *Data or Specimens Only Research*.

Para selecionar os sinais de interesse, foi criado um algoritmo em *Python* que realizou uma varredura no banco de dados, buscando pelos registros que contia pelo menos um sinal de ECG, um de PPG e um de PA, caso o algoritmo encontrasse os três sinais, era feito o *download* do arquivo *.dat* e *.hea*.

Inicialmente foram adquiridos 38458 registros com sinais de ECG, PPG e PA. Destes 20917 registros estavam com interrupções, 280 registros com saturação, restando 17261 registros, com o restante dos 17261 sinais, foi realizada uma seleção manual onde foram escolhidos registros que possuía a onda R maior que as outras ondas do sinal de ECG, desta forma foram selecionados 42 registros. Na Tabela 3.1 são mostrados os critérios de inclusão e exclusão utilizados para selecionar os sinais.

Tabela 3.1. Critérios de inclusão e exclusão para os sinais de ECG, PPG e PA.

Critérios de inclusão	Critérios de exclusão
<ul style="list-style-type: none"> • Sinais com registros maiores que 10 segundos • Onda R maior que as outras ondas no sinal de ECG 	<ul style="list-style-type: none"> • Sinais com saturação • Sinais com interrupções

Nos sinais adquiridos do banco de dados, foram identificadas interrupções ao longo do sinal, desta forma foi necessário selecionar os trechos do sinal que não possuíam interrupções. Assim, foi criado um algoritmo que realiza a leitura de cada registro e verifica se os sinais possuíam algum tipo de problema. Primeiro foi realizada uma avaliação dos sinais, em que o algoritmo verifica se os sinais possuíam picos ou vales discrepantes, ou se o sinal estava saturado. Nesse processo foram analisados os sinais de ECG, PPG e PA, inicialmente foram verificados os pontos de saturação do sinal e se o intervalo com sinal sem saturação era maior que 5 segundos, caso essa condição não fosse satisfeita, o trecho do sinal é descartado. Caso a condição fosse atendida, então o algoritmo verificava se nos outros sinais possuem o mesmo trechos onde a mesma condição é satisfeita. Após selecionar os trechos dos sinais, os intervalos validos foram correlacionados com os

outros sinais, em que foi verificado se cada trecho valido correspondia ao mesmo trecho nos outros sinais. Desta forma, foram salvos os trechos de sinais que possuíam o mesmo intervalo de tempo com sinais válidos.

Quanto a taxa de amostragem cabe avaliar se ela é ou não suficiente para a estimação da PA. De fato, pode-se argumentar que pode haver perda de informações no processo de subamostragem do sinal. Para se verificar se uma amostragem do sinal pode ser um problema, foram realizados alguns cálculos para avaliar o efeito da taxa de amostragem sobre os erros nas estimativas de intervalos temporais. Desta forma com uma taxa de 125Hz, o intervalo entre duas amostras é de $FS_{125Hz} = \frac{1}{125Hz}$, $FS_{125Hz} = 8ms$. Logo o erro máximo é de $4ms$. E para a taxa de 600Hz, o intervalo entre duas amostra é de $FS_{600Hz} = \frac{1}{600Hz}$, $FS_{600Hz} = 1.67ms$. Logo o erro máximo é de $0,84ms$.

De forma alternativa, foram realizados alguns experimento com sinais de ECG, que foram adquiridos em 600Hz por um eletrocardiógrafo da marca Micromed, modelo Win-cardio. Na sequência foi criado um algoritmo para realizar uma subamostragem do sinal de ECG de 600Hz para uma nova amostragem de 120Hz. E um outro algoritmo para encontrar os picos da onda R no sinal de ECG. Na Tabela 3.2 é mostrado o instante da localização do pico da onda R tanto para o sinal amostrado em 600Hz quanto para o sinal amostrado em 120Hz. Na Figura 3.2 é mostrado os dois sinais de ECG.

Tabela 3.2. Diferença entre a amostragem a 600Hz e 120Hz. Em cada caso é apresentado o número da amostra e o tempo em segundos da localização do pico da onda R do sinal de ECG. No final da tabela é mostrado a diferença em *ms* entre a localização do pico da onda R de ambos os sinais amostrados em 600Hz e 120Hz.

Descrição	Localização do pico R						
	1	2	3	4	5	6	7
Nº da Amostra (600Hz)	285	885	1486	2086	2686	3286	3886
Tempo em Segundos (600Hz)	0,4750	1,4750	2,4766	3,4766	4,4766	5,4766	6,4766
Nº da Amostra (120Hz)	57	177	297	417	537	657	777
Tempo em Segundos (120Hz)	0,4750	1,4750	2,4750	3,4750	4,4750	5,4750	6,4750
Diferença (ms)	0	0	1,6	1,6	1,6	1,6	1,6

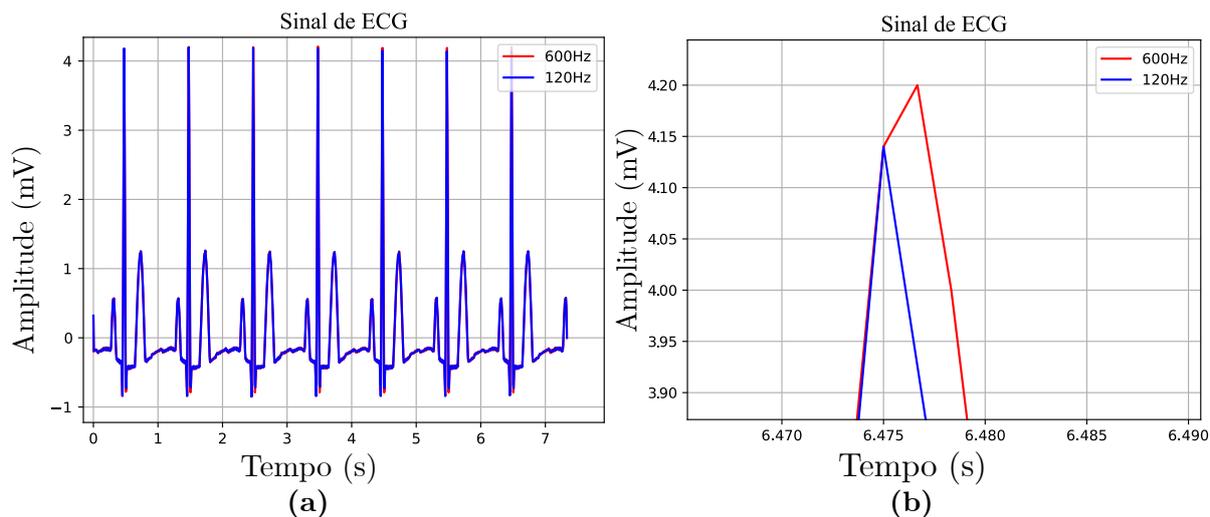


Figura 3.2. Em vermelho o sinal de ECG amostrado em 600Hz e em azul o mesmo sinal de ECG amostrado em 120Hz. Em (a) é mostrado o sinal de ECG completo e em (b) é mostrado um *zoom* do sinal, onde é possível ver detalhes entre os dois sinais.

No segundo teste, foi selecionado um outro sinal de ECG, também amostrado em 600Hz. Na Tabela 3.3 é mostrado o instante da localização do pico da onda R tanto para o sinal amostrado em 600Hz quanto para o sinal amostrado em 120Hz. Na Figura 3.3 é mostrado os dois sinais de ECG.

Tabela 3.3. Diferença entre a amostragem a 600Hz e 120Hz. Em cada caso é apresentado o número da amostra e o tempo em segundos da localização do pico da onda R do sinal de ECG. No final da tabela é mostrado a diferença em *ms* entre a localização do pico da onda R de ambos os sinais amostrados em 600Hz e 120Hz.

Descrição	Localização do pico R						
	1	2	3	4	5	6	7
Nº da Amostra (600Hz)	169	846	1521	2184	2894	3531	4133
Tempo em Segundos (600Hz)	0,2816	1,4100	2,5350	3,6400	4,8233	5,8850	6,8883
Nº da Amostra (120Hz)	34	169	304	437	579	706	827
Tempo em Segundos (120Hz)	0,2833	1,4083	2,5333	3,6416	4,8250	5,8833	6,8916
Diferença (ms)	-1,6	1,6	1,6	-1,6	-1,6	1,6	-3,3

Com pode ser observado nos testes realizados, a maior diferença entre a localização do pico da onda R foi de $3,3ms$, menor que o erro calculado que seria de $4ms$ para o sinal de 125Hz. Desta forma a subamostragem não é um problema significativo para este trabalho.

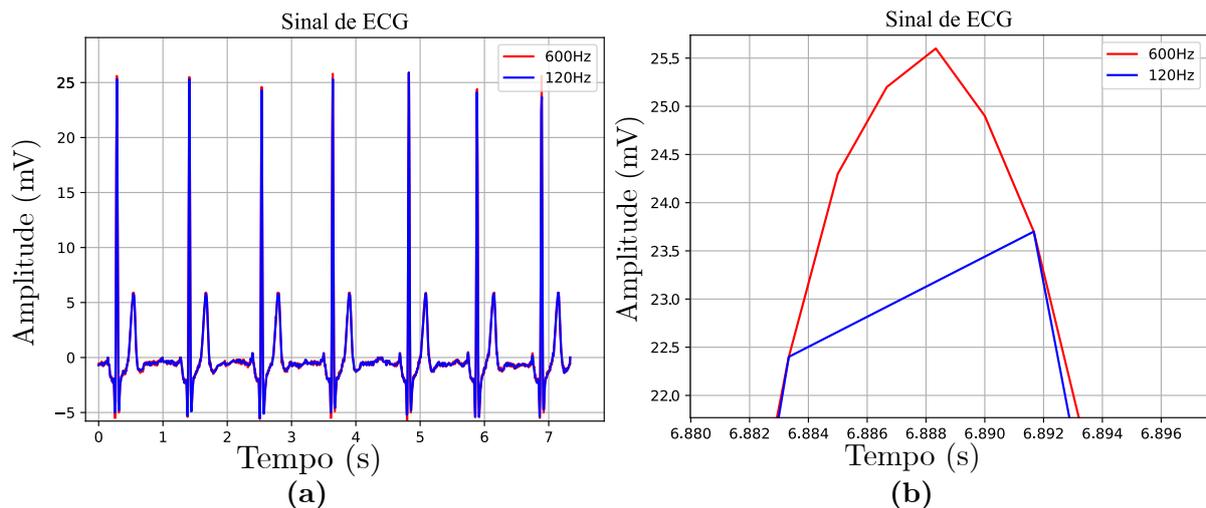


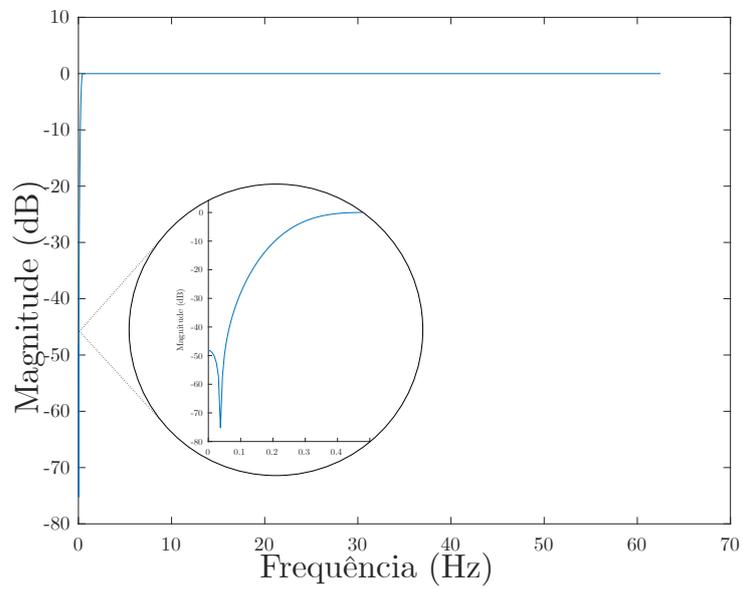
Figura 3.3. Em vermelho o sinal de ECG amostrado em 600Hz e em azul o mesmo sinal de ECG amostrado em 120Hz. Em (a) é mostrado o sinal de ECG completo e em (b) é mostrado um *zoom* do sinal, onde é possível ver detalhes entre os dois sinais.

3.2 PROCESSAMENTO DE SINAIS DE ELETROCARDIOGRAFIA E DE FOTOPLETISMOGRAFIA

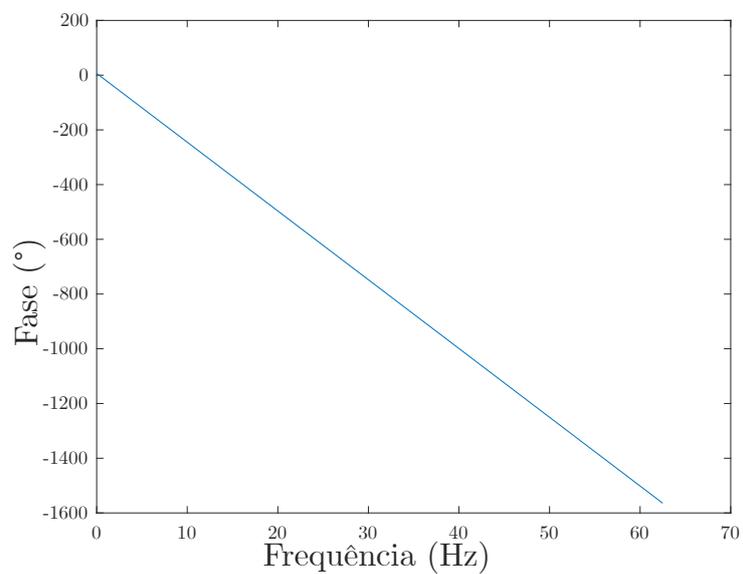
Para a filtragem dos sinais de ECG e PPG, foram projetados filtros com Resposta ao Impulso Finita, do inglês *Finite Impulse Response (FIR)*. Esses filtros são estáveis e tem uma ótima linearidade de fase para preservar a resposta impulsional, a fase linear o que é importante para não causar distorções nas ondas presentes nos sinais.

Na Figura 3.4 é mostrado a resposta do filtro passa-alto de 0.25Hz, projetado para o sinal de PPG, com uma ordem de 1000 que permitiu uma largura de banda de transição reduzida de forma não provocar distorções em outros componentes do sinal.

Na Figura 3.5 é mostrado a resposta do filtro passa-alto de 0.5Hz, projetado para o sinal de ECG, com uma ordem de 1000. E na Figura 3.6 é mostrado a resposta do filtro rejeita-faixa de 60Hz, projetado para o sinal de ECG, com uma ordem de 2000. A escolha da ordem de 1000 e 2000 para o sinal de ECG, foi pelo fato que essa ordem permitiu uma largura de banda de transição reduzida de forma não provocar distorções em outros componentes do sinal.



(a)



(b)

Figura 3.4. Em (a) é mostrado a resposta em frequência do filtro passa-alto do tipo FIR, com corte em 0.25Hz, e com um destaque nas baixas frequências. E em (b) é mostrado a fase do filtro.

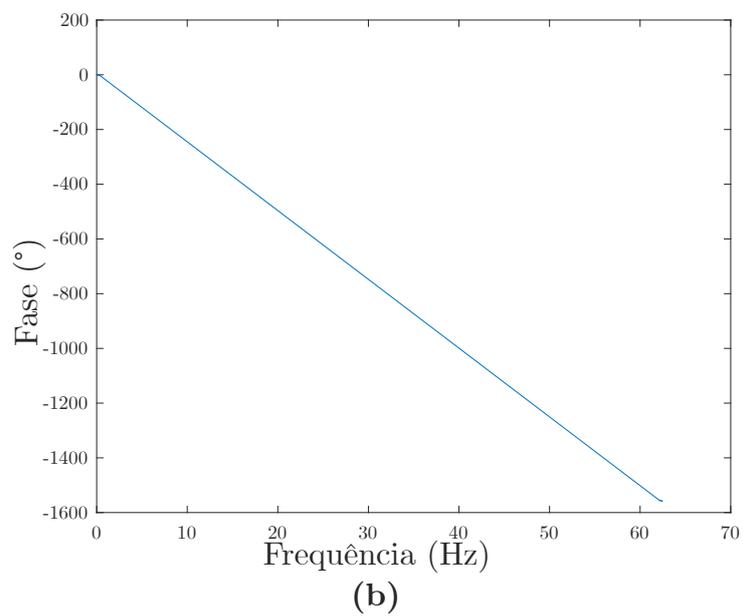
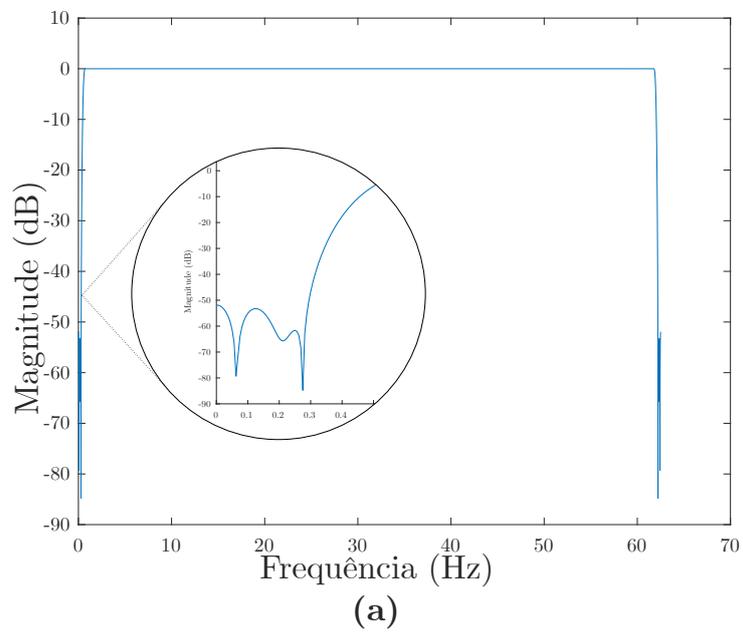


Figura 3.5. Em (a) é mostrado a resposta em frequência do filtro passa-alto do tipo FIR, com corte em 0.5Hz, e com um destaque nas baixas frequências. E em (b) é mostrado a fase do filtro.

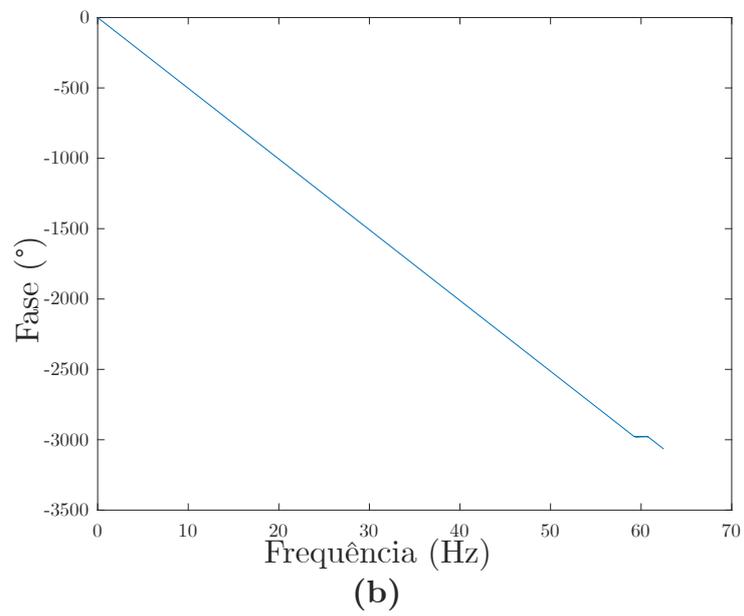
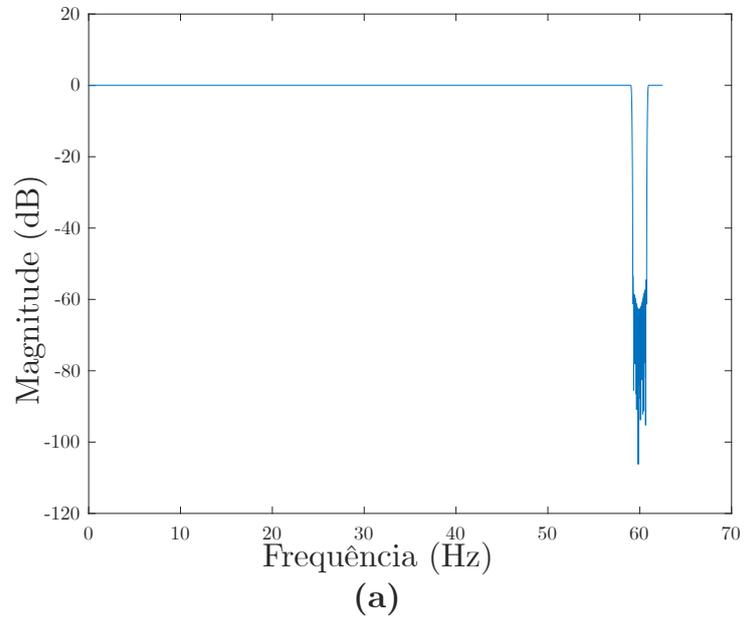


Figura 3.6. Em (a) é mostrado a resposta em frequência do filtro rejeita-faixa do tipo FIR, com corte em 60Hz. E em (b) é mostrado a fase do filtro.

3.2.1 Filtragem do sinal de ECG

Ao analisar os sinais de ECG, foram identificados ruídos de 60Hz provindos da rede elétrica e uma variação da linha de base, próxima de 0Hz. Para eliminar a componente de frequência de 60Hz, foi projetado um filtro de rejeita-faixa FIR com uma ordem de 2000. Como a amostragem do sinal é de 125Hz, a banda é limitada em 62.5Hz, desta forma o sinal não possui a harmônica de 120Hz. Para eliminar a linha de base do sinal, foi projetado um filtro passa-alto FIR com uma ordem de 1000 e com a frequência de corte em 0,5Hz. Na Figura 3.7 é mostrado o sinal antes e depois do processo de filtragem e os gráficos no domínio da frequência.

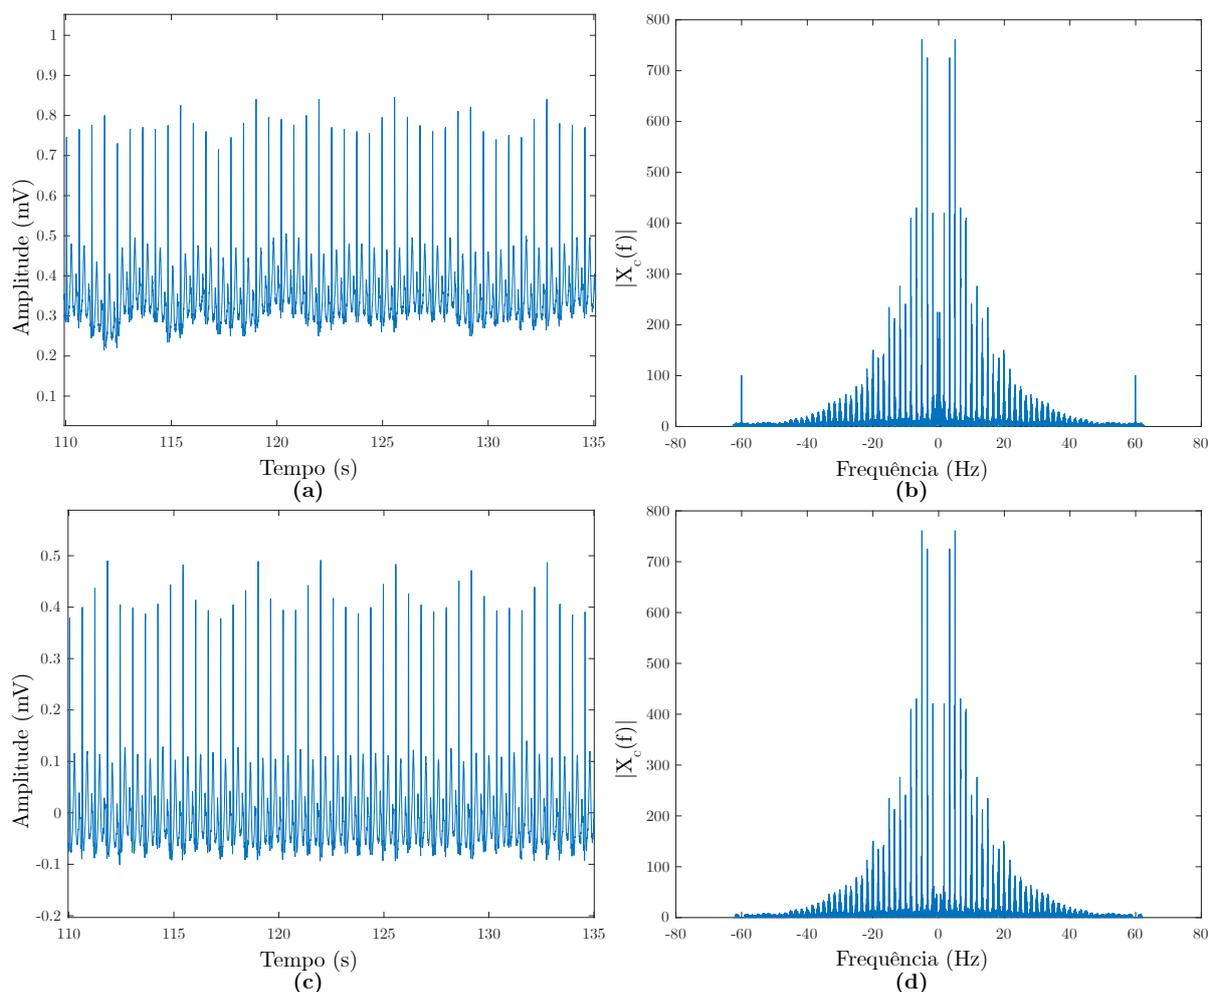


Figura 3.7. Sinal de eletrocardiograma, onde é mostrado: (a) no domínio do tempo o sinal bruto, com variações na linha de base; (b) no domínio da frequência, em magnitude, com uma componente em 60Hz e outra próxima a 0Hz. Observe que em (c) no domínio do tempo, com o sinal já filtrado com um filtro FIR passa-alto e outro rejeita-faixa, não há uma linha de base tão intensa no domínio do tempo como no caso de (a). No domínio da frequência (d), observa-se a eliminação dos picos em torno de 60 hertz, presentes em (b) e a redução das componentes próximo a 0 hertz.

3.2.2 Filtragem do sinal de PPG

Ao analisar os sinais de PPG, foi verificada a necessidade de filtrar a linha de base do sinal. Para isso foi projetado um filtro passa-alto FIR com uma ordem de 1000 e com a frequência de corte em 0,25Hz. Na Figura 3.8 é mostrado o sinal antes e depois do processo de filtragem e os gráficos no domínio da frequência.

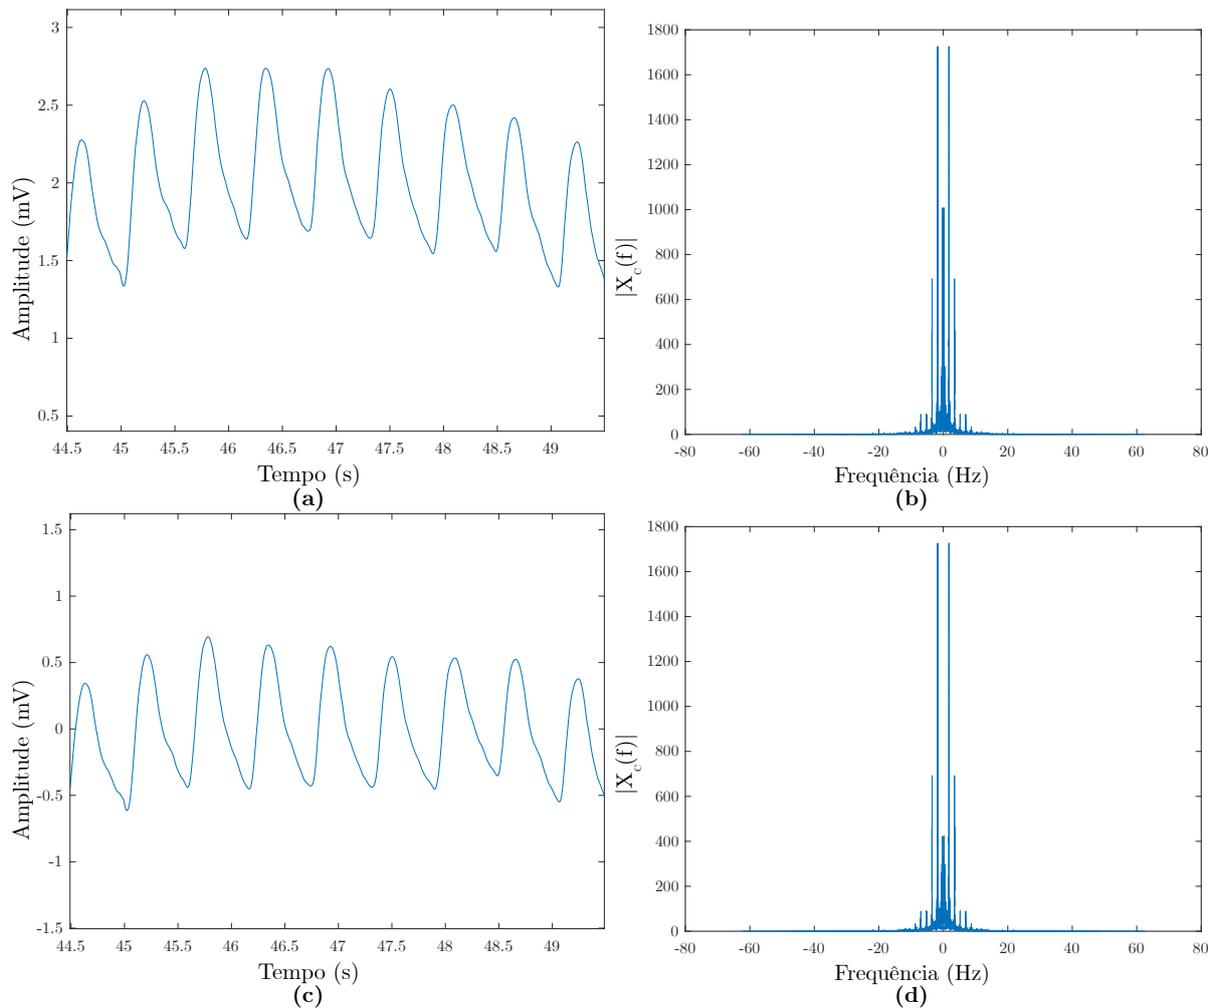


Figura 3.8. Sinal de fotopletismografia, onde é mostrado: (a) no domínio do tempo o sinal bruto, com variações na linha de base; (b) no domínio da frequência, em magnitude, com uma componente próxima a 0Hz. Observe que em (c) no domínio do tempo, com o sinal já filtrado com um filtro FIR passa-alto, não há uma linha de base tão intensa no domínio do tempo como no caso de (a). No domínio da frequência (d), observa-se a redução das componentes próximo a 0 hertz.

3.3 DESENVOLVIMENTO DOS ALGORITMOS DE EXTRAÇÃO DE CARACTERÍSTICAS DE ESTIMAÇÃO DA PA

3.3.1 Extração de características dos sinais de ECG e PPG

O primeiro algoritmo desenvolvido para extração de características diz respeito à verificação da existência de picos nos sinais de ECG e PPG, ou seja, se não está faltando algum dos picos. Desta forma foi realizado um casamento dos picos de ECG com os de PPG. Para encontrar os picos da onda R do ECG foi utilizado o algoritmo de *Pan Tompkins* [34], e para localizar os picos e vales do PPG foi utilizada a função *FindPeaks* do MatLab R2019a 64-bit STUDENT. O algoritmo inicia a procura por todos os picos de ECG, em seguida é localizado todos os picos do PPG. Ao analisar os picos, o algoritmo procura o primeiro pico do ECG e verifica se o pico de PPG está antes do próximo pico de ECG. Caso a condição anterior seja satisfeita, o algoritmo verifica se antes do pico de PPG existe um pico de ECG. Caso o algoritmo não encontre algum dos picos, o trecho correspondente é descartado.

Durante os testes, foi identificado que alguns dos picos não foram localizados corretamente. Desta forma foi necessário criar um novo algoritmo para inspecionar se todos os picos de ECG e PPG foram localizados. Com esse algoritmo é possível inserir ou excluir qualquer localização dos picos de forma manual, ou simplesmente realizar ajustes. Nas Figuras 3.9 e 3.10 é mostrado o processo de correção de um pico de PPG.

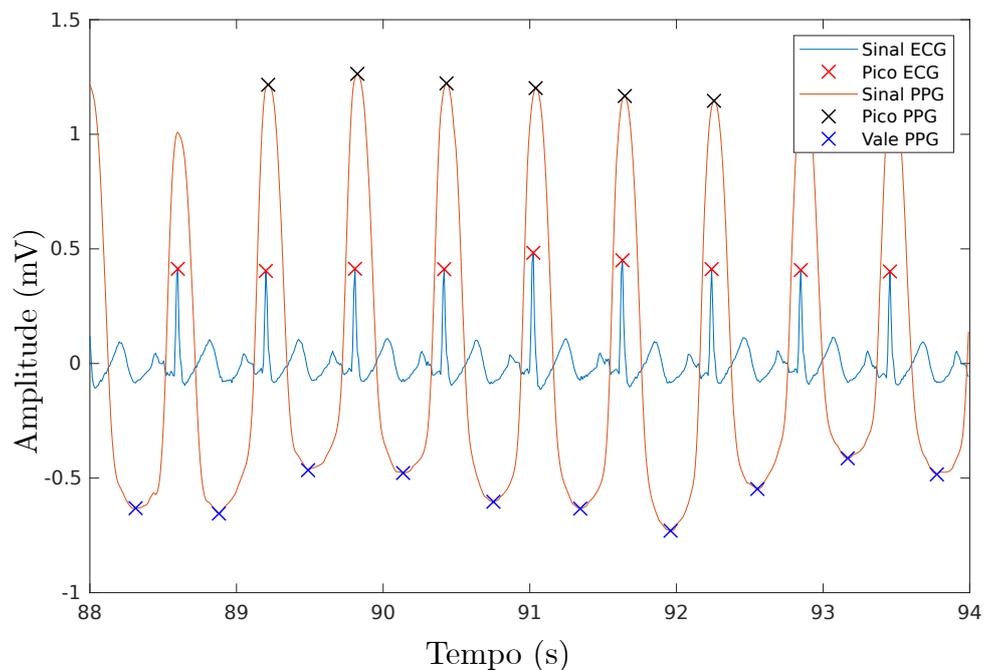


Figura 3.9. Sinal de ECG em azul e o sinal de PPG em vermelho. Observe que está faltando a marcação do segundo pico de PPG.

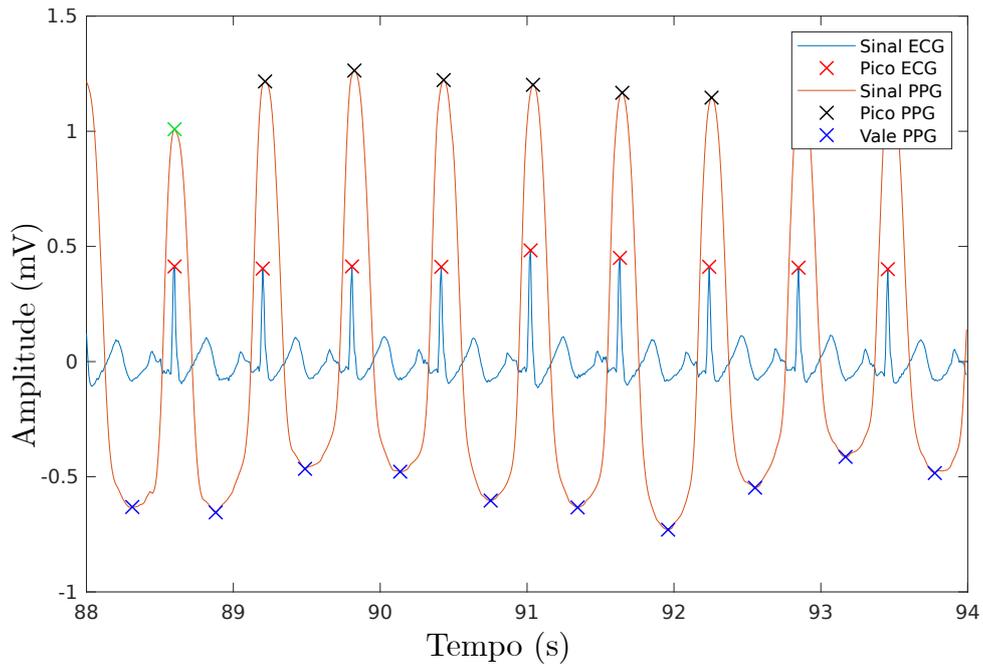


Figura 3.10. Sinal de ECG em azul e o sinal de PPG em vermelho. Observe que após a utilização do algoritmo de correção, foi adicionada uma marcação de um X verde no pico do sinal de PPG.

Inicialmente, foram extraídas 3 características temporais dos sinais de ECG e PPG. A primeira característica extraída foi o intervalo entre o pico da onda R do sinal de ECG e o pico do sinal de PPG, que foi nomeado de PTT_P . Na Figura 3.11 é mostrado mais detalhes da característica.

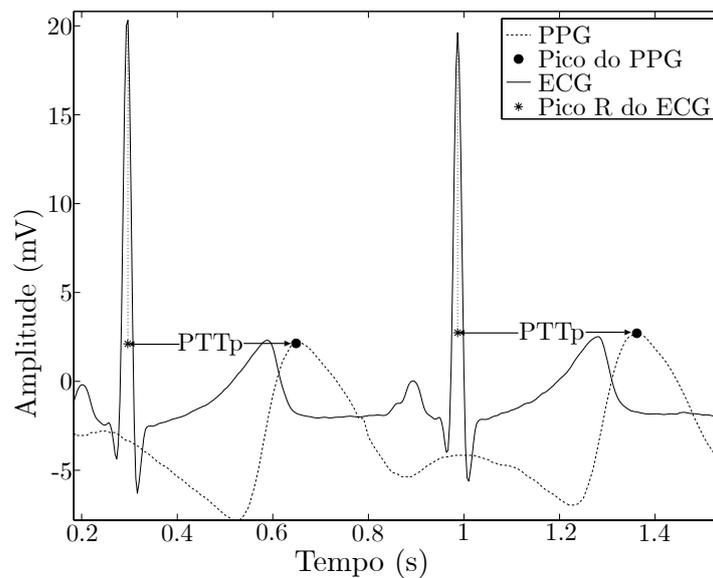


Figura 3.11. Sinal de ECG linha contínua e sinal de PPG linha tracejada. Note que está marcado o local da onda R do ECG e o pico do PPG, que corresponde ao intervalo PTT_P . Adaptado de [14].

O intervalo PTT_P é dada por

$$PTT_P = PPG_P - ECG_R, \quad (3.1)$$

em que PPG_P é o instante do ponto máximo no sinal de PPG, ECG_R e o instante da onda R no sinal de ECG.

Outra característica extraída foi o intervalo entre o pico da onda R do sinal de ECG e o vale do sinal de PPG, que foi nomeado de PTT_V . Na Figura 3.12 é mostrado mais detalhes da característica.

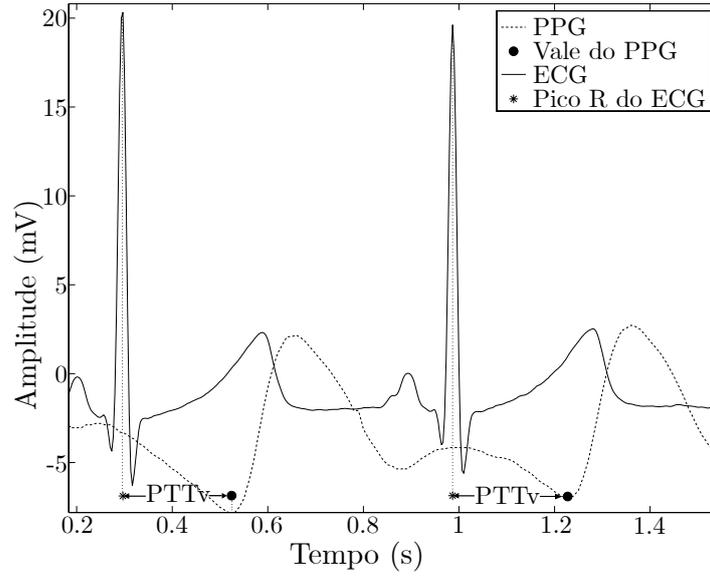


Figura 3.12. Sinal de ECG linha contínua e sinal de PPG linha tracejada. Note que está marcado o local da onda R do ECG e o vale do PPG, que corresponde ao intervalo PTT_V . Adaptado de [14].

O intervalo PTT_V é dada por

$$PTT_V = PPG_V - ECG_R, \quad (3.2)$$

em que PTT_V é o instante do ponto mínimo (vale) no sinal de PPG, ECG_R e o instante da onda R no sinal de ECG.

E por fim a terceira característica extraída foi o intervalo R-R. Na Figura 3.13 é mostrado mais detalhes da característica. Segundo Zhang, quando a FC aumenta ou diminui ocorre um aumento ou diminuição correspondente na PAD e PAS [53].

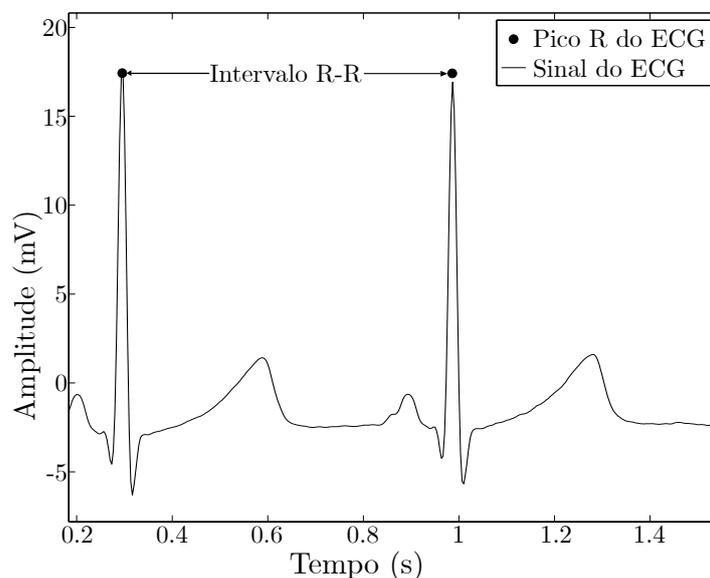


Figura 3.13. Sinal de ECG linha contínua. Note que estão marcados os locais da onda R do sinal de ECG, ou seja, o intervalo R-R do sinal de ECG. Adaptado de [14].

O intervalo RR é dada por

$$RR = ECG_{Rf} - ECG_{Ri}, \quad (3.3)$$

em que ECG_{Ri} é a localização da primeira onda R do sinal de ECG, ECG_{Rf} é a localização da próxima onda R do sinal de ECG.

3.3.2 Uso dos algoritmos de regressão para a estimação da PA

Para se obter o valores de PA é necessária a utilização de algoritmos que realizam uma regressão do sinal. Desta forma é possível obter o valor da PAD e da PAS. Neste contexto primeiro é realizada a extração das características dos sinais de ECG e PPG, na sequência é realizado o processo de treinamento do regressor e por último é realizado o teste.

3.3.3 Uso dos algoritmos de regressão para a estimação da PA e classificação indireta de pré-hipertensão

Para a classificação da faixa de pré-hipertensão que vai de $80mmHg$ até $90mmHg$ (a mesma que foi utilizada pelo artigo [21]), foram utilizados os seguintes algoritmos: SVR, Regressão com *Bagging Predictors*, Modelo de Regressão Linear, Modelo Linear de Regressão Generalizado, LSboost, Regressão por Árvore de Decisão e Regressão por *Stepwise Linear Model*. Na sequência foi realizada a classificação da faixa de pré-hipertensão.

3.3.4 Uso de algoritmos de classificação para diagnóstico direto da pré-hipertensão

Nas pesquisas realizadas durante o levantamento bibliográfico, foi observado que as classificações das faixas de PA foram realizadas a partir dos resultados dos regressores, no entanto, para uma comparação de desempenho foi realizada uma classificação direta, onde os sinais de ECG e PPG são classificados diretamente, sem passar pelo estágio de regressão. Esse processo pode melhorar os resultados de classificação, isso pelo fato de não haver dois estágios separados, ou seja, cada um podendo introduzir erros no processo de regressão ou classificação. Foi escolhido utilizar o classificador *Robust boosting*, por ser um classificador robusto e tem a vantagem de exigir menos dados para treinamento [13].

3.4 PROCEDIMENTOS EXPERIMENTAIS

Nos primeiros experimentos, foi escolhido o regressor SVR, a escolha desse método foi motivada pelo fator de ser uma abordagem muito utilizada na literatura científica.

No primeiro teste, foi selecionado um único registro, em que foi extraído apenas características temporais. Deste sinal uma parte foi utilizado para treinamento do algoritmo de regressão e o restante foi utilizado no processo de teste do regressor. Neste teste foi utilizado o SVR para realizar a regressão da PA.

No segundo teste, foi selecionado um grupo de 42 registros, em que foi extraído apenas características temporais, sendo que partes desses registros foram utilizados para o treinamento do algoritmo de regressão e o restante dos registros foram utilizados para o teste. Neste teste foi utilizado o SVR para realizar a regressão da PA.

No terceiro teste, foram extraídas novas características (5 bandas de energia) dos sinais de ECG e PPG de um único registro e acrescentar na matriz de característica temporais já existente. Esse novo teste se baseia no fato que pode haver um relação entre a PA e as bandas de energia do sinal de ECG, a teoria é que o sinal de ECG muda seu espectro de frequência quando a PA se altera. Neste teste foi utilizado o SVR para

realizar a regressão da PA.

No quarto teste, além das características temporais extraídas do grupo de 42 registro, foram extraídas características de bandas de energia, tanto do sinal de ECG quanto do sinal de PPG. Neste teste foi utilizado o SVR para realizar a regressão da PA.

No quinto teste, foi utilizado apenas as características temporais dos sinais de ECG e PPG, considerando os 42 registros, no entanto foi aplicado o processo de calibração, ou seja, parte de um sinal de um registro foi utilizado para treinamento e a outra parte foi utilizada para teste. Neste processo foram testados diferentes tipos de regressores, como por exemplo: SVR, Regressão com *Bagging Predictors*, Modelo de Regressão Linear, Modelo Linear de Regressão Generalizado, LSboost, Regressão por Árvore de Decisão e Regressão por *Stepwise Linear Model*.

No sexto teste, foi realizado a classificação da pré-hipertensão diretamente dos sinais de ECG e PPG, ou seja, sem passar pelos regressores. Neste teste foi utilizado o Robust boosting para realizar a classificação da pré-hipertensão.

Todo o processamento dos dados foram realizado com um notebook com processador Intel Core i7-770HQ 2.80GHz com 4 núcleos, 32GB de memória RAM DDR4 e com sistema operacional Linux Mint 19.3 x64, e foi utilizado o MatLab R2019a 64-bit STUDENT.

3.5 AVALIAÇÃO DE DESEMPENHO A PARTIR DAS ESTIMAÇÕES DA PA E DAS CLASSIFICAÇÕES DIRETA E INDIRETA DE PRÉ-HIPERTENSÃO

Para avaliação do algoritmo de regressão e do classificador, foi utilizada a estratégia denominada amostragem aleatória. Nessa estratégia, cada sessão de treinamento utiliza um subconjunto de dados selecionado aleatoriamente a partir do conjunto completo disponível, de forma que os dados de treinamento em uma sessão são distintos daqueles de outras sessões. O processo de amostragem inicialmente 100 vezes, sendo posteriormente repetido num total de 5000, 10000, 50000 e 100000 vezes, isso para garantir uma variância pequena. Em cada amostragem foi calculado os verdadeiros positivos, verdadeiros negativos, falsos positivos, falsos negativos e no final foi feita uma média de todos os valores.

Para avaliação a eficiência do algoritmo de regressão para estimar a PA, foram utilizadas medições de desempenho, como: Desvio Padrão, do inglês *Standard Deviation* (STD) e Erro Absoluto Médio, do inglês *Mean Absolute Error* (MAE).

Para avaliação do classificador pela análise das medidas estatísticas de desempenho foram analisados os valores de verdadeiros positivos, verdadeiros negativos, falsos posi-

vos, falsos negativos, acurácia, precisão, sensibilidade e medida-F.

Segundo a Associação para o Avanço da Instrumentação Médica, do inglês *Association for the Advancement of Medical Instrumentation* (AAMI) a diferença entre a PAS, PAM e PAD da nova técnica e o método de referência, deve ser de no máximo $\pm 5\text{mmHg}$ para o MAE e com STD menor ou igual a 8mmHg [1].

4 RESULTADOS

4.1 REGRESSÃO E AVALIAÇÃO PARA ESTIMAR A PA

4.1.1 Teste com calibração realizado com 1 registro

No primeiro teste foi utilizado o registro 3052346_0698 do banco de dados. Na Tabela 4.1 são mostrados os erros STD para a estimação da PAD utilizando SVR. Na Tabela 4.2 são mostrados os erros MAE para a estimação da PAD utilizando SVR. Foram realizados testes com diferentes porcentagem de dados utilizados para treinamento (60%, 70%, 80%, 90% e 95%). Para cada grupo de treinamento foi realizada a reamostragem aleatória com seções de 100, 5000, 10000, 50000 e 100000 vezes.

Tabela 4.1. Avaliação de desempenho do regressor SVR para estimar a PAD, em que são analisados os erros de STD. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG.

Seções	60%	70%	80%	90%	95%
100	1.58	1.61	1.61	1.52	1.51
5000	1.62	1.60	1.58	1.55	1.51
10000	1.61	1.60	1.59	1.55	1.52
50000	1.61	1.60	1.59	1.55	1.51
100000	1.61	1.60	1.58	1.55	1.51

Tabela 4.2. Avaliação de desempenho do regressor SVR para estimar a PAD, em que são analisados os erros de MAE. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG.

Seções	60%	70%	80%	90%	95%
100	1.33	1.38	1.38	1.31	1.34
5000	1.37	1.36	1.35	1.35	1.34
10000	1.37	1.36	1.36	1.35	1.36
50000	1.37	1.36	1.36	1.35	1.35
100000	1.37	1.36	1.36	1.35	1.34

Na Figura 4.1, são mostrados os histogramas dos erros STD, para estimar a PAD.

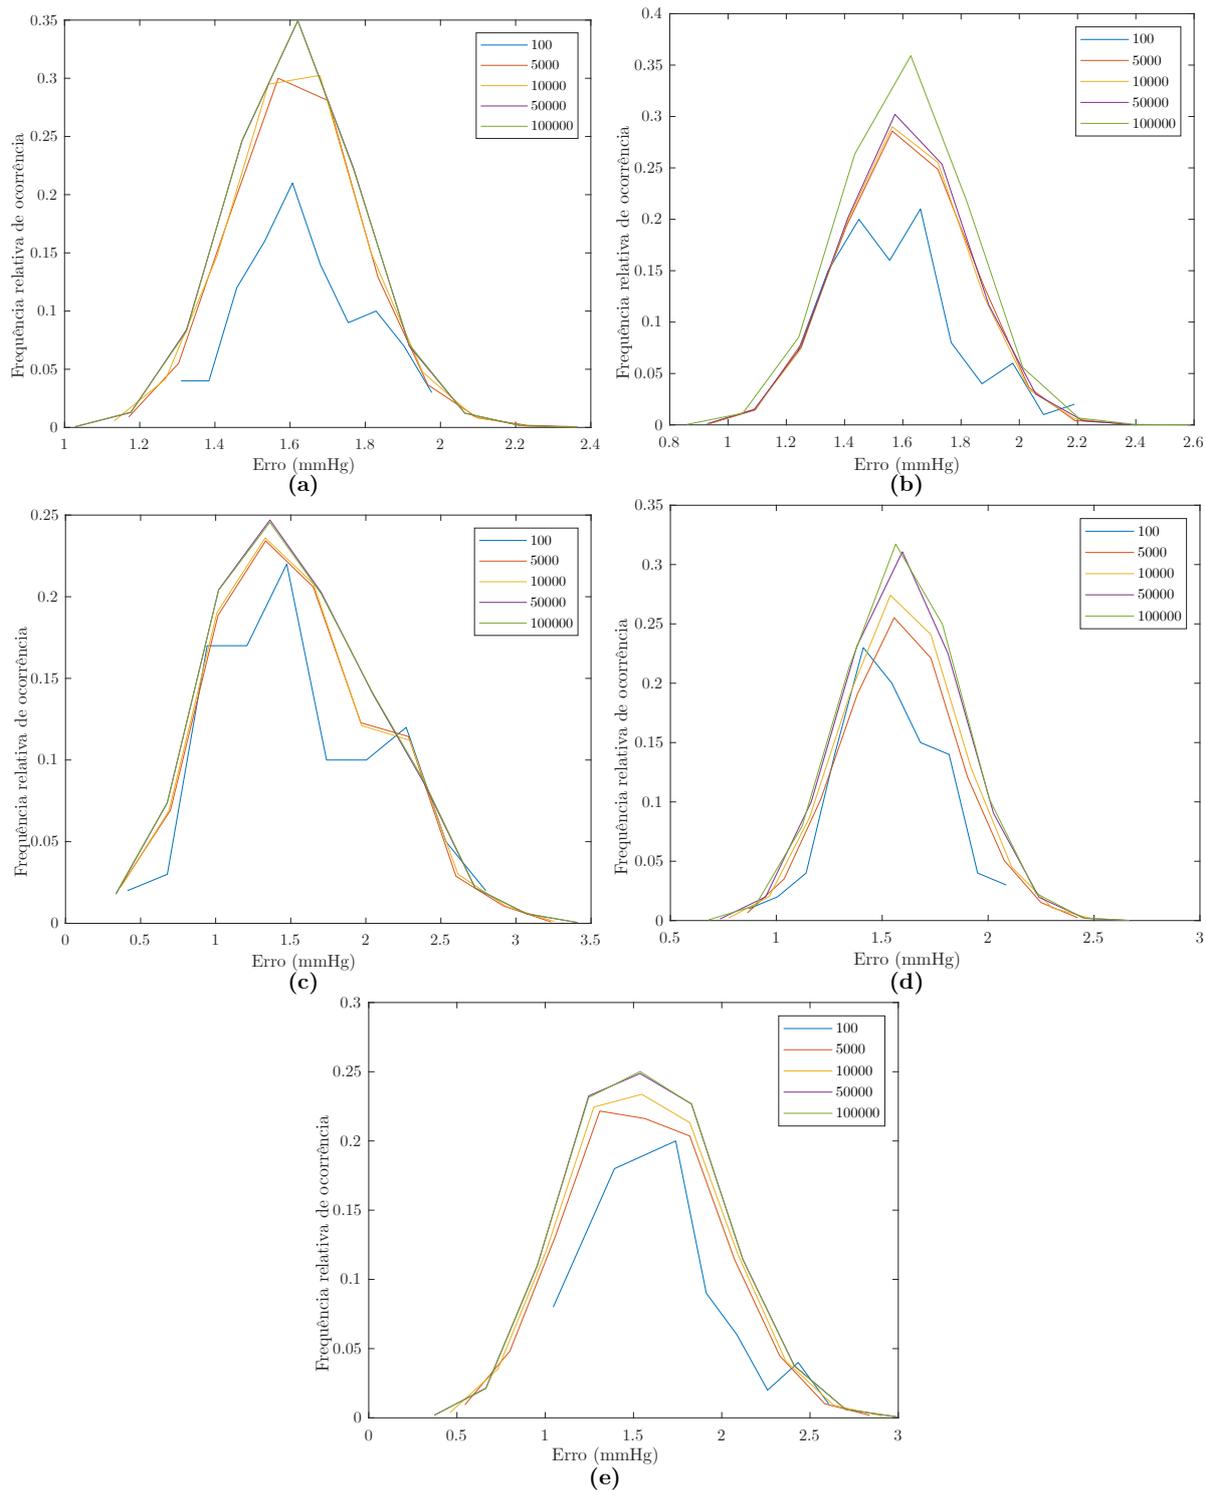


Figura 4.1. Histograma mostrando o erro STD para estimar a PAD com cada porcentagem utilizada para treinamento (a) - 60%, (b) - 70%, (c) - 80%, (d) - 90% e (e) - 95%) e com a quantidade de seções de treinamento realizadas (100, 5000, 10000, 50000 e 100000).

Na Tabela 4.3 são mostrados os resultados do erro STD para a estimação da PAS utilizando SVR, e na Tabela 4.4 são mostrados os erros MAE para a estimação da PAS utilizando SVR. Foram realizados testes com diferentes porcentagem de dados utilizados para treinamento (60%, 70%, 80% 90% e 95%). Para cada grupo de treinamento foi realizada a reamostragem aleatória com seções de 100, 5000, 10000, 50000 e 100000 vezes.

Tabela 4.3. Avaliação de desempenho do regressor SVR para estimar a PAS, em que são analisados os erros de STD. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG.

Seções	60%	70%	80%	90%	95%
100	4.86	4.77	4.70	4.59	4.48
5000	4.79	4.76	4.71	4.61	4.46
10000	4.79	4.75	4.70	4.60	4.45
50000	4.78	4.75	4.70	4.60	4.42
100000	4.79	4.75	4.70	4.60	4.42

Tabela 4.4. Avaliação de desempenho do regressor SVR para estimar a PAS, em que são analisados os erros de MAE. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG.

Seções	60%	70%	80%	90%	95%
100	4.02	4.01	3.98	3.97	3.97
5000	4.01	3.98	3.96	3.95	3.96
10000	3.98	3.96	3.96	3.93	3.95
50000	3.97	3.94	3.95	3.93	3.93
100000	3.96	3.94	3.93	3.92	3.92

Na Figura 4.2, são mostrados os histogramas dos erros STD, para estimar a PAS.

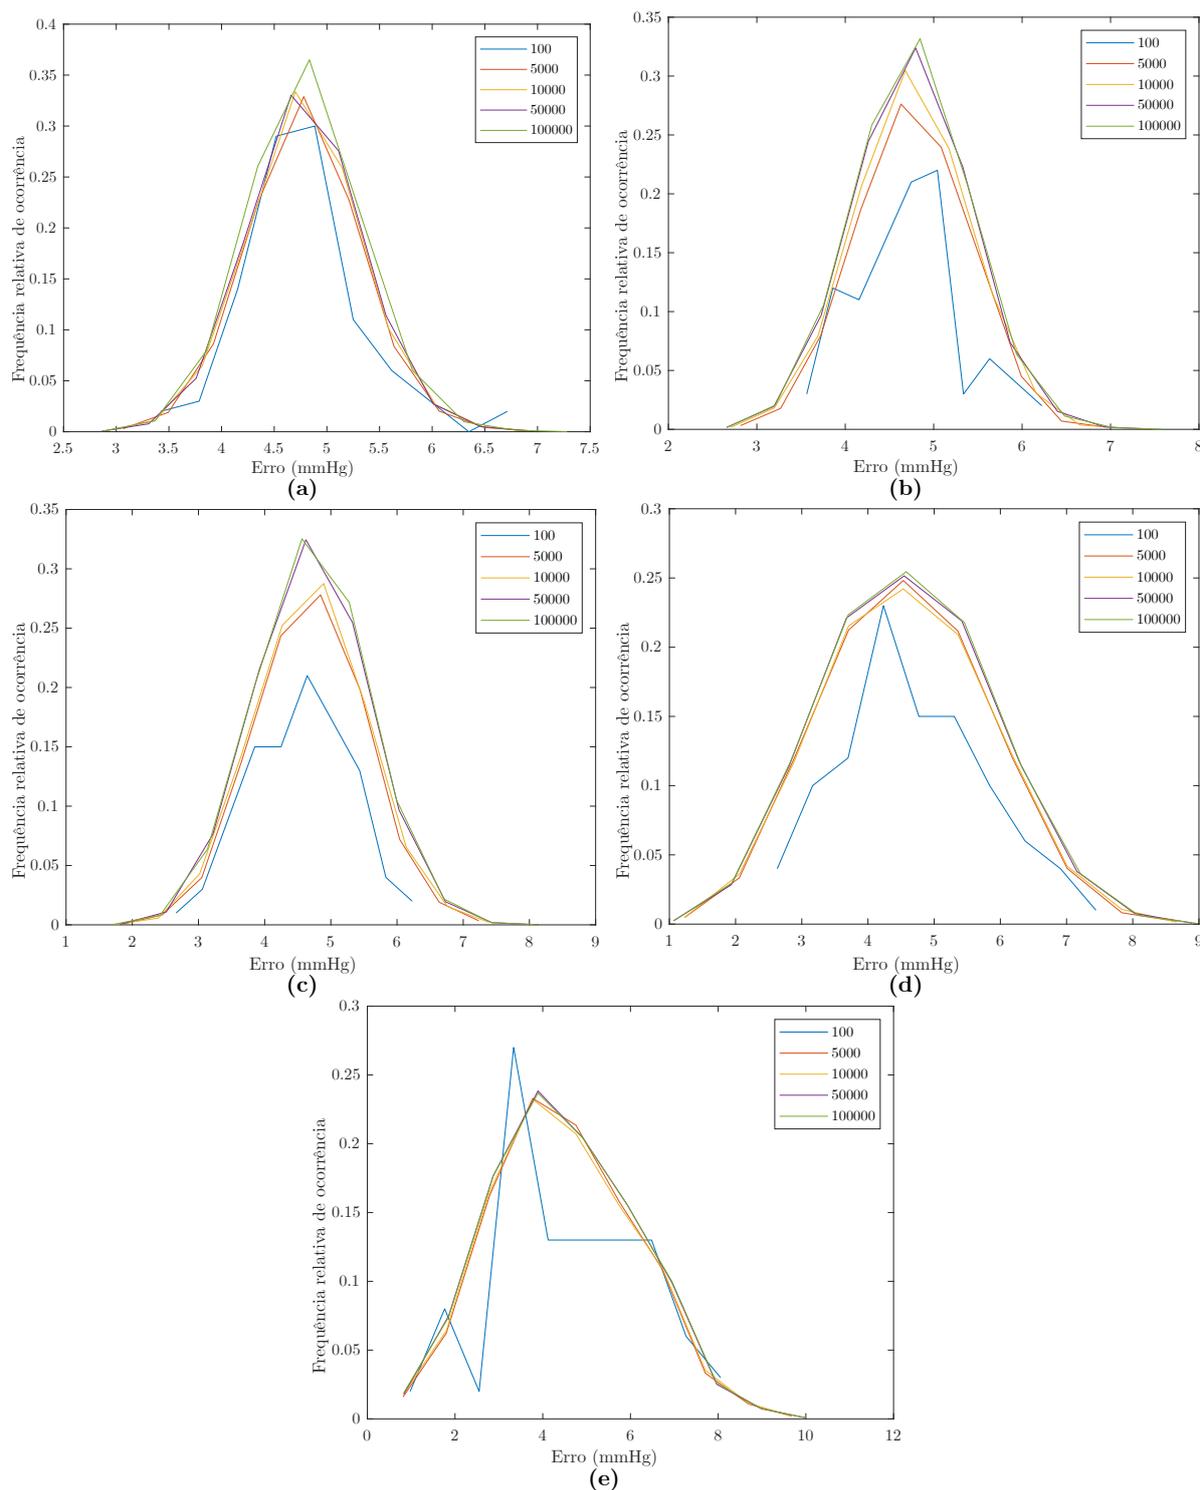


Figura 4.2. Histograma mostrando o erro STD para estimar a PAS com cada porcentagem utilizada para treinamento (a) - 60%, (b) - 70%, (c) - 80%, (d) - 90% e (e) - 95% e com a quantidade de seções de treinamento realizadas (100, 5000, 10000, 50000 e 100000).

Neste teste o resultado foi muito bom, no entanto, o algoritmo de regressão foi treinado com uma parte de um sinal e testado outra parte do mesmo sinal, desta forma,

já era esperado um desempenho bom. No próximo teste é realizado um teste com mais registros.

4.1.2 Teste sem calibração realizado com 42 registros

Na segunda parte dos ensaios, foram realizados testes com 42 registros de participantes selecionados anteriormente. Nesse processo, alguns registros foram utilizados para treinamento e o restante dos registros foram utilizados para teste, isso garantindo que os dados para teste nunca foram utilizados para treinamento. Nas Tabelas 4.5 e 4.6 é mostrado os erros MAE e STD para a PAD e a PAS.

Tabela 4.5. Avaliação de desempenho do regressor SVR para estimar a PAD, em que são analisados os erros de MAE e STD. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG. Foram realizados 5000 seções de treinamento e foram utilizados diferentes porcentagens dos dados para treinamento e teste.

Parâmetro de desempenho	60%	70%	80%	90%	95%
MAE (mmHg)	6.39	5.76	5.07	3.78	3.68
STD (mmHg)	4.95	5.51	4.97	3.95	3.85

Tabela 4.6. Avaliação de desempenho do regressor SVR para estimar a PAS, em que são analisados os erros de MAE e STD. Neste teste foram utilizadas apenas as características temporais entre o sinal de ECG e PPG. Foram realizados 5000 seções de treinamento e foram utilizados diferentes porcentagens dos dados para treinamento e teste.

Parâmetro de desempenho	60%	70%	80%	90%	95%
MAE (mmHg)	13.52	18.87	14.77	6.60	6.45
STD (mmHg)	13.41	15.64	17.97	5.66	5.36

Na Figura 4.3, são mostrados os histogramas de erros STD e MAE, tanto para a PAD quanto para a PAS. Nesse ensaio foi utilizado 60% dos dados para treinamento e 40% dos dados para teste.

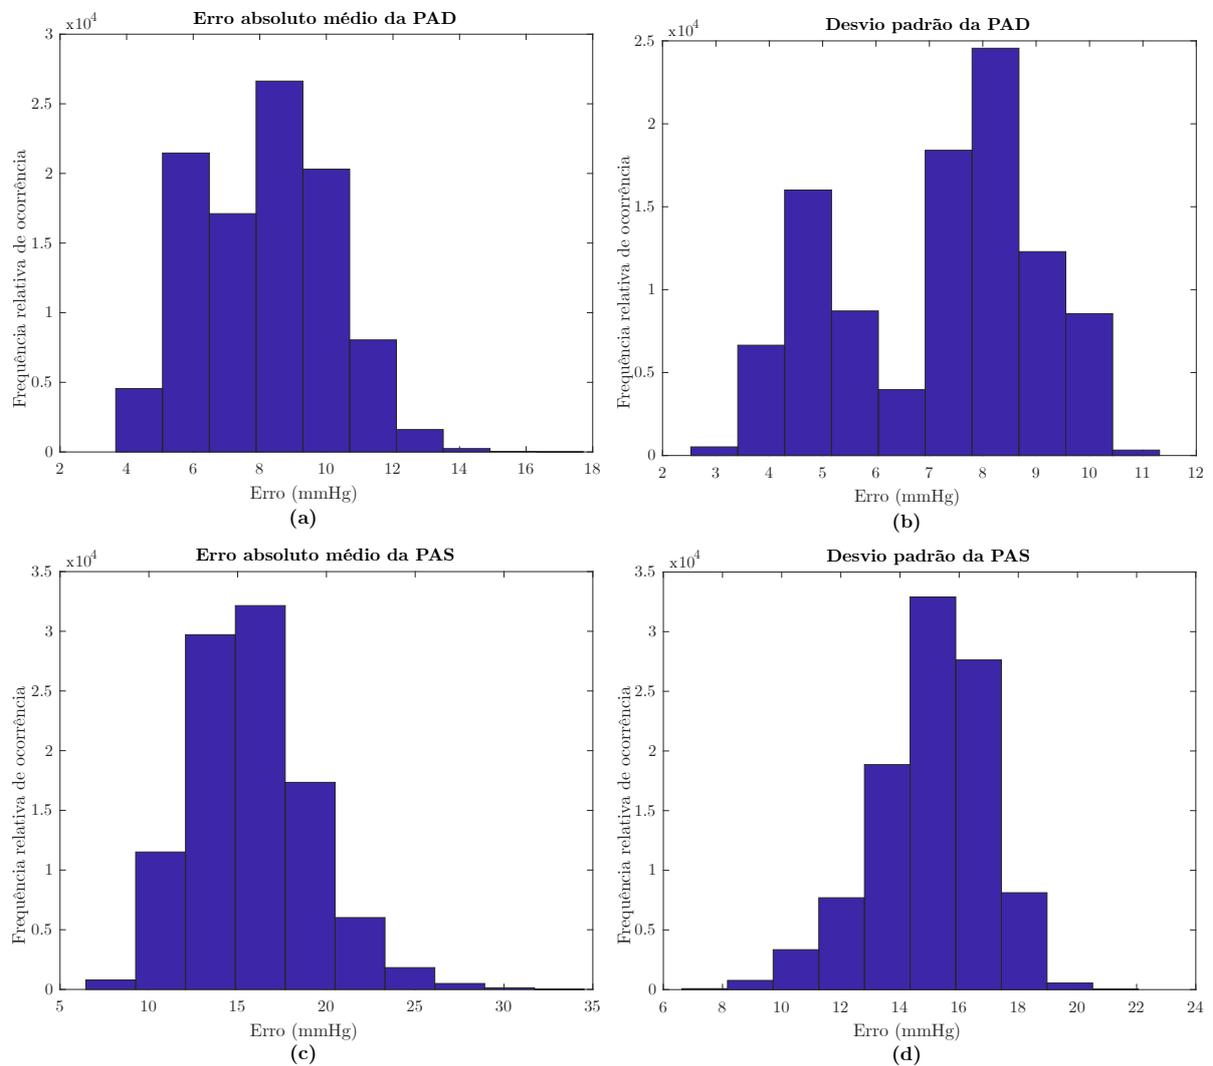


Figura 4.3. Histograma mostrando do STD e MAE com 60% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.

Na Figura 4.4, são mostrados os histogramas de erros STD e MAE, tanto para a PAD quanto para a PAS. Nesse ensaio foi utilizado 70% dos dados para treinamento e 30% dos dados para teste.

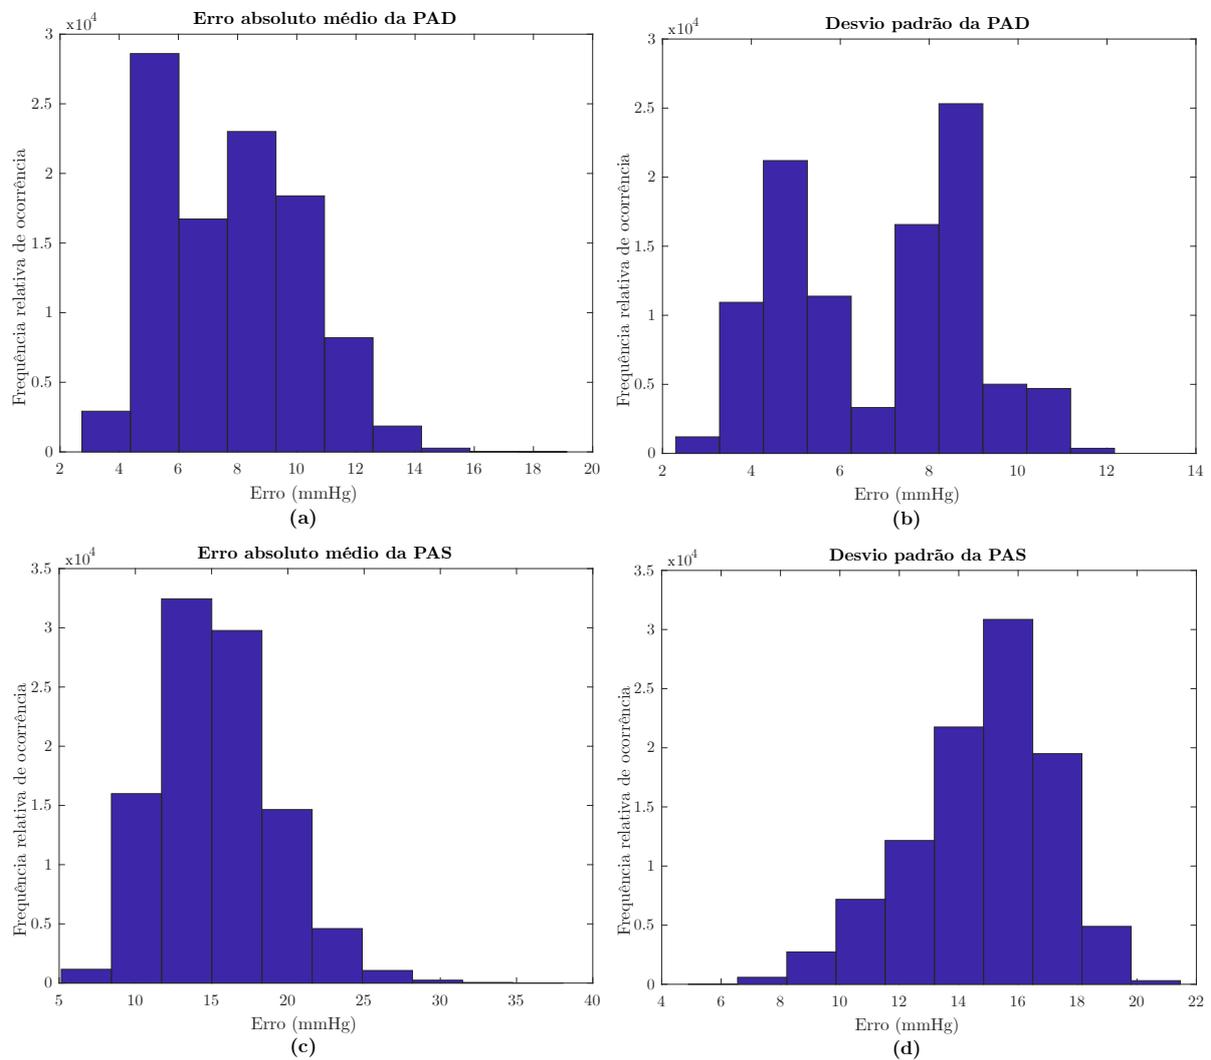


Figura 4.4. Histogramas do STD e MAE com 70% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.

Na Figura 4.5, são mostrados os histogramas de erros STD e MAE, tanto para a PAD quanto para a PAS. Nesse ensaio foi utilizado 80% dos dados para treinamento e 20% dos dados para teste.

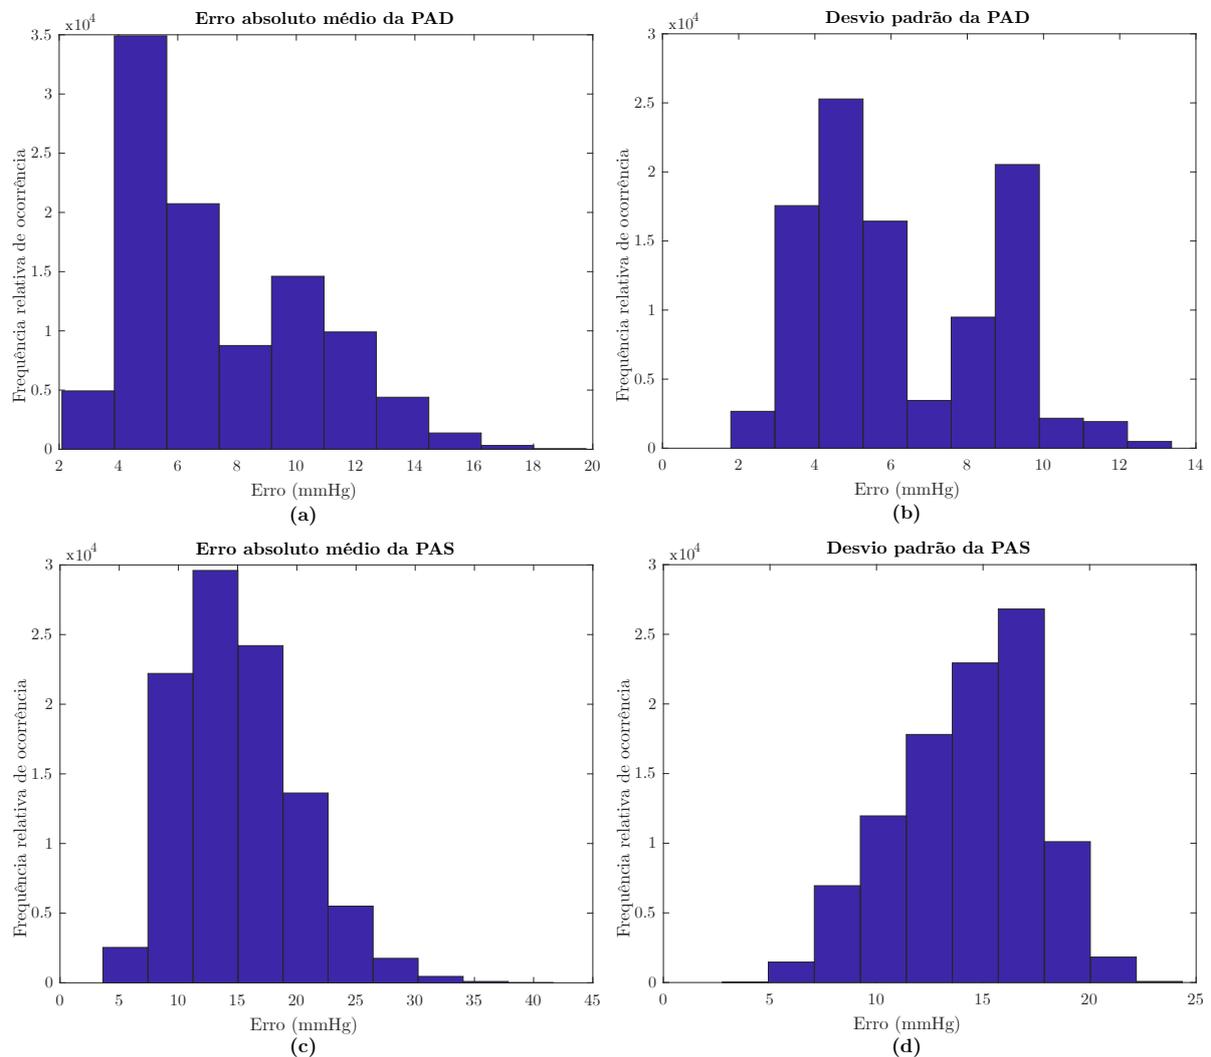


Figura 4.5. Histogramas do STD e MAE com 80% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.

Na Figura 4.6, são mostrados os histogramas de erros STD e MAE, tanto para a PAD quanto para a PAS. Nesse ensaio foi utilizado 90% dos dados para treinamento e 10% dos dados para teste.

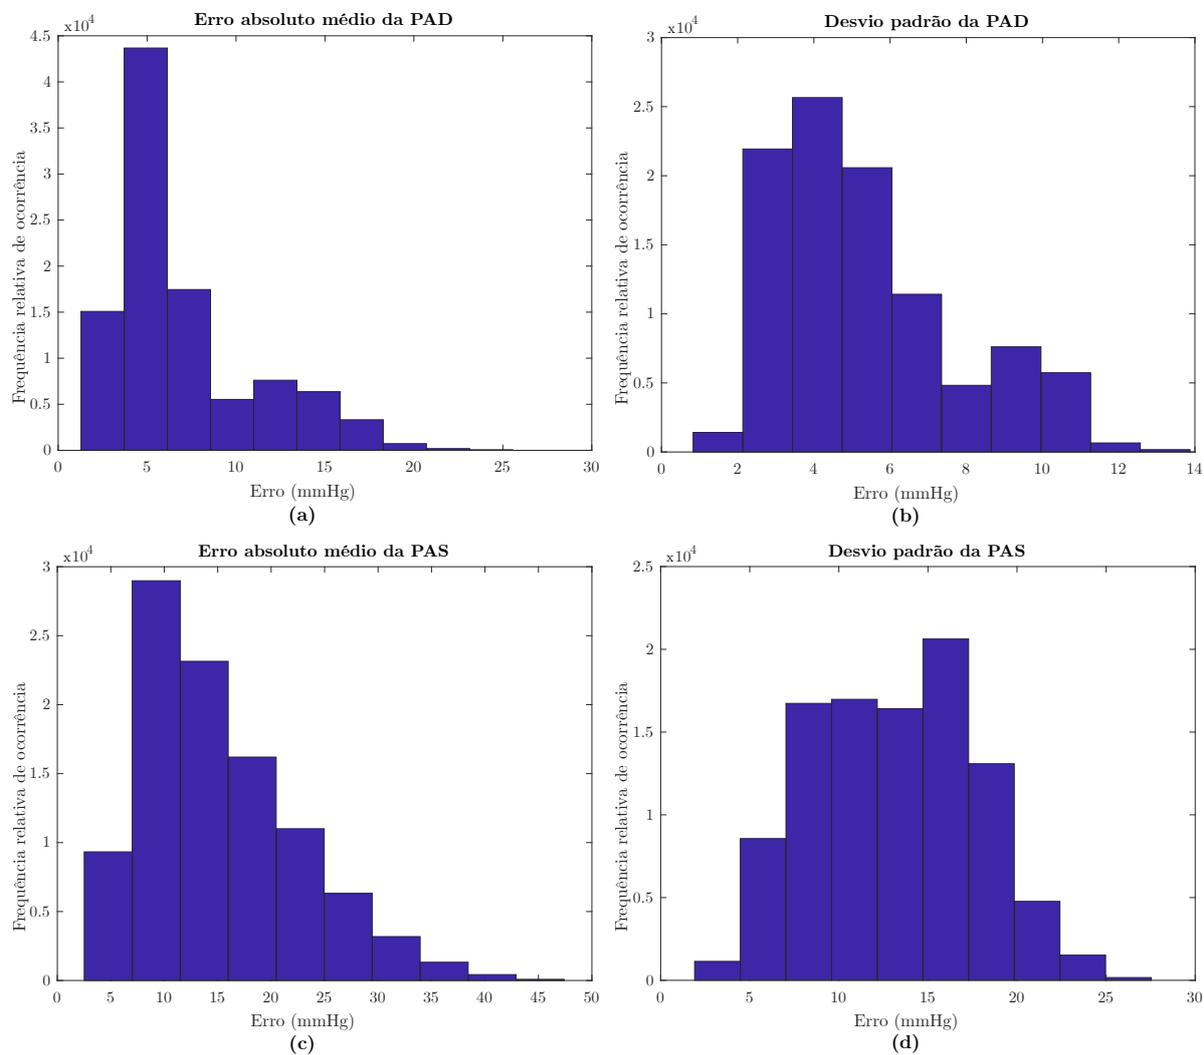


Figura 4.6. Histogramas do STD e MAE com 90% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.

Na Figura 4.7, são mostrados os histogramas de erros STD e MAE, tanto para a PAD e da PAS. Nesse ensaio foi utilizado 95% dos dados para treinamento e 5% dos dados para teste.

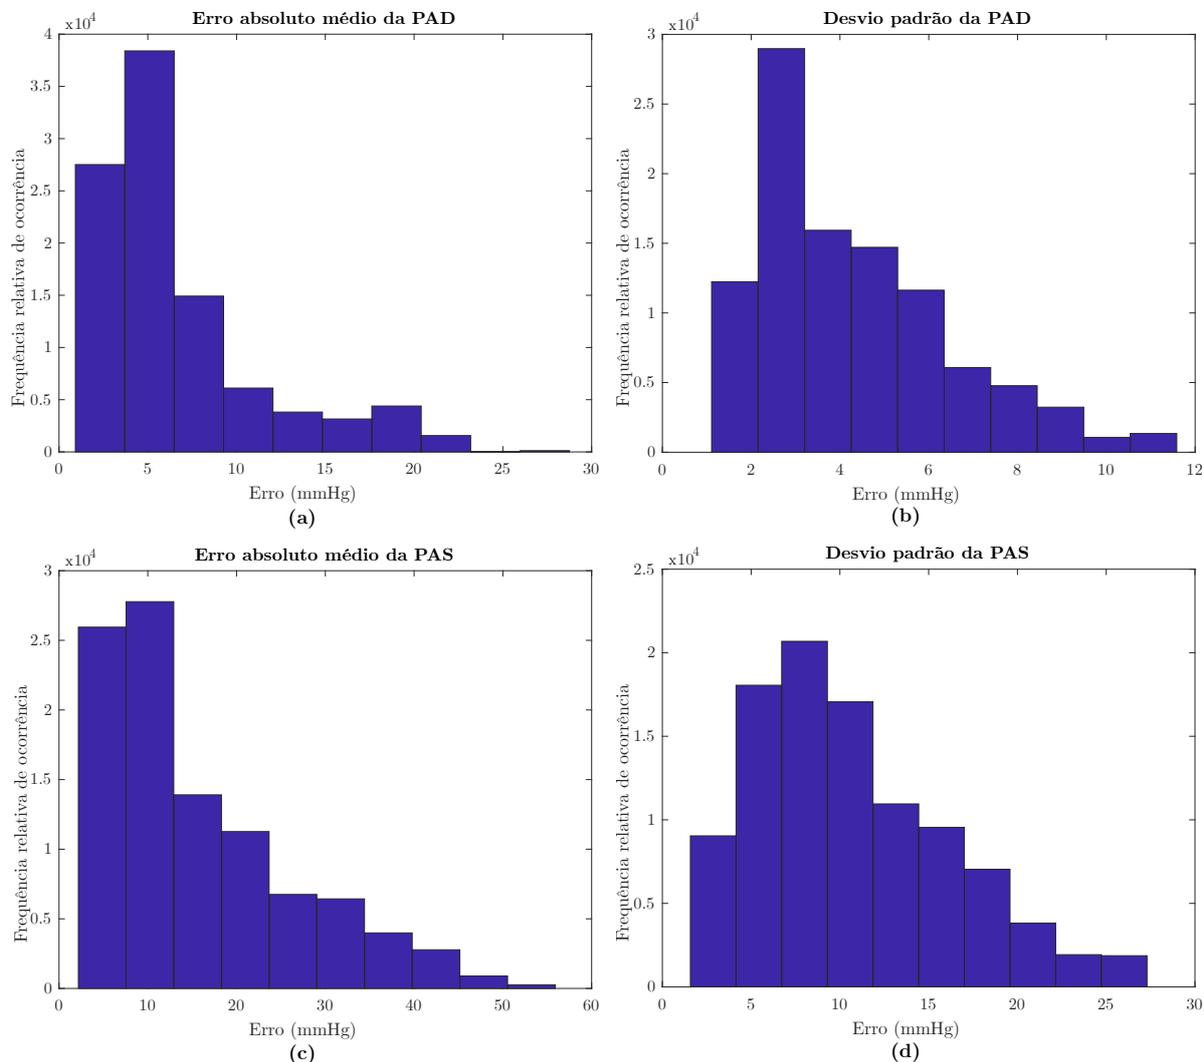


Figura 4.7. Histogramas do STD e MAE com 95% dos dados utilizado para treinamento. Em (a) é mostrado o MAE da PAD, (b) mostrando STD da PAD, (c) mostrando MAE da PAS e em (d) mostrando STD da PAS.

Neste teste o resultado piorou um pouco quando comparado com o primeiro teste, mas o erros da PAD ficou muito próximo do resultado do artigo [21], no entanto, a diferença de resultados da PAS foi de quase 50%. No próximo teste é utilizado características em bandas de energia que podem melhorar o desempenho do algoritmo de regressão.

4.1.3 Teste com calibração realizado com 1 registro e com a inclusão das bandas de energia

Em novos testes realizados com o registro 3052346_0698, foram incluídas as características de bandas de energia, ou seja, foram adicionado 5 bandas de energia do sinal de ECG e 5 bandas de energia do sinal de PPG. Pode-se observar que houve uma pequena melhora nos resultados. E a hipótese é que com mais essas características pode-se melhorar significativamente os resultados.

Na Tabela 4.7 são mostrados os resultados dos erros STD e MAE da PAD, neste teste foi realizado apenas 5000 seções de treinamento, pois como foi observado nos testes anteriores não houve grandes ganhos com números maiores.

Tabela 4.7. Avaliação de desempenho do regressor SVR para estimar a PAD, em que são analisados os erros de MAE e STD. Neste teste foram incluídas as características de bandas de energia. Foram realizadas 5000 seções de treinamento e foi utilizado 70% dos dados para treinamento e 30% dos dados para teste.

Parâmetro de desempenho	60%	70%	80%	90%	95%
STD (mmHg)	1.48	1.47	1.45	1.41	1.38
MAE (mmHg)	1.24	1.23	1.22	1.21	1.21

Na Figura 4.8 é mostrado o histograma dos testes realizado para estimar a PAD.

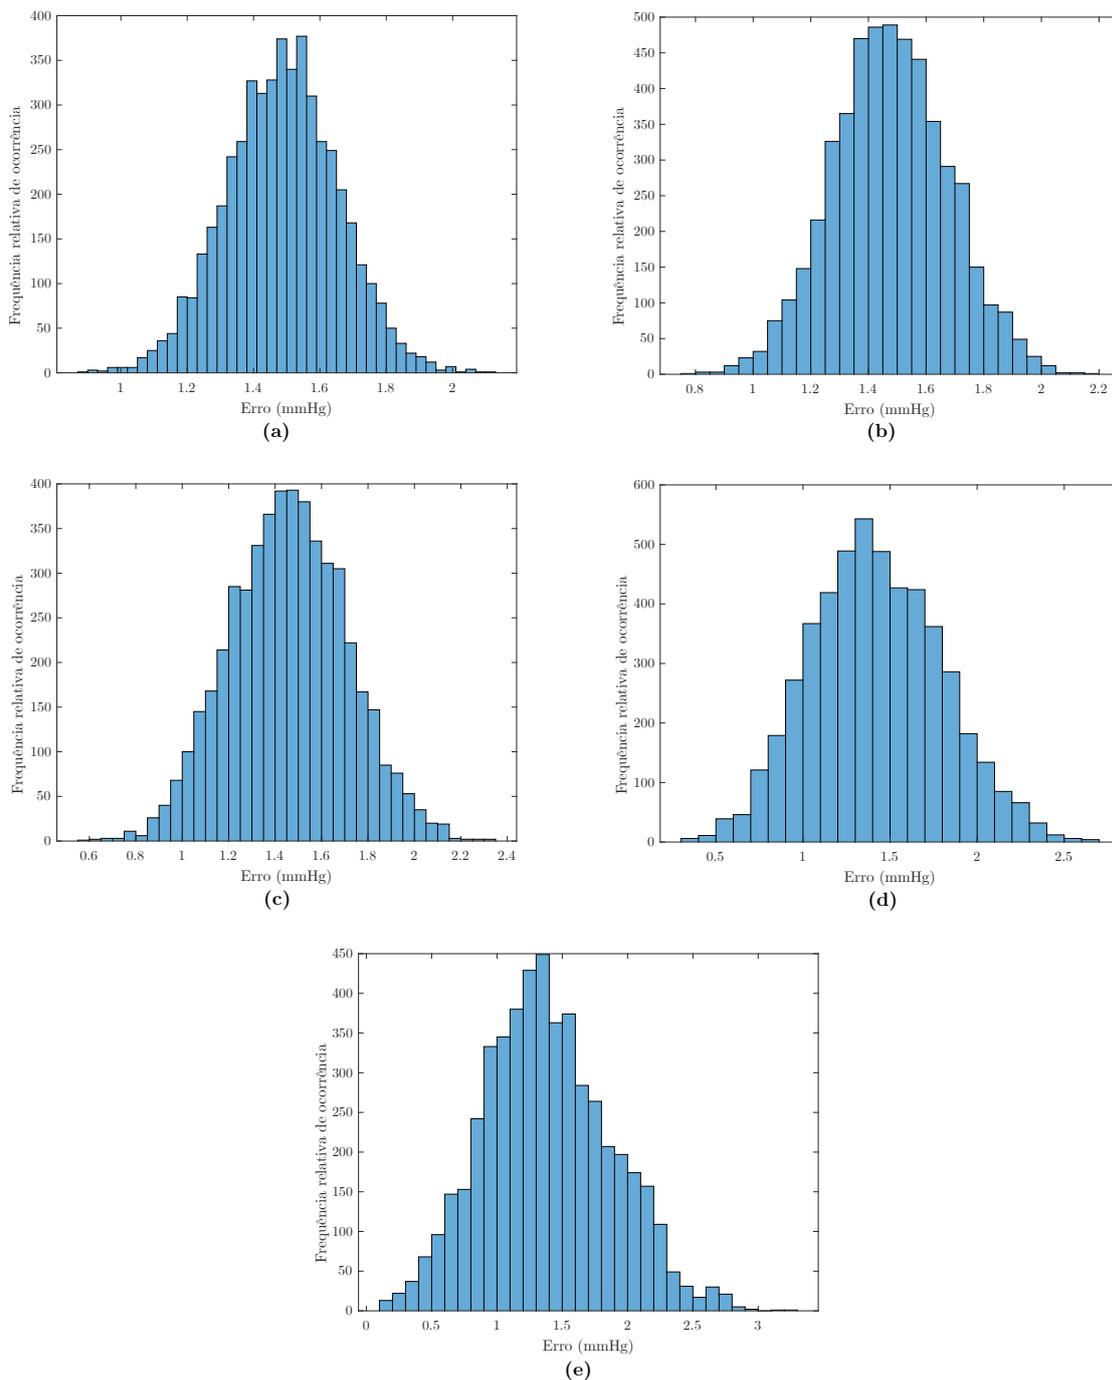


Figura 4.8. Histograma mostrando o erro STD para estimar a PAD. Onde é mostrado diferentes porcentagem de dados utilizados para treinamento (a) - 60%, (b) - 70%, (c) - 80%, (d) - 90% e (e) - 95% e em cada caso o restante dos dados foram utilizado para teste.

Na Tabela 4.8 são mostrados os resultados do erro STD e MAE da PAS, nesse teste foram realizadas apenas 5000 seções de treinamento.

Tabela 4.8. Avaliação de desempenho do regressor SVR para estimar a PAS, em que são analisados os erros de MAE e STD. Neste teste foram incluídas as características de bandas de energia. Foram realizadas 5000 seções de treinamento e foi utilizado 70% dos dados para treinamento e 30% dos dados para teste.

Parâmetro de desempenho	60%	70%	80%	90%	95%
STD (mmHg)	4.77	4.75	4.67	4.52	4.33
MAE (mmHg)	3.84	3.80	3.75	3.70	3.68

Na Figura 4.9 é mostrado o histograma dos testes realizado para estimar a PAS.

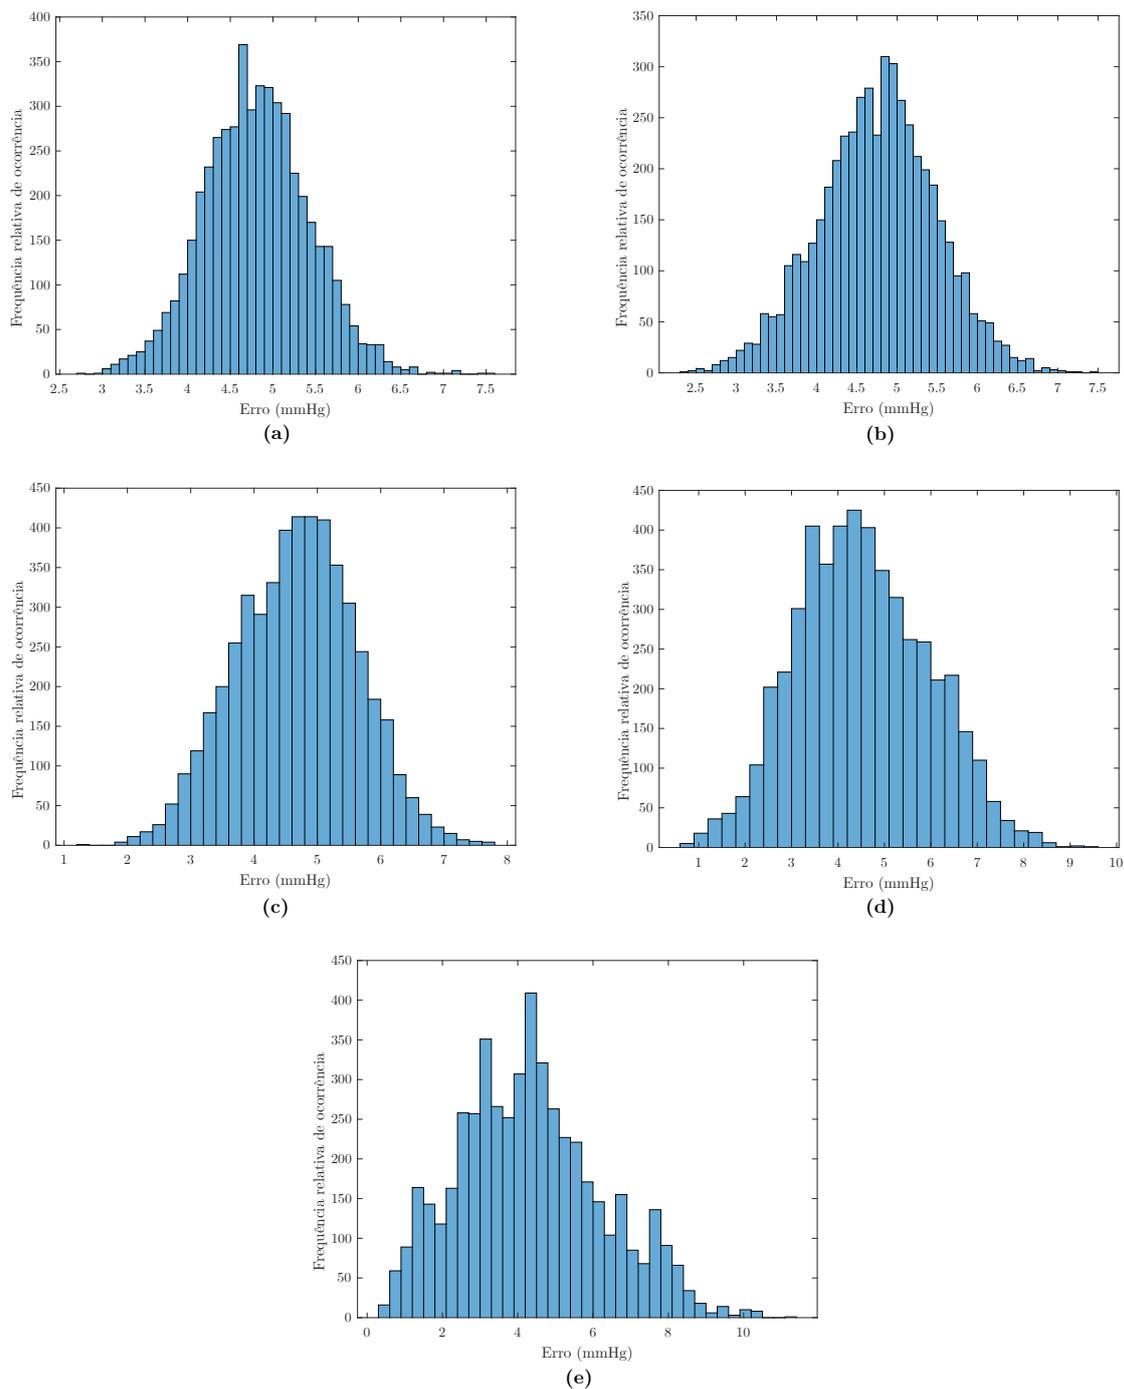


Figura 4.9. Histograma mostrando o erro STD para estimar a PAS. Onde é mostrado diferentes porcentagem de dados utilizados para treinamento (a) - 60%, (b) - 70%, (c) - 80%, (d) - 90% e (e) - 95% e em cada caso o restante dos dados foram utilizado para teste.

Neste teste o resultado de MAE e STD teve uma pequena melhora quando comparado com o primeiro teste. No entanto é necessário realiza testes com mais participantes para comprovar se realmente há uma melhora com o acréscimo das característica de bandas de energia. No próximo teste é utilizado características dos 42 registros.

4.1.4 Teste sem calibração realizado com 42 registros e com a inclusão das bandas de energia

Um novo teste, em que foram incluídas as características de bandas de energia nos 42 registros para estimar a PA. Na Tabela 4.9 é mostrado os erros para estimar a PAD e PAS.

Tabela 4.9. Avaliação de desempenho do regressor SVR para estimar a PA, em que são analisados os erros de MAE e STD, para as ambas pressões PAD e a PAS. Neste teste foram incluídas as características de bandas de energia. Foram realizadas 5000 seções de treinamento e foi utilizado 70% dos dados para treinamento e 30% dos dados para teste.

Algoritmo	PAD		PAS	
	STD (mmHg)	MAE (mmHg)	STD (mmHg)	MAE (mmHg)
Regressão por Vetores de Suporte (SVR)	9.77	16.57	17.00	16.75

Neste teste o resultado de MAE e STD pioraram significativamente tanto na PAD quanto na PAS, com esses resultados tem se um indicativo que o acréscimo das bandas de energia não ajudaram o regressor. Isso pode ser pelo fato que tenha pouco exemplos, e como houve um aumento na quantidade de característica o algoritmo não foi capaz de melhorar seu desempenho.

4.1.5 Teste com calibração realizado com 42 registros

Foi realizado um teste com os 42 registros com diferentes tipos de regressores, de forma que foi utilizada uma parte do sinal de um registro para treinamento e a outra parte do sinal foi utilizada para teste, mas lembrando não a mesma janela de tempo. Na Tabela 4.10 são mostrados os resultados de cada regressor.

Neste teste, com a inclusão do processo de calibração os resultados de MAE e STD melhoraram, o Regressão baseado em *Bagging Predictors* teve o melhor desempenho, ou seja, com um menor erro tanto na PAD quanto na PAS. No entanto para comprovar uma melhora significativa é necessário realizar experimentos com mais registros para observar se o desempenho se mantém consistente.

Tabela 4.10. Avaliação de desempenho de diferentes tipos de regressores para estimar a PA, em que são analisados os erros de MAE e STD, para as ambas pressões PAD e PAS. Os resultados são de testes que foram realizados com o processo de calibração. Em todos os casos foram realizadas 10 seções de treinamento e foram utilizados 70% dos dados para treinamento e 30% dos dados para teste.

Algoritmo	PAD		PAS	
	STD (mmHg)	MAE (mmHg)	STD (mmHg)	MAE (mmHg)
Regressão por Vetores de Suporte (SVR)	3.55	3.06	4.16	3.56
Regressão baseado em <i>Bagging Predictors</i>	2.72	2.21	3.24	2.63
Modelo de Regressão Linear	4.58	5.04	5.31	6.04
Modelo Linear de Regressão Generalizado	3.49	3.37	4.01	3.90
LSboost	2.96	2.40	3.38	2.86
Regressão por Árvore de Decisão	2.80	1.89	3.26	2.24
<i>Stepwise Linear Model</i>	4.41	4.61	5.13	5.26

4.1.6 Comparação e desempenhos entre os algoritmos

Na Tabela 4.11 é apresentado um resumo de todos os resultados observados até aqui, no final da tabela foi adicionado os resultados do artigo [21] que contém resultados com o sistema de calibração e sem o sistema calibração.

Tabela 4.11. Avaliação de desempenho de diferentes tipos de regressores para estimar a PA, em que são analisados os erros de MAE e STD, para as ambas pressões PAD e PAS. São apresentados testes que foram realizados com calibração e testes que foram realizados sem calibração, e no final são apresentados os dados do artigo [21]

Algoritmo	PAD		PAS	
	STD (mmHg)	MAE (mmHg)	STD (mmHg)	MAE (mmHg)
SVR - 3052346_0698 - Com Calibração (CC)	1.60	1.36	4.76	3.98
SVR - 42 registros - Sem Calibração (SC)	5.51	5.76	15.64	18.87
SVR - 3052346_0698 + Bandas de energia - CC	1.47	1.23	4.75	3.80
SVR - 42 registros + Bandas de energia - SC	9.77	16.57	17.00	16.75
SVR - 42 registros - CC	3.55	3.06	4.16	3.56
Regressão com <i>Bagging Predictors</i> - CC	2.72	2.21	3.24	2.63
Modelo de Regressão Linear - CC	4.58	5.04	5.31	6.04
Modelo Linear de Regressão Generalizado - CC	3.49	3.37	4.01	3.90
LSboost - CC	2.96	2.40	3.38	2.86
Regressão por Árvore de Decisão - CC	2.80	1.89	3.26	2.24
<i>Stepwise Linear Model</i> - CC	4.41	4.61	5.13	5.26
Artigo [21] - SC	6.14	5.35	10.09	11.17
Artigo [21] - CC	3.52	4.31	5.45	8.21

4.2 CLASSIFICAÇÃO E AVALIAÇÃO DO DIAGNÓSTICO DA PRÉ-HIPERTENSÃO

Para classificação da pré-hipertensão, foi utilizada a faixa de pressão que vai de 80mmHg até 90mmHg , como foi utilizada no trabalho [21]. Por motivos de comparação os testes foram realizados apenas com a PAD, pois tanto nesse trabalho quanto no trabalho [21] os resultados foram melhores.

4.2.1 Classificação da PA após a regressão

Nas Tabelas 4.12, 4.13, 4.14, 4.15, 4.16, 4.17 e 4.18, são mostrados os resultados da classificação na faixa de pré-hipertensão. Neste teste primeiramente foi realizada a regressão da PA e em seguida foi realizada a classificação.

Tabela 4.12. Avaliação de desempenho do classificador por *Stepwise Linear Model* para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.

Parâmetro de desempenho	Valor medido	Artigo [21]
STD (mmHg)	4.39	3.52
MAE (mmHg)	4.93	4.31
Acurácia	93%	91%
Sensibilidade	– ¹	– ²
Medida-F	– ¹	– ²
Precisão	– ¹	– ²

¹Não foi encontrado nenhum caso positivo.

²O Artigo [21], não forneceu os dados de sensibilidade, medida-F e precisão.

Tabela 4.13. Avaliação de desempenho do classificador por Regressão por Árvore de Decisão para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.

Parâmetro de desempenho	Valor medido	Artigo [21]
STD (mmHg)	2.54	3.52
MAE (mmHg)	1.84	4.31
Acurácia	99%	91%
Sensibilidade	– ¹	– ²
Medida-F	99%	– ²
Precisão	98%	– ²

¹Não foi encontrado nenhum caso positivo.

²O Artigo [21], não forneceu os dados de sensibilidade, medida-F e precisão.

Tabela 4.14. Avaliação de desempenho do classificador por *LSboost* para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.

Parâmetro de desempenho	Valor medido	Artigo [21]
STD (mmHg)	7.76	3.52
MAE (mmHg)	2.29	4.31
Acurácia	99%	91%
Sensibilidade	92%	– ¹
Medida-F	94%	– ¹
Precisão	98%	– ¹

¹O Artigo [21], não forneceu os dados de sensibilidade, medida-F e precisão.

Tabela 4.15. Avaliação de desempenho do classificador por Modelo Linear de Regressão Generalizado para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.

Parâmetro de desempenho	Valor medido	Artigo [21]
STD (mmHg)	3.25	3.52
MAE (mmHg)	3.25	4.31
Acurácia	94%	91%
Sensibilidade	65%	– ¹
Medida-F	77%	– ¹
Precisão	97%	– ¹

¹O Artigo [21], não forneceu os dados de sensibilidade, medida-F e precisão.

Tabela 4.16. Avaliação de desempenho do classificador por Modelo de Regressão Linear para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.

Parâmetro de desempenho	Valor medido	Artigo [21]
STD (mmHg)	4.50	3.52
MAE (mmHg)	4.95	4.31
Acurácia	93%	91%
Sensibilidade	– ¹	– ²
Medida-F	– ¹	– ²
Precisão	– ¹	– ²

¹Não foi encontrado nenhum caso positivo.

²O Artigo [21], não forneceu os dados de sensibilidade, medida-F e precisão.

Tabela 4.17. Avaliação de desempenho do classificador por Regressão Baseado em *Bagging Predictors* para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.

Parâmetro de desempenho	Valor medido	Artigo [21]
STD (mmHg)	2.56	3.52
MAE (mmHg)	2.22	4.31
Acurácia	99%	91%
Sensibilidade	93%	– ¹
Medida-F	95%	– ¹
Precisão	95%	– ¹

¹O Artigo [21], não forneceu os dados de sensibilidade, medida-F e precisão.

Tabela 4.18. Avaliação de desempenho do classificador por Regressão por Vetores de Suporte (SVR) para diagnóstico de pré-hipertensão ($80 < PA \leq 90$) na PAD. A classificação é realizada após o processo de regressão.

Parâmetro de desempenho	Valor medido	Artigo [21]
STD (mmHg)	3.50	3.52
MAE (mmHg)	3.08	4.31
Acurácia	99%	91%
Sensibilidade	85%	– ²
Medida-F	91%	– ²
Precisão	– ¹	– ²

¹Não foi encontrado nenhum caso positivo.

²O Artigo [21], não forneceu os dados de sensibilidade, medida-F e precisão.

Nestes testes os resultados da acurácia para a PAD mostram uma melhora significativa. No entanto, provavelmente os resultados foram melhores por existirem poucos sinais que se encontravam na faixa de pré-hipertensão ou de hipertensão. Desta forma é necessário realizar teste com mais sinais que contenham hipertensão diagnosticada.

4.2.2 Classificação direta da PA

Na Tabela 4.19 são mostrados os resultados da classificação direta, ou seja, a classificação da faixa de pré-hipertensão foi realizada diretamente das características extraídas dos sinais de ECG e PPG. Este teste foi realizado utilizando o classificador *Robust boosting* [13].

Diante dos resultados apresentados na Tabela 4.19, foi observado uma melhora quando comparado com os resultados do artigo [21]. Uma possibilidade da melhora dos resultados foi pelo fato de que a classificação foi feita diretamente nos sinais de ECG e PPG, sem passar pelo estágio de regressão. Mas é necessário investigar mais esse teste de uma forma sistemática, pois com esse indicativo de que a classificação possa melhorar, cabe avaliar

Tabela 4.19. Avaliação de desempenho do classificador *Robust boosting* para diagnóstico de pré-hipertensão com base nos sinais de ECG e PPG, realizando a classificação direta em comparação com o método de classificação indireto proposto por [21].

Algoritmo	PAD	Parâmetro de desempenho			
	Intervalo (mmHg)	Acurácia	Sensibilidade	Medida-F	Precisão
<i>Robust boosting</i>	$80 < PA \leq 90$	99%	94%	95%	96%
Artigo [21]	$80 < PA \leq 90$	91%	– ¹	– ¹	– ¹

¹O artigo [21] não informou os valores de sensibilidade, medida-F e a precisão.

detalhadamente outros classificadores e em novos sinais de exemplos e assim verificar se os resultados são consistentes com essas diversas situações.

4.3 CONTRIBUIÇÕES DO TRABALHO

Durante a realização dos experimentos, com base nas propostas realizadas ao longo do trabalho, são listadas as seguintes contribuições desta dissertação em relação ao que foi encontrado na literatura científica levantada.

- Realizado a classificação de pré-hipertensão diretamente das características sem passar por um regressor. Nos trabalhos levantados na literatura científica observou-se que a classificação da hipertensão a partir dos sinais de ECG e PPG se baseia em um regressor para a estimação do valor de pressão, e a partir deste ponto compara-se o valor obtido por regressão com níveis de referência para a definição de pré-hipertensão. No entanto, acredita-se que essa abordagem possa limitar o desempenho final, enquanto há classificadores que podem ser explorados de forma direta aplicada aos sinais de ECG e PPG. Desta forma este trabalho propôs avaliar a utilização de um classificador aplicado diretamente às características extraídas dos sinais de ECG e PPG para definir uma classe de pré-hipertensão sem a utilização prévia de um regressor. E pelo fato das características que são inerentemente desbalanceadas, ou seja, tem-se mais características de uma determinada faixa da PA do que outras faixas da PA [42].
- Os trabalhos que foram observados na literatura utilizam características temporais dos sinais tanto de ECG e PPG. No entanto, o fato é que se é possível estimar a PA a partir dos sinais de ECG e PPG, isso pode ser porque há alterações nas proporções de ondas mais rápidas e ondas mais lentas que compõem os dois sinais em questão. Com essa hipótese foi realizado teste utilizando características no domínio da frequência.

- Foi realizado um teste com características simplificadas, ou seja, foram utilizados conjuntos mais simples de características temporais dos sinais de ECG e PPG. Isso é motivado pelo fato de que algumas alterações das defasagens entre os sinais de ECG e PPG (para diferentes PAs) podem ser redundantes, de forma que o uso de características mais simples pode facilitar a generalização pelos regressores e classificadores. Foi observado que na literatura é utilizado um conjunto de característica temporais; não foi encontrada, no entanto, uma comparação sistemática entre os desempenhos obtidos com diferentes quantidades de características temporais.
- Outros experimentos que foram realizados, incluiu a avaliação do desempenho na situação em que o regressor é usado para estimar a PA a partir de sinais de usuários não usados no treinamento, ou seja, o regressor foi treinado com sinais de um participante e na sequência foi utilizado com sinais de outro participante para avaliar o desempenho do algoritmo, em um processo denominado avaliação livre de calibração. Um segundo teste que foi realizado diz respeito a estimar a PA a partir de um mesmo participante, ou seja, o regressor foi treinado com uma parte dos sinais de um participante e tentará estimar a PA com dados de outros segmentos de sinais do mesmo participante, em um procedimento denominado avaliação com calibração.
- Também foram realizados testes utilizando diferentes regressores, isso porque alguns regressores podem se comportar melhor com menos ou com mais características. Desta forma, os regressores utilizados na literatura podem não se comportar bem quando é alterada a quantidade de características. Por este motivo, foi realizada a comparação com vários regressores.

5 CONCLUSÃO

Essa pesquisa abordou o problema de se estimar a PA de forma não invasiva utilizando o PPG e ECG como principal fonte de informação. Durante o trabalho foram avaliadas diferentes estratégias, como por exemplo a de utilizar segmentos de dados de cada participante para treinamento e o restante dos sinais dos mesmos participantes para o teste dos regressores. Este método foi considerado como teste calibrado. Em outras avaliações foram utilizados diferentes participantes para o processo de treinamento e teste, de forma que o algoritmo deve avaliar pressões de indivíduos diferentes dos anteriormente analisados, em uma abordagem considerada sem calibração. Outro ponto testado foi a utilização de um classificador para classificar a pré-hipertensão diretamente dos sinais de ECG e PPG, sem passar pelo processo de regressão.

Nos resultados foi observado que a utilização de características em frequência não melhorou as estimativas de pressão. Uma possível explicação diz respeito ao número baixo de registros utilizados, e considerando um aumento significativo na quantidade de características, ou seja, foram adicionados mais 5 características do sinal de ECG e mais 5 características do sinal de PPG, desta forma pode ser que os algoritmos não consigam generalizar as classes de PA. Portanto em uma investigação futura cabe realiza mais testes com uma amostra maior de sinais. Por outro lado a classificação direta melhorou, e acredita-se que isso pode ser pelo fato da classificação ser realizada antes do processo de regressão. Em trabalhos futuros será interessante realizar novos experimentos, testando outras combinações de regressores e classificadores.

Nos resultados obtidos utilizando o SVR sem calibração, foram alcançados resultados em PAD com erro STD = 5.41 e MAE = 5.76, similares aos do artigo [21]; no entanto, os resultados em PAS foram piores, com erro STD = 15.64 e MAE = 18.87. Já nos resultados utilizando o SVR com calibração houve uma pequena melhora quando comparada com o artigo [21], os resultados foram os seguintes em PAD com erro STD = 3.55 e MAE = 3.06, já os resultados em PAS, com erro STD = 4.16 e MAE = 3.56, ou seja, similares aos do artigo [21]. Mas os melhores resultados obtidos na regressão foi utilizando o algoritmo de Regressão por Árvore de Decisão com calibração, onde se teve os seguintes resultados: PAD com erro STD = 2.80 e MAE = 1.89, já os resultados em PAS, com erro STD = 3.26 e MAE = 2.24.

Já nos testes de classificação direta, utilizando o classificador *Robust boosting*, o classificador teve um desempenho muito bom, com uma acurácia de 99%, sensibilidade de 94%, medida-F de 95% e uma precisão de 96%. Estes resultados de classificação superam os encontrados na literatura. Isso se deve ao fato que o algoritmo *Robust boosting* é utilizado em situações onde se tem conjunto de características desbalanceadas, ou seja, onde se tem uma diferença no número entre classes. Nesse estudo foi observado que se tem um número maior de dados nas classe de PA normal e um número menor de dados nas classes com pre-hipertensão ou hipertensão.

Uma outra características que pode ajudar no processo de regressão. É a amplitude e a duração do complexo QRS do sinal de ECG. Esses dois parâmetros podem estar relacionados com a força que o coração exerce para criar a onda de pressão.

Assim, pode-se verificar que houve uma melhora significativa ao utilizar a Regressão por Árvore de Decisão com calibração. Em trabalhos futuros será interessante realizar novos testes sem o processo de calibração, para ver se o desempenho se mantém consistente.

LISTA DE REFERÊNCIAS

- [1] ANSI/AAMI SP10:2002/(R)2008. *American National Standard for Manual, electronic, or automated sphygmomanometers*, 2008.
- [2] A. Auvinen, J. Bridges, k. Dawson, et al. Scientific committee on emerging and newly identified health risks scenihr mercury sphygmomanometers in healthcare and the feasibility of alternatives. *SCENIHR (Scientific Committee on Emerging and Newly Identified Health Risks)*, 2009.
- [3] K. E. Barrett, S. M. Barman, S. Boitano, e H. L. Brooks. *Ganong's Review of Medical Physiology*. The McGraw-Hill Companies, New York, NY, USA, 23 edição, 2010.
- [4] R. O. Bonow, D. L. Mann, D. P. Zipes, e P. Libby. *Braunwald Tratado de Doenças Cardiovasculares*. Elsevier, Rio de Janeiro, 9ª edição, 2013.
- [5] L. Breiman. Bagging Predictors. *Machine Learning*, 24(421):123–140, 1996.
- [6] L. Breiman. Random Forests. *Kluwer Academic Publishers*, (45):5–32, 2001.
- [7] M. Cerulli. O Método Oscilométrico de Medição da Pressão Arterial, 2000.
- [8] Sociedade Brasileira de Cardiologia. Departamento de hipertensão arterial. Disponível em <http://departamentos.cardiol.br/sbc-dha/>. Último acesso: 14/03/2020.
- [9] D. DeMers e D. Wachs. Physiology, Mean Arterial Pressure, 2019. Disponível em <http://www.ncbi.nlm.nih.gov/pubmed/30855814>. Último acesso: 14/03/2020.
- [10] M. W. Dib, R. Riera, e M. B. Ferraz. Estimated Annual Cost of Arterial Hypertension Treatment in Brazil. *Revista Panamericana de Salud Publica/Pan American Journal of Public Health*, 27(2):125–131, 2010.
- [11] X. R. Ding, N. Zhao, G. Z. Yang, et al. Continuous Blood Pressure Measurement From Invasive to Unobtrusive: Celebration of 200th Birth Anniversary of Carl Ludwig. *IEEE Journal of Biomedical and Health Informatics*, 20(6):1455–1465, 2016.

- [12] A. J. Dobson. *An Introduction to Generalized Linear Models*. New York: Chapman & Hall, 1990.
- [13] Y. Freund. A more robust boosting algorithm. *Computer Science and Engineering, UCSD*, 2009.
- [14] P. Fung, G. Dumont, C. Ries, et al. Continuous noninvasive blood pressure measurement by pulse transit time. *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, 26 I(4):738–741, 2004.
- [15] S. Ghosh, A. Banerjee, N. Ray, et al. Continuous Blood Pressure Prediction from Pulse Transit Time Using ECG and PPG Signals. *IEEE Circuits and Systems Magazine*, páginas 188–191, 2016.
- [16] B. A. Gould, R. S. Hornung, D. G. Altman, et al. Indirect measurement of blood pressure during exercise testing can be misleading. *British Heart Journal*, 53(January):611–615, 1985.
- [17] A. C. Guyton e J. E. Hall. *Tratado de Fisiologia Médica*. Elsevier Editora Ltda., Rio de Janeiro, 11 edição, 2006.
- [18] D. J. Hughes, L. A. Geddes, C. F. Babbs, e J. D. Bourland. Measurements of Young’s Modulus of the Canine Aorta In-Vivo with 10 MHz Ultrasound. *Biomedical Engineering Center*, páginas 326–326, 1978.
- [19] S. Irefin, R. H. Hoyt, S. J. Asirvatham, et al. The Heart Rhythm Society (HRS)/American Society of Anesthesiologists (ASA) Expert Consensus Statement on the Perioperative Management of Patients with Implantable Defibrillators, Pacemakers and Arrhythmia Monitors: Facilities and Patient Management. *Heart Rhythm*, 8(7):1114–1154, 2011.
- [20] P. H. Jones e W.M. Wang. Method of Measuring Blood Pressure With a Plethysmograph. United States Patent, 5.269.310, 1992.
- [21] M. Kachuee, M. M. Kiani, H. Mohammadzade, e M. Shabany. Cuffless Blood Pressure Estimation Algorithms for Continuous Health-Care Monitoring. *IEEE Transactions on Biomedical Engineering*, 64(4):859–869, 2017.
- [22] H. T. Ma. A blood pressure monitoring method for stroke management. *BioMed Research International*, 2014, 2014.
- [23] D. M. R. Martins. Verificação da pressão arterial em crianças: Condições e procedimentos. 14(2):179–183, 1980.

- [24] Mathworks. Fit linear regression model using stepwise regression. Disponível em <https://www.mathworks.com/help/stats/stepwiselm.html>. Último acesso: 10/03/2020.
- [25] Mathworks. Linear regression model. Disponível em <https://www.mathworks.com/help/stats/linearmodel.html>. Último acesso: 10/03/2020.
- [26] F. Miao, N. Fu, Y. T. Zhang, et al. A Novel Continuous Blood Pressure Estimation Approach Based on Data Mining Techniques. *IEEE Journal of Biomedical and Health Informatics*, 21(6):1730–1740, 2017.
- [27] Ministério da Saúde. Pesquisa Nacional de Saúde 2013. Percepção do estado de saúde estilos de vida e doenças crônicas, 2014.
- [28] R. Mukkamala, J. O. Hahn, O. T. Inan, et al. Toward Ubiquitous Blood Pressure Monitoring via Pulse Transit Time: Theory and Practice. *IEEE Transactions on Biomedical Engineering*, 62(8):1879–1901, 2015.
- [29] C. Nataraj, A. Jalali, e P. Ghorbanian. Application of Computational Intelligence Techniques for Cardiovascular Diagnostics. *Department of Mechanical Engineering, Villanova University, Villanova, Pennsylvania, USA*, 2012.
- [30] R. T. Netea, L. D. Elving, J. A. Lutterman, e T. H. Thien. Body position and blood pressure measurement in patients with diabetes mellitus. *Journal of Internal Medicine*, 251(5):393–399, 2002.
- [31] T. T. Netea, J. W. M. Lenders, P. Smits, e T. Thien. Both body and arm position significantly influence blood pressure measurement. *Journal of Human Hypertension*, 17(7):459–462, 2003.
- [32] G. Ogedegbe e T. Pickering. NIH Public Access. *Cardiol Clin.*, 28(4):571–586, 2010.
- [33] F. C. A. PAIM. Desenvolvimento de um sistema de telemetria para aquisição de sinais fisiológicos com aplicação em programas de reabilitação cardíaca. *Dissertação (Mestrado em Engenharia Elétrica) Universidade Federal de Santa Catarina*, page 137, 2005.
- [34] J. Pan e W. J. Tompkins. Real-Time QRS Detection Algorithm. *IEEE Transactions on Biomedical Engineering*, BME-32(3):230–236, 1985.
- [35] L. Peter, N. Noury, e M. Cerny. A review of methods for non-invasive and continuous blood pressure monitoring: Pulse transit time method is promising? *IRBM*, 35:271–282, 2014.

- [36] L. H. Peterson, A. B., R. D. Dripps, et al. A method for recording the arterial pressure pulse and blood pressure in man. *American Heart Journal*, 37:771–782, 1949.
- [37] Physionet. The mimic-iii waveform database. Disponível em <https://archive.physionet.org/physiobank/database/mimic3wdb/>. Último acesso: 13/03/2020.
- [38] M. A. S. Ribeiro, P. C. R. Garcia, e R. M. Fiori. Determinação da pressão arterial em recém-nascidos. *Scientia Medica*, 17(3):156–157, 2007.
- [39] Rnceus. Arterial blood pressure monitoring. Disponível em <http://www.rnceus.com/hemo/artline.htm>. Último acesso: 14/03/2020.
- [40] Dr. Saed Sayad. Decision tree - regression. Disponível em https://www.saedsayad.com/decision_tree_reg.htm. Último acesso: 07/03/2020.
- [41] Dr. Saed Sayad. Support vector machine - regression (svr). Disponível em https://www.saedsayad.com/support_vector_machine_reg.htm. Último acesso: 08/03/2020.
- [42] C. Seiffert, T. M. Khoshgoftaar, J. Van Hulse, e A. Napolitano. RUSBoost: A hybrid approach to alleviating class imbalance. *IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans*, 40(1):185–197, 2010.
- [43] P. A. Shaltis, A. T. Reisner, e H. H. Asada. Cuffless blood pressure monitoring using hydrostatic pressure changes. *IEEE Transactions on Biomedical Engineering*, 55(6):1775–1777, 2008.
- [44] K. H. Shelley. Photoplethysmography: Beyond the calculation of arterial oxygen saturation and heart rate. *Anesthesia and Analgesia*, 105(SUPPL. 6):13–18, 2007.
- [45] Sociedade Brasileira de Geriatria e Gerontologia. Pressão alta (hipertensão). Disponível em <http://www.sbgg-sp.com.br/pub/lexicon/pressao-alta-hipertensao/>. Último acesso: 14/03/2020.
- [46] R. W. Sun, W. Jia, Z. H. Mao, et al. HHS Public Access. *Int Conf Signal Process Proc*, páginas 115–118, 2015.
- [47] V. Vapnik, H. Drucker, C. J. C. Burges, et al. Support Vector Regression Machines. *Advances in Neural Information Processing Systems*, 28(7):779–784, 1996.
- [48] C. Wang. Ultrasonic device for blood pressure measurement. *University of California San Diego*, page 12, 2018.

- [49] G. Wang, M. Atef, e Y. Lian. Towards a Continuous Non-Invasive Cuffless Blood Pressure Monitoring System Using PPG: Systems and Circuits Review. *IEEE Circuits and Systems Magazine*, 18(3):6–26, 2018.
- [50] B. Williams, G. Mancia, W. Spiering, et al. *2018 ESC/ESH Guidelines for the management of arterial hypertension.*, volume 39. European Heart Journal, 2018.
- [51] World Health Organization. Raised blood pressure. Disponível em http://www.who.int/gho/ncd/risk_factors/blood_pressure_prevalence_text/en/. Último acesso: 12/03/2020.
- [52] S. H. Yoon, J. H. Jung, A. Y. Jeon, et al. Simulation of estimating the blood pressure using an arterial pressure-volume model. *2007 International Conference on Convergence Information Technology, ICCIT 2007*, páginas 2181–2186, 2007.
- [53] B. Zhang, Z. Wei, J. Ren, et al. An Empirical Study on Predicting Blood Pressure Using Classification and Regression Trees. *IEEE Access*, 6:21758–21768, 2018.