

Universidade de Brasília – UnB Campus Gama – FGA Engenharia Eletrônica

Estimação de pressão arterial Usando Fotopletismografia com ou sem Eletrocardiografia: Análise Comparativa em Diferentes Estratégias de Regressão e Classificação

VINÍCIUS FERREIRA RIBEIRO

Orientador: Dr. CRISTIANO JACQUES MIOSSO, PHD

UNB – UNIVERSIDADE DE BRASÍLIA FGA – FACULDADE GAMA ENGENHARIA ELETRÔNICA

Estimação de pressão arterial Usando Fotopletismografia com ou sem Eletrocardiografia: Análise Comparativa em Diferentes Estratégias de Regressão e Classificação

VINÍCIUS FERREIRA RIBEIRO

ORIENTADOR: CRISTIANO JACQUES MIOSSO, PHD

TRABALHO DE CONCLUSÃO DE CURSO ENGENHARIA ELETRÔNICA

BRASÍLIA/DF, MAIO DE 2021

UNB – UNIVERSIDADE DE BRASÍLIA FGA – FACULDADE GAMA ENGENHARIA ELETRÔNICA

Estimação de pressão arterial Usando Fotopletismografia com ou sem Eletrocardiografia: Análise Comparativa em Diferentes Estratégias de Regressão e Classificação

VINÍCIUS FERREIRA RIBEIRO

TRABALHO DE CONCLUSÃO DE CURSO SUBMETIDO À FACULDADE UNB GAMA DA Universidade de Brasília, como parte dos requisitos necessários para a obtenção do grau de bacharel em engenharia eletrônica

APROVADA POR:

Cristiano Jacques Miosso, PhD

(Orientador)

Filipe Emídio Tôrres, M Sc

Rodrigo Amaral, M Sc

FICHA CATALOGRÁFICA

Ribeiro, Vinicius Ferreira			
Estimação de pressão arterial Usando Fotopletismografia com ou sem Eletrocardiografia:			
Análise Comparativa em Diferentes Estraté	gias de Regressão e Classificação		
[Distrito Federal], 2021.			
60p., 210 \times 297 mm (FGA/UnB Gama, Bacharelado em Engenharia Eletrônica, 2020).			
Trabalho de Conclusão de Curso, Faculdade UnB Gama, Engenharia Eletrônica			
1. Estimação de Pressão Arterial 2. Eletrocardiografia			
3. Fotopletismografia4. Classificação de Sinais Biológicos			
I. FGA UnB/UnB. II. Título (série)			

Referência

RIBEIRO, VINICIUS FERREIRA (2021). Estimação de pressão arterial Usando Fotopletismografia com ou sem Eletrocardiografia: Análise Comparativa em Diferentes Estratégias de Regressão e Classificação. Trabalho de Conclusão de Curso, Engenharia Eletrônica, Faculdade UnB Gama, Universidade de Brasília, Brasília, DF, 60p.

CESSÃO DE DIREITOS

AUTOR: Vinícius Ferreira Ribeiro

TÍTULO: Estimação de pressão arterial Usando Fotopletismografia com ou sem Eletrocardiografia: Análise Comparativa em Diferentes Estratégias de Regressão e Classificação
GRAU: Bacharel em Engenharia Eletrônica
ANO: 2021

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

ribeirovinicius08@gmail.com Brasília, DF – Brasil

RESUMO

A oscilação da Pressão Arterial (PA), está associada a várias doenças, tanto para a pressão alta (HA - Hipertensão Arterial), e a pressão baixa (Hipotensão Arterial). De acordo com a Organização Mundial da Saúde (OMS), estima-se que cerca de 600 milhões de pessoas tenham HA, com estimativa de crescimento global de 60% de casos até 2025, além de cerca de 7,1 milhões de mortes anuais. Existem duas maneiras de aferir a PA, utilizando a medição invasiva e a medição não invasiva. O monitoramento da PA pelo metódo invasivo, é considerado o padrão ouro, realizado através da canulização de uma artéria com um cateter, porém pode causar complicações no paciente, atualmente o método mais usado para medição continua e não invasiva da PA é o Monitoramento Ambulatorial de Pressão Arterial (MAPA), que faz essa medição em intervalos constantes durante 24 horas, o que ainda faz com que haja a perda de eventos possivelmente importantes na variação da PA por possuir um intervalo de amostragem pequeno.

Um método muito pesquisado atualmente, utiliza a análise através do PTT (Pulse Transit Time), que é o tempo que a onda criada pela PA leva para propagar-se pelo sistema arterial. O PTT deriva do atraso referente a onda R do Eletrocardiograma (ECG) e a chegada dessa onda em um membro periférico, esse aferido pela Fotoplestimografia, do inglês *Photopletismography* (PPG), no entanto pode sofrer alterações relativas as posições dos sensores, a circunferência das artérias e a calibração dos equipamentos utilizados.

Com isso, este trabalho propõe avaliar técnicas recentes de regressão e classificação de sinais em comparação com estudos já realizados na literatura, utilizando somente o sinal de ECG, somente o sinal de PPG e utilizando ambos os sinais em conjunto, através da extração de características dos sinais e sem a extração de características.

Para obter a estimação da PA, foi realizada a seleção manual de trechos de sinais sem interrupção, para a utilização de uma base de dados maior. Após a seleção foi realizada a filtagem dos sinais para a retirada de ruídos existentes na sua obtenção. Foram extraídas características dos sinais de ECG (picos R), e do sinal de PPG (picos e vales, porcentagens da amplitude do sinal, e pico diastólico e sistólico, definidos de acordo com a literatura).

Para obter a classificação PA, as caracteristicas são inseridas em uma CNN (*Convolu*tional Neural Network) e em uma SVM (Support Vector Machine), sem a utilização e com a utilização de regressores, o mesmo processo é realizado sem as caracteristicas extraídas, utilizando os próprios sinais como entrada.

Na avaliação dos resultados obtidos neste trabalho, são utilizadas as métricas de F1 Score, Precisão e Acurácia, e para a comparação dos métodos já testados na literatura, são utilizados métricas encontradas nestes trabalhos, que são os erros relativo e absoluto. **Palavras-chave**: Estimação de Pressão Arterial. Fotopletismografia. Eletrocardiografia.

Sumário

1	Intr	oduçã	0	1
	1.1	Conte	xtualização	1
		1.1.1	A necessidade da avaliação contínua de Pressão Arterial	1
		1.1.2	A Evolução Histórica dos Métodos de Aferição de Pressão	2
		1.1.3	Recursos Atuais para Avaliação Contínua de Pressão	3
	1.2	Defini	ção do Problema Científico e Proposta de Pesquisa	4
	1.3	Objet	ivos	5
		1.3.1	Objetivo Geral	5
		1.3.2	Objetivos Específicos	5
	1.4	Estrut	cura do Trabalho	6
2	Fun	damer	ntação Teórica	7
	2.1	Fisiol	ogia do Ciclo Cardíaco	7
	2.2	Pressâ	to Arterial	8
	2.3	Aferiç	ão da Pressão Arterial	9
		2.3.1	Métodos invasivos de Aferição da Pressão Arterial	9
		2.3.2	Métodos não invasivos de aferição da Pressão Arterial	10
			Método auscultatório	10
			Método oscilométrico	11

		2.3.3	Eletrocardiograma	12
		2.3.4	Fotoplestimografia	14
	2.4	Regres	ssores e Classificadores	17
		2.4.1	RNA - Rede Neural Artificial	17
			Funções de Ativação	18
		2.4.2	SVM - Support Vectors Machine	18
		2.4.3	SVR - Support Vector Regression	19
		2.4.4	CNN - Convolutional Neural Network	19
		2.4.5	Robust boosting	21
	2.5	Parân	netros de Desempenho	22
		2.5.1	Tipos de Erros	22
		2.5.2	Acurácia e Precisão	22
		2.5.3	Desvio Padrão	23
		2.5.4	F1 Score	24
3	Mat	teriais	e Métodos	25
	3.1	Banco	de dados	26
		3.1.1	Filtragem de Sinais do Banco de Dados Pré-processado	28
	3.2	Filtrag	gem de Sinais	29
		3.2.1	Filtragem dos Sinais de Eletrocardiografia	29
		3.2.2	Filtragem dos Sinais de Fotopletismografia	31
	3.3	Caract	terísitcas dos Sinais	32
		3.3.1	Sinal de Eletrocardiografia	32
		3.3.2	Sinal de Fotopletismografia	32

	3.4	Processo de Janelamento	33
		3.4.1 PTT	34
	3.5	Estimação de Pressão Arterial	36
	3.6	Procedimento Experimental	37
	3.7	Avaliação de Desempenho	38
4	Res	ultados	39
	4.1	Regressão utilizando CNN	39
		4.1.1 Estimação de PA utilizando os sinais de PPG e ECG $\ .\ .\ .\ .$	39
		4.1.2 Classificação de PA utilizando CNN com os sinais de PPG e ECG	43
	4.2	Classificação de PA utilizando SVM e Robust boosting com os sinais de PPG e ECG	49
	4.3	Avaliação de Desempenho	50
		4.3.1 Regressão para Estimação da PA	50
		4.3.2 Classificação da PA	52

5 Conclusão

55

LISTA DE TABELAS

1.1	Classificação da PA em faixas definidas para adultos maiores de 18 anos, de acordo com critérios definidos por [35].	2
4.1	Regressão com CNN para estimação de PAD utilizando sinais de ECG e PPG em conjunto	39
4.2	Regressão com CNN para estimação de PAD utilizando sinais de ECG e PPG em conjunto, com normalização da entrada de dados para a CNN $$.	40
4.3	Regressão com CNN para estimação de PAD utilizando sinais de ECG e PPG em conjunto, com normalização da entrada de dados e dados alvo da CNN	40
4.4	Avaliação de desempenho de métodos de regressão utilizados neste traba- lho, em comparação com os resultados obtidos em trabalhos de referência	51
4.5	Classificação de PAS após regressão por CNN com sinais de um ciclo cardíaco, para pressão alta tendo PAS ≥ 130	52
4.6	Classificação de PAS após regressão por CNN aplicando o processo de <i>shift</i> nos sinais, para pressão alta tendo PAS ≥ 130	52
4.7	Classificação de PAD após regressão por CNN com sinais de um ciclo cardíaco, para pressão alta tendo PAD ≥ 80	52
4.8	Classificação de PAD após regressão por CNN aplicando o processo de <i>shift</i> nos sinais, para pressão alta tendo PAD ≥ 80	53
4.9	Classificação de PAD após regressão por CNN com sinais de um ciclo cardíaco, para pressão alta tendo PAD ≥ 60	53
4.10	Classificação de PAD após regressão por CNN aplicando o processo de shift nos sinais, para pressão alta tendo PAD ≥ 60	53

4.11	1 Avaliação de desempenho de classificação direta de pressão alta para PAD,	
	comparando com os resultados obtidos por $[3]$	54
4.12	Apresentação dos resultados obtidos e apresentad p a avaliação de desem-	
	penho de classificação direta de pressão alta para PAS	54

LISTA DE FIGURAS

1.1	Relação do sinal de ECG e PPG, onde é mostrado o pico da onda R e o pico do sinal de PPG, para obtenção do PTT e posteriormente do PWV. Adaptado de [3].	4
2.1	Eventos do lado esquerdo do coração durante ciclo cardíaco. Adaptado de [16]	7
2.2	Do lado esquerdo é mostrado o movimento de contração do ventrículo, que causa a ejeção do sangue do mesmo, no lado direito é mostrado o relaxa- mento ventricular, e o movimento de retração das artérias, que empurra o sangue para o sistema circulatório. Adaptado de [40]	8
2.3	Esquema de aferição de pressão arterial por método invasivo. Adaptado de [3]	10
2.4	Representação do método de medição de PA pelo método ausculatório, composto pelo manguito inflável, o manômetro e o estetocópio. Adaptado de [16]	11
2.5	Método oscilométrico. Adaptado de [21]	12
2.6	Exemplo de Eletrocardiograma com a identificação das ondas. Adaptado de [16]	13
2.7	Configuração das derivações de um eletrocardiograma. Adaptado de $[3].$.	14
2.8	Configuração de equipamento para a obtenção de sinal de pletismografia. Adaptado de [31]	15
2.9	Demonstração da obtenção do sinal de PPG, na parte superior da figura é mostrada a emissão da luz de LED passando pelos tecidos do corpo, enquanto que na parte inferior é apresentado sinal obtido, com a indicação dos componentes AC e DC. Adaptado de [6]	16

2.10	características do sinal de PPG. Adaptado de [41]	16
2.11	Representação da estrutura de uma RNA alimentada adiante. Adaptado de [15]	17
2.12	Representação de uma SVM com várias entradas, e apartir do treinamento realizado, é possível obter uma saída para os dados. Adaptado de [34]	19
2.13	Topologia de uma CNN. Adaptado de [18]	20
2.14	CNN - Convolução e <i>Pooling</i> . Adaptado de [18]	20
2.15	Exemplo de acurácia e precisão. Quanto mais próximos forem os valores dos dados obtidos ao valor real pretendido, maior a acurácia, enquanto que quanto maior a proximidade entre si dos valores obtidos dos dados, maior a precisão. Adaptado de [42].	23
3.1	Diagrama de blocos do processamento dos sinais da base de dados realizado por [3] a esquerda, e o diagrama de blocos realizado neste trabalho	25
3.2	Exemplo de trecho de sinal de ECG da base de dados [29], pré-processado e adquirido por [3]	27
3.3	Exemplo de sinal de PPG da base de dados [29], pré-processado e adquirido por [3]	28
3.4	Processo de filtragem do sinal de ECG: em (a) é apresentado o sinal bruto, em (b) no domínio da frequência, com a componente em 60Hz e 0Hz. Em (c) o sinal filtrado no domínio do tempo, e em (d) é observado que a componente em 60Hz é eliminada e a redução das componentes próximas a 0Hz. Adaptado de [3]	30
3.5	Processo de filtragem do sinal de PPG: em (a) é apresentado o sinal bruto, em (b) no domínio da frequência, com a componente em 0Hz. Em (c) o sinal filtrado no domínio do tempo, e em (d) é observado a redução das componentes próximas a 0Hz. Adaptado de [3]	31
3.6	Sinal de ECG com a identificação dos picos.	32
3.7	Sinal de PPG com a identificação de picos e vales	33

3.8	Sinal de PPG em verde, e sinal de ECG em vermelho. R peak, é o pico R do sinal de ECG, PPG Peak, o pico do sinal de PPG. A diferença entre esses picos é chamada de PTT. Adaptado de [17]	34
3.9	Sinal de PPG pontilhado, e sinal de ECG continuo. A diferença entre o pico do ECG e do vale do PPG é chamada de PTT_V . Adaptado de [3].	35
3.10	Exemplo de janelamento dos sinais de ECG e PPG, com o mesmo período de tempo, onde os sinais são sobrepostos para a realização da estimação da PA	36
4.1	Retorno da função MAE e sua validação com o terceiro cenário de teste, apresentado convergência para zero desde o princípio. \ldots \ldots \ldots \ldots	41
4.2	Retorno da função <i>loss</i> e sua validação com o terceiro cenário de teste, apresentado convergência para zero desde o princípio	41
4.3	Retorno da função <i>MAE</i> e sua validação com o terceiro cenário de teste, utilizando somente o sinal de PPG, apresentando uma variação muito grande entre os resultados obtidos, de MAE e sua validação	42
4.4	Retorno da função MAE e sua validação com o terceiro cenário de teste, utilizando somente o sinal de ECG, apresentando uma variação muito grande entre os resultados obtidos, de MAE e sua validação	43
4.5	Classificação de PAD utilizando CNN, para PAD considerada alta acima de 80mmHg, apresentando as curvas de acurácia do treino e de validação dos dados utilizados.	44
4.6	Função <i>loss</i> e sua respectiva validação para a classificação de PAD utilizando CNN, para PAD considerada alta acima de 80mmHg	44
4.7	Classificação de PAD utilizando CNN, para PAD considerada alta acima de 60mmHg, apresentando as curvas de acurácia do treino e de validação dos dados utilizados.	45
4.8	Função <i>loss</i> e sua respectiva validação para a classificação de PAD utilizando CNN, para PAD considerada alta acima de 60mmHg	46
4.9	Classificação de PAS utilizando CNN, para PAS considerada alta acima de 130mmHg, apresentando as curvas de acurácia do treino e de validação dos dados utilizados	17
	$uos uauos uuuzauos, \ldots \ldots$	41

4.10	Função $loss$ e sua respectiva validação para a classificação de PAS utili-	
	zando CNN, para PAS considerada alta acima de 130mm Hg $\ .\ .\ .\ .$	47
4.11	Classificação de PAS utilizando CNN, para PAS considerada alta acima de	
	130mmHg, com os sinais de PPG e ECG possuindo dois ciclos cardíacos,	
	apresentando as curvas de acurácia do treino e de validação dos dados	
	utilizados	48
4.12	Função loss e sua respectiva validação para a classificação de PAS utili-	
	zando CNN, para PAS considerada alta acima de 130mmHg com os sinais	
	de PPG e ECG possuindo dois ciclos cardíacos.	49

LISTA DE SÍMBOLOS, NOMENCLATURAS E ABREVIAÇÕES

AC	_	Alternating Current	
AVC	—	Acidente Vascular Cerebral	
CNN	—	Convolutional Neural Network	
DC	—	Direct Current	
ECG	_	Eletrocardiograma	
FIR	—	Finite Impulse Response	
HA	—	Hipertensão Arterial	
LED	—	Light Emitting Diode	
MAE	—	Mean Absolute Error	
MAPA	_	Monitorização Ambulatorial de Pressão Arterial	
MLP	—	Multi Layer Perceptron	
mV	—	miliVolts	
OMS	—	Organização Mundial da Saúde	
PA	_	Pressão Arterial	
PAD	_	Pressão Arterial Diastólica	
PAM	—	Pressão Arterial Média	
PAS	—	Pressão Arterial Sistólica	
PPG	—	Photoplethys mography	
PPI	—	Peak-to-Peak Interval	
\mathbf{PTT}	—	Pulse Transit Time	
PWV	- Pulse Wave Velocity		
ReLu	_	Rectified Linear Unit	
RNA	_	Rede Neural Artificial	
SVM	_	Support Vectors Machine	
SVR	_	Support Vector Regression	
UTI	_	Unidade de Terapia Intensiva	

ViGitel – Sistema de Vigilância de Doenças Crônicas por Inquérito Telefônico

1 Introdução

1.1 Contextualização

1.1.1 A necessidade da avaliação contínua de Pressão Arterial

A oscilação da Pressão Arterial (PA), está associada a várias doenças, tanto para a pressão alta (HA - Hipertensão Arterial), e a pressão baixa (Hipotensão Arterial), como por exemplo, derrame, infarto e Acidente Vascular Cerebral (AVC). Os casos de hipertensão em adultos no Brasil estão aumentando, de acordo com estudo do Sistema de Vigilância de Doenças Crônicas por Inquérito Telefônico (Vigitel), do Ministério da Saúde, houve um aumento de 14,2% nos diagnósticos de HA no Brasil nos últimos dez anos [26].

De acordo com a Organização Mundial da Saúde (OMS), estima-se que cerca de 600 milhões de pessoas tenham HA, com estimativa de crescimento global de 60% de casos até 2025, além de cerca de 7,1 milhões de mortes anuais [22].

A HA é caracterizada pela elevação constante da PA, apesar de não causar sintomas por um período de tempo, o que pode máscarar seus efeitos em curto tempo, levando a consequências graves quando não propriamente detectada e tratada [5]. Quando a PA é aferida, dois valores são registrados: Pressão Arterial Sistólica (PAS) e Pressão Arterial Diastólica (PAD) [5]. Os valores padrões para a PA, são classificados como ótima, normal, limitrofe e hipertenso, sendo apresentados na Tabela 1.1:

Classificação	PAS (mmHg)	PAD (mmHg)
Ótima	< 120	< 80
Normal	< 130	< 85
Limitrofe	130 - 139	85 - 89
Hipertensão Estágio 1	140 - 159	90 - 99
Hipertensão Estágio 2	160 - 179	100 - 109
Hipertensão Estágio 3	≥ 180	≥ 110
Hipertensão Sistólica Isolada	≥ 140	< 90

Tabela 1.1. Classificação da PA em faixas definidas para adultos maiores de 18 anos, de acordo com critérios definidos por [35].

A PA é um sinal vital que varia no decorrer do tempo, sendo afetada por vários fatores relacionados a rotina de uma pessoa, além da variação causada por mecanismos neuro-hormonais [39]. A PA é produto da pressão hidrostática que o sangue faz contra as paredes dos vasos sanguineos, que se move das áreas de alta pressão, para as áreas de baixa pressão [25].

A força da contração ventricular é que cria esse fluxo sanguineo, que sai do ventrículo esquerdo para a aorta e as artérias, que expandem-se para receber todo o volume de sangue, ao acontecer o relaxamento do ventrículo e a válvula da aorta se fechar, as paredes arteriais se retraem, fazendo o sangue ser direcionado para a frente em direção as pequenas artérias e arteríolas [40].

1.1.2 A Evolução Histórica dos Métodos de Aferição de Pressão

Em 1718, Stephen Hales, realizou a primeira medição de PA registrada, inserindo um tudo de latão na artéria de um cavalo, conectada à um tubo de vidro, para que pudesse observar a pulsação do sangue [7]. Em 1820, Poiseulle, criou o manômetro de mercúrio, o que permitiu que em 1847, Carl Ludwig, criasse o quimógrafo, que é composto por uma cânula, um manômetro de mercúiro e um flutuador preso a uma caneta, obtendo assim, a gravação de uma forma de onda arterial. Em 1855, Karl Vierordt, criou uma técnica não invasiva para medir a pressão arterial, o esfigmógrafo, até que em 1895, Scipione Riva-Rocci, criou o manguito inflável, e em 1905, o cirurgião russo Korotkoff, descobriu o método que ainda está em uso, o método auscultatório, que é composto por um manguito inflável, e um estetoscópio [8].

A ocorrência de uma alteração na PA, pode refletir o estado de saúde de uma pessoa, portanto, a necessidade do acompanhamento da medição da PA de forma continua, sem acarretar desconforto é de suma importância para a prevenção de doenças cardiovasculares [44].

Existem duas maneiras de aferir a PA, utilizando a medição invasiva e a medição não invasiva. O monitoramento da PA pelo metódo invasivo, é considerado o padrão ouro, realizado através da canulização de uma artéria com um cateter, um transdutor, e outros componentes. Embora esté método seja o mais confiável e forneça uma medição continua e com valores precisos, tem uso restrito, devido ao descoforto causado, ao risco de infecção, e as complicações que podem vir a acontecer com o paciente [3, 8].

A medição não invasiva possui medições descontínuas e contínuas. Um exemplo de medição descontínua, é o método auscultatório, que pode sofrer alterações em sua leitura devido a presença do próprio profissional de saúde que esta realizando o procedimento [44, 14].

A medida da PA pode ser realizada de maneira não invasiva, e sem a influência de um observador utilizando a Monitorização Ambulatorial de Pressão Arterial (MAPA), durante 24 horas, permitindo monitorar o comportamento PA até mesmo durante o sono [39], no entanto, o método ainda apresenta desvantagens, geralmente os registros da PA pelo método da MAPA são realizados a cada 15 minutos, podendo ainda sofrer influência do comportamento do paciente que está utilizando o equipamento, já que o manguito é inflado e desinflado para a realização da medida, podendo causar desconforto e ocasionar a perda de eventos entre um registro e outro, e a alteração dos valores medidos [3].

1.1.3 Recursos Atuais para Avaliação Contínua de Pressão

Na tentativa de melhorar os meios para conseguir realizar o monitoramento contínuo da PA, uma das mais novas tecnologias utilizadas é o Tempo de Trânsito de Pulso, do inglês *Pulse Transit Time* (PTT), que está relacionado á Velocidade da Onda de Pulso, do inglês *Pulse Wave Velocity* (PWV), um pulso gerado na abertura da válvula aórtica, que se propaga ao longo das artérias, e o PWV refere-se á velocidade de propagação desse pulso [10], esse método depende de parâmetros como propriedades das paredes arteriais e de calibrações do equipamento que é utilizado [3].

Atualmente na literatura, o PTT é definido como o tempo que o pulso arterial leva para se deslocar do ventrículo esquerdo para um local periférico, geralmente um dedo da mão ou do pé. Como ponto de partida é utilizada a onda R do Eletrocardiograma (ECG) normalmente, e o método de Fotoplestimografia, do inglês *Photopletismography* (PPG), usado para estimar a chegada desse pulso no local periférico. Como os valores de PTT não são adequados para serem usados diretamente, o PWV é mais utilizado em investigações clínicas [13]. Essa relação dos sinais para a obtenção do PTT, é mostrada na Figura 1.1.



Figura 1.1. Relação do sinal de ECG e PPG, onde é mostrado o pico da onda R e o pico do sinal de PPG, para obtenção do PTT e posteriormente do PWV. Adaptado de [3].

1.2 Definição do Problema Científico e Proposta de Pesquisa

Atualmente o método mais usado para medição continua da PA é o MAPA, que faz essa medição em intervalos constantes durante 24 horas, o que ainda faz com que haja a perda de eventos possivelmente importantes na variação da PA, por possuir uma amostragem considerada pequena. Além disso, o MAPA utiliza um manguito inflável, que com a inflação do mesmo, pode ocasionar desconforto no usuário, o que pode ocasionar alteração no valor da PA medida, além de poder causar danos nos tecidos [33].

Um método muito pesquisado atualmente, utiliza a análise através do PTT, que é o tempo que a onda criada pela PA leva para propagar-se pelo sistema arterial. O PTT deriva do atraso referente a onda R do ECG e a chegada dessa onda em um membro periférico, esse aferido pelo PPG [3]. No entanto, para a obtenção do ECG, são anexados, por exemplo, eletrodos no tórax, e um sensor PPG no lóbulo da orelha ou dedo das mãos, que podem sofrer alterações relativas as posições dos sensores, a circunferência das artérias e a calibração dos equipamentos utilizados [33].

O método de estimação da PA utilizando somente o sinal de PPG, é uma aplicação relativamente recente, alguns autores relatam uma correlação linear entre a PA e a duração do batimento cardíaco, obtida através do sinal de PPG, é citado que o tempo de ascendência sistólico, e o tempo diastólico, possuem tamanho de 2/3 (dois terços) e metade do tamanho da amplitude do pulso. Os testes dos estudos realizados mostram que quanto maior a PA, menor é a duração de cada batimento, entretanto, outros testes mostram que essa não é uma relação linear [19].

Em estudos recentes não são encontrados análises que definam a PA utilizando classi-

ficadores mais recentres da literatura, além de que a maioria dos autores utilizam próprios coeficientes, que possibilitam uma alta probabilidade de acerto, para o conjunto de dados especifícicos utilizados, sendo esses coeficientes ajustados para outros dados, alguns também utilizam combinações de regressores e conjunto de características dos sinais de ECG e PPG, para estimar os valores de PAD e PAS [3, 19].

Como o envelhecimento da população corrobora o que foi exposto sobre o crescente aumento de doenças cardiovasculares no mundo, e normalmente essas pessoas são frequentemente pacientes que sofrem de doenças crônicas [44, 32], é necessário o aperfeiçoamento das técnicas de medição não invasivas de pressão arterial [3]. Quando não exigem hospitalização ou necesssitam de um acompanhamento continuo, métodos como o MAPA são utilizados, entretanto, atualmente há também a utilização de sensores corporais e dispositivos médicos vestíveis, que possibilitam também a extração de outros parâmetros fisiológicos, como a saturação de oxigênio no sangue (SpO2), frequência cardíaca e sua variabilidade, e em particular a medição da PA, uma tecnologia que ainda está em evolução, devido a confiança dos valores apresentados [32].

Com isso, este trabalho propõe realizar a estimação da PA utilizando somente o sinal de ECG, somente o sinal de PPG e utilizando ambos os sinais em conjunto, comparando os resultados obtidos utilizando classificadores robustos e mais atuais, além de comparar com resultados obtidos por estudos recentes.

1.3 Objetivos

1.3.1 Objetivo Geral

O objetivo desta pesquisa é avaliar técnicas recentes de regressão e classificação de sinais em comparação com estudos já realizados na literatura, utilizando sinais ECG e PPG para a estimação da PA, com o intuito de verificar o desempenho tanto em cenários utilizando ambos os sinais, e em cenários utilizandos cada sinal isoladamente.

1.3.2 Objetivos Específicos

- Desenvolver e implementar algoritmo para seleção dos sinais de ECG e PPG sem interrupção de contato durante a aquisição, para curadoria de uma base maior de treinamento de algoritmos mais avançados;
- Avaliação do treinamento utilizando classificadores sem extração prévia de carac-

terísticas ECG e PPG em conjunto;

- Repetição de processo para classificação utilizando apenas PPG;
- Repetição de processo para classificação utilizando apenas ECG;
- Comparação de desempenho dos métodos de classificação utilizando ECG e PPG em conjunto, com métodos utilizando apenas PPG e apenas o ECG.

1.4 Estrutura do Trabalho

No capítulo 1 se encontra a introdução referente a motivação para a pesquisa desenvolvida, onde são apresentados conceitos básicos que justifiquem o objetivo principal, contém também os objetivos que pretende-se alcançar.

O capítulo 2 contém a fundamentação teórica, onde é aprofundado o conhecimento téorico para o entendimento do que é a PA, os métodos existentes para a medição da PA, além da fundamentação e explicação dos sinais de ECG e PPG, da técnica de PTT, métodos utilizados e propostos para a obtenção da PA através destes sinais.

No capítulo 3 são apresentados as técnicas utilizadas para o tratamento dos sinais, os procedimentos realizados para a obtenção dos valores de PA, e os critérios para a análise e comparação dos resultados obtidos nesta pesquisa, em comparação com estudos já realizados.

No capítulo 4 são apresentados os resultados obtidos através dos métodos propostos por esta pesquisa, e a interpretação dos mesmos, além da comparação com os resultados de outros estudos realizados, em relação a métricas de desempenho.

O capítulo 5 apresenta a conclusão deste trabalho, apresentando em resumo os resultados que foram obtidos em relação aos objetivos propostos, as dificuldades enfrentadas e propostas de contribuições futuras.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Fisiologia do Ciclo Cardíaco

O ciclo cardíaco é composto por dois períodos, um período de relaxamento do músculo cardíaco (diastóle), e por um período de contração do músculo (sístole) [40].



Figura 2.1. Eventos do lado esquerdo do coração durante ciclo cardíaco. Adaptado de [16].

Na Figura 2.1, são mostradas curvas presentes em um ciclo cardíaco, as curvas pontilhadas e a curva vermelha apresentam variações da pressão na aorta, no ventrículo esquerdo e no átrio esquerdo. A curva azul está representando as variações volumétricas no ventriculo esquerdo, a curva em amarelo apresenta um sinal de ECG, enquanto a ultima curva, um fonocardiograma, faz o registro dos sons produzidos pelo coração durante o ciclo cardíaco. Com o aumento da frequência cardíaca, a duração dos cíclos cardíacos dimínui, a duração do potencial de ação e o período de contração (sístole) também diminuem, entretanto não tão alto percentualmente quanto na fase diástole [16].



Figura 2.2. Do lado esquerdo é mostrado o movimento de contração do ventrículo, que causa a ejeção do sangue do mesmo, no lado direito é mostrado o relaxamento ventricular, e o movimento de retração das artérias, que empurra o sangue para o sistema circulatório. Adaptado de [40].

O eletrocardiograma presente na Figura 2.1, mostra as ondas P,Q, R, S e T, que são tensões elétricas geradas pelo coração. A onda P representa a propagação da despolarização pelos átrios, seguido pela contração atrial. O complexo QRS representa a despolarização elétrica dos ventrículos, iniciando a contração ventricular, ou seja, o complexo QRS se inicia antes da sístole ventricular. A onda T representa a repolarização dos ventrículos, quando as fibras musculares começam a relaxar, ocorrendo antes do final da contração ventricular [16].

2.2 Pressão Arterial

A Pressão Arterial Média (PAM) é a força propulsora do fluxo sanguíneo. A PA é um balanço entre o fluxo sanguíneo para dentro das artérias e o fluxo sanguíneo para fora das artérias. Se o fluxo para dentro excede o fluxo para fora, o volume sanguíneo nas artérias aumenta e a PAM também. Se o fluxo para fora excede o para dentro, o volume diminui e a PAM diminui [3, 40].

A PA é a representação da pressão criada através do bombeamento de sangue pelo coração, configurando um equilibribo entre o fluxo sanguineo que entra nas artérias, e o fluxo que sai das mesmas, quando ocorre o aumento do volume arterial, a pressão também aumenta. Sabendo que a PA é pulsátil, é utilizada um único valor, a PAM, que é a pressão arterial média de um ciclo cardiaco, composto pela PAS e pela PAD [3, 40].

A PAM é estimada da seguinte maneira:

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

onde, PAD é a pressão arterial diastólica, com valor considerado normal em torno de 80 mmHg, e PAS é a pressão arterial sistólica, com valor considerado normal em torno de 120 mmHg [3, 40].

A ocorrência de uma alteração nos valores da PA, pode indicar problemas no sistema circulatório, quando ocorre a queda acentuada da pressão (hipotensão), o fluxo sanguineo criado pela atividade cardíaca, não consegue superar a força da gravidade, diminuindo a troca gasosa do sangue, o que também acarreta na queda dos níveis de oxigênio, o que causa alguns problemas, por exemplo, tonturas e desmaios. A elevação da pressão, para valores acima dos considerados ideias é chamada de hipertensão, e pode até mesmo ocasionar ruptura da parede de vasos sanguineos que estejam enfraquecidos, uma consequência grave desta situação, é a hemorragia cerebral, podendo causar perda de função neurológica, comumente conhecido como derrame [40].

2.3 Aferição da Pressão Arterial

Existem duas maneiras de aferição da PA, utilizando métodos invasivos e não invasivos, sendo sua escolha atrelada a necessidade do paciente.

2.3.1 Métodos invasivos de Aferição da Pressão Arterial

Método invasivo, também conhecido por método direto, é considerado o padrão-ouro para a aferição da PA. Este método consiste em realizar a introdução de um cateter, que por sua vez está conectado a um transdutor, em uma artéria, sendo sua resposta verificada continuamente [30]. O cateter é um tubo de alta pressão, composto por um fluído, a forma de onda da coluna do fluído é transmitida ao transdutor, que converte em sinal elétrico, esse sinal é processado e exibido através de um monitor [3]. Embora seja um método com grande precisão, podem ocorrer grandes riscos para o paciente ao optar pela utilização dessa técnica, como espasmos, dor e até mesmo sangramentos, dessa forma, sendo utilizada apenas em pacientes hospitalizados, e que necessitam de cuidados maiores [30].



Figura 2.3. Esquema de aferição de pressão arterial por método invasivo. Adaptado de [3].

Como mostrado na Figura 2.3, o cateter é conectado ao liquido presente na coluna, enquanto o transdutor realiza a leitura da PAM, PAS e PAD, que são exibidas no monitor.

2.3.2 Métodos não invasivos de aferição da Pressão Arterial

Métodos não invasivos, são os métodos também conhecidos como indiretos, oferecem risco minímo aos pacientes, em sua grande maioria utilizam um manguito, que é colocado no braço do paciente, inflado até a pressão exercida ser superior a PAS, sendo gradualmente esvaziada até retornar ao fluxo sanguineo normal [38].

Método auscultatório

É o método mais comum utilizado para a medição de PA. É realizado utilizando um manguito inflável, junto com um manômetro posicionado no braço. A medição ocorre através da inflação do manguito, e um estetoscópio, posicionado abaixo do manguito, para que seja possível detectar os ruídos de Korotkoff, conforme o manguito é esvaziado, as vibrações provenientes das paredes das artérias, geram ondas sonoras audíveis, com o inicio das ondas sonoras é possível detectar a PAS, ao cessar essas ondas pode ser detectada a PAD [3, 30, 9].



Figura 2.4. Representação do método de medição de PA pelo método ausculatório, composto pelo manguito inflável, o manômetro e o estetocópio. Adaptado de [16]

Na Figura 2.4 é possível observar a ilustração do método auscultatório, o manômetro possicionado no braço, o manguito inflável, e o estetoscópio, para a medição da PA.

Método oscilométrico

Esse método registra oscilações de pressão durante a deflação do manguito, essas oscilações começam com a PAS e terminam pouco após a PAD. O manguito capta o sinal, e um microprocessador é utilizado para a análise das oscilações, determinando a PAS, PAD e frequência cardiaca através de um algoritmo [3, 21].



Figura 2.5. Método oscilométrico. Adaptado de [21].

É possível observar na parte superior da Figura 2.5, o manguito inflando com uma pressão maior que a PAS, enquanto que nas oscilações é mostrado a pressão sendo reduzida, observando as marcações da PAS, PAM e PAD [3].

2.3.3 Eletrocardiograma

Durante o ciclo cardíaco, uma corrente elétrica se propaga através do coração para os tecidos adjacentes, e uma pequena parte dessa corrente propaga-se até a superfície do corpo. Ao se colocar eletrodos na pele, possibilita o registro dos potenciais elétricos, chamado de eletrocardiograma [16].

O eletrocardiograma conforme mostrado na Figura 2.6 é composto por um conjunto de ondas (P, complexo QRS e T). A onda P ocorre com a despolarização dos átrios, antes de começar a contração atrial, gerando assim um potencial elétrico. O complexo QRS, ocorre quando há a despolarização dos ventrículos, antes de sua contração. Já a onda T, ocorre através dos potenciais gerados enquanto os ventrículos se restabelecem do estado de despolarização, sendo conhecida com o onda de repolarização [16].



Figura 2.6. Exemplo de Eletrocardiograma com a identificação das ondas. Adaptado de [16].

Para adquirir os sinais de ECG, são utilizados eletrodos colocados na pele do paciente, formando derivações, cada uma dessas derivações registra a diferença de potencial elétrico entre dois eletrodos. Esses sinais são obtidos através de um equipamento chamado de eletrocardiógrafo, que adquire, amplifica, filtra e registra os sinais de ECG, tendo em vista que esses sinais são obtidos na ordem de miliVolts (mV) [3].

Normalmente eletrocardiogramas comerciais podem registrar até 12 derivações, sendo derivações I, II e III de membros convencionais, V1, V2, V3, V4, V5 e V6 derivações precordiais, e aVR, aVL e aVF derivações aumentadas. Na Figura 2.7, é mostrada como é a configuração dessas derivações, os eletrodos ligados aos braços esquerdo e direito (BE e BD), e as perna esquerda (PE), formam o triângulo de Wilson, que é utilizado como referência para as derivações precordiais [3].



Figura 2.7. Configuração das derivações de um eletrocardiograma. Adaptado de [3].

È possível observar na primeira parte da imagem o esquema de ligação dos eletrodos para o registro das derivações I, II e III, enquanto que na parte inferior esquerda, é mostrado a configuração para o registro das derivações V1, V2 e V3, V4, V5 e V6, também chamadas de derivações precordiais, e na parte inferior diretia, a configuração para a formação do terminal central de Wilson [3].

2.3.4 Fotoplestimografia

Fotopletismografia, é uma tecnologia utilizada para a detecção de mudanças no volume do fluxo sanguíneo, utilizado principalmente em oxímetros de pulso, para monitorar a frequência cardíaca e a saturação de oxigênio do sangue (SpO2) [41].

O equipamento é composto por um fotoemissor (geralmente um LED) e um fotoreceptor, que podem ter duas configurações, uma conhecida como pletismografia transmissiva, que utiliza um led na frente do fotoreceptor, fazendo com que a luz do LED atravesse os tecidos do paciente, apresentada do lado esquerdo da Figura 2.8, enquanto que na segunda configuração, o led é colocado ao lado do fotoreceptor, de forma que a luz emitida pelo LED seja refletida pelos tecidos e capturada pelo fotoreceptor, conhecida com pletismografia reflexiva, mostrada do lado direito da Figura 2.8 [3].



Figura 2.8. Configuração de equipamento para a obtenção de sinal de pletismografia. Adaptado de [31]

Na configuração de plestimografia transmissiva, a espessura do objeto de medição é um obstáclo, quanto maior a espessura, maior precisa ser a intensidade da fonte luminousa, sendo assim mais utilizada em regiões como os dedos, orelhas e para aplicação veterinária, a lingua. Já a configuração reflexiva não possui como fator limitante a espessura da parte do corpo [31].

A luz que é emitida através do tecido biológico de um indivíduo pode ser absorvida pela pele, ossos e sangue, isso causa alterações nos valores obtidos pelos fotoreceptores. A maioria das alterações do fluxo sanguineo ocorre nas artérias e arterpiolas, durante a fase sistólica as artérias contêm maior volume de sangue, que a fase diastólia, essa alteração de volume é detectada pelo sensor PPG [6].

Com isso, tem-se dois componentes no sinal PPG, o componente AC (*Alternating Current*), que é o sinal proveniente pela onda de pulso arterial, sendo associado a frequência cardíaca, e um componente DC (*Direct Current*), gerado pelo volme total do sangue, sendo relacionada com a espessura dos tecidos e cor da pele, não ocorrendo variação durante o decorrer do tempo [3, 41].



Figura 2.9. Demonstração da obtenção do sinal de PPG, na parte superior da figura é mostrada a emissão da luz de LED passando pelos tecidos do corpo, enquanto que na parte inferior é apresentado sinal obtido, com a indicação dos componentes AC e DC. Adaptado de [6].

Conforme mostra a Figura 2.10 o pico sistólico é resultante da onda de pressão proveniente das artérias, que viaja do ventrículo esquerdo para as regiões periféricas, o entalhe dicrótico marca um aumento da pressão arterial, quando a válvula aórtica se fecha. O pico diastólico indica os reflexos da onda de pressão nas artérias [41].



Figura 2.10. características do sinal de PPG. Adaptado de [41].

2.4 Regressores e Classificadores

2.4.1 RNA - Rede Neural Artificial

Uma Rede Neural Artificial (RNA), é um método de inteligência artificial que consegue determinar e prever o comportamento de um conjunto de dados, utilizando seções de treinamentos e simulações. As RNA's são compostas por um modelo matemático e por milhares de unidades de processamento. Uma RNA pode possuir várias camadas de estruturas diferentes, dependendo da conexão existente entre elas, que está diretamente relacionada com o algoritmo de aprendizagem que será utilizado para o treinamento da RNA, este, que modifica os pesos sinápticos na RNA, para atingir o objetivo estipulado [28].

Uma RNA pode ser do tipo Redes alimentadas adiante (*Feed-forward networks*), onde a informação utilizada na rede sempre vai da camada de entrada para a camada de saída, os neurônios são sempre conectados a proxima camada, não existe conexão entre neurônios de mesma camada conforme é mostrado na Figura 2.11. Também pode ser do tipo recorrente, *Feed-backward networks*, nessa estrutura ocorre a realimentação dos neurônios, onde sua saída também atua como entrada no próprio neurônio e/ou outros de camadas anteriores. Também existem as redes competitivas, onde os neurônios são separados em duas camadas, camada de entrada e camadas de saída, onde os neurônios competem com base no nível de similaridade com o padrão proveniente da entrada, e somente o vencedor dessa disputa é utilizado na próxima iteração [15].



Figura 2.11. Representação da estrutura de uma RNA alimentada adiante. Adaptado de [15]

Funções de Ativação

As funções de ativação decidem se um neurônio é ativado ou não, configurando uma transformação não linear no sinal de entrada, transformando assim o sinal de saída que é utilizado como entrada na próxima camada. Sem a função de ativação, os pesos fazem uma transformação linear, podendo uma rede neural ser considerada como um modelo de regressão linear [1].

Uma função de ativação pode ser uma função de Etapa Binária (*Binary Step Function*), é um classificador baseado em limiar, que apenas diz sobre a ativação do neurônio, por exemplo, caso o valor encontrado no mesmo esteja acima do limiar determinado, ele é ativado, caso contrário não é ativado. Outro exemplo é a função Sigmóide, essa função varia de 0 a 1, aproximando os valores das saídas desses extremos, sendo muito utilizada para a classificação de valores para um determinado objetivo. A função *Rectified Linear Unit* (ReLU), não ativa todos os neurônios ao mesmo tempo, caso ocorra entrada negativa, ela então sera convertida para zero [1].

2.4.2 SVM - Support Vectors Machine

A Máquina de Vetor de Suporte, do inglês Support Vectors Machine (SVM), é um método de aprendizagem de máquina que utiliza dados como entrada e realiza a classificação dos mesmos. Para que a máquina seja eficaz, é necessário utilizar o conjunto de dados de entrada e de saída de treinamento, para construir o modelo que pode ser utilizado para a classificação de dados. Esse modelo é criado tomando as entradas de treinamento, mapeando-as no espaço multidimensional e utilizando regressão para encontrar um hiperplano, uma superfície em espaço de n dimensões que o separa em duas metades de espaço. Com a máquina treinada, ela passa a ser capaz de avaliar novas entradas em relação ao hiperplano divisor e classificá-las entre duas categorias [34].



Figura 2.12. Representação de uma SVM com várias entradas, e apartir do treinamento realizado, é possível obter uma saída para os dados. Adaptado de [34].

Conforme observado na Figura 2.12, um usuário é capaz de inserir uma entrada, e com base no modelo desenvolvido através de treinamento, é devolvida uma saída. Não há limite para o número de entradas para as máquinas de vetores, entretanto, em termos práticos, a capacidade computacional limita a quantidade de entradas que pode ser utilizada [34].

2.4.3 SVR - Support Vector Regression

A Regressão por Suporte de Vetores, do inglês *Support Vector Regression* (SVR), utiliza do mesmo principio que a SVM [3]. A SVR é baseada no aprendizado estatístico, que propõe técnicas de aprendizado que possuem capacidade de generalização maior, a depender do tipo de função kernel usada, são usadas para encontrar um preditor aproximado dos dados das amostras utilizados [2].

A principal diferença entre a SVR e a SVM, é que a primeira retorna um número real, ao invés de retornar uma classificação direta [3].

2.4.4 CNN - Convolutional Neural Network

Uma Rede Neural Convolucional, do inglês *Convolutional Neural Network* (CNN), é uma rede onde um campo receptivo é deslocado passo-a-passo por uma matriz bidimensional dos valores de entrada. A matriz 2D resultante pode ser utilizada como entrada para camadas subsequentes. Uma CNN, se diferencia das redes neurais tradicionais, visto que ao invés de conectar todos os neurônios da saída à entrada de todos os neurônios da camada seguinte, utilizam convoluções, existindo apenas conexões locais [18], essa topologia pode ser observada na Figura 2.13.



Figura 2.13. Topologia de uma CNN. Adaptado de [18].

As CNN's alavancam relações espaciais, o que reduz o número de parâmetros da rede e melhorando o desempenho com mecanismos de retropropagação. No geral, são formadas por camadas de dois tipos, camadas de convolução e camadas de subamostragem, também chamada de *pooling*, conforme a Figura 2.14 em conjunto, essas duas camadas compõem a etapa de extração de características [18, 27],



Figura 2.14. CNN - Convolução e Pooling. Adaptado de [18].

A convolução é uma operação matemática entre duas funções, em grande parte dos casos onde é utilizada, a convolução utiliza dados discretizados, de forma que se obtém a
equação 2.3 mostrada abaixo.

$$s(t) = (x * w)(t) = \sum_{n = -\infty}^{\infty} x(a)\omega(t - a)$$
 (2.2)

O kernel e os dados de entrada são matrizes multidimensionais, portanto, é necessária uma represetação da operação em um espaço multidimensional para que seja aplicada a convolução como uma camada de um a rede neural.

$$s(i,j) = (I * K_r)(i,j) = \sum_{m} \sum_{n} I(m,n) K_r(i-m,j-n)$$
(2.3)

Onde I é a amostra de dados, e K_r é o Kernel.

A camada de convolução utiliza filtros para obter as características mais expressivas dos dados de entradas, a característica a ser identificada é definida através do tipo de filtro (Kernel) utilizado [4].

Após a camada de convolução é comumente utilizada a função de ativação ReLu, para a introdução de não linearidade ao modelo, mantendo o volume de dados e acelerando o treinamento da rede [4].

Na camada de *Pooling* o objetivo é extrair após a saída da camada convolucional, as características mais significativas e fornecê-las como entrada para as próximas camadas [27].

Em resumo, a partir de vetores de entrada, filtros são aplicados em regiões de entrada que se sobrepõe ao longo dos vetores (convolução), e em outra camada são retiradas amostras, no fim uma camada aplica uma função de ativação, obtendo-se na saída um vetor com as classes possíveis (no caso, 2 classes) [18].

2.4.5 Robust boosting

Robust boosting é uma extensão do AdaBoosting. O algoritmo Robust boosting procura resolver o problema de desequilibrio entre classes, realizando o ajuste de distribuição de classes do conjunto de dados de treinamento, enquanto parte das técnicas utilizadas para esse objetivo fazem esse equilibrio removendo exemplos da classe majoritária realizando a subamostragem, ou adicionando exemplos à classe minoritária, um processo de sobreamostragem, o *Robust boosting* remove aleatoriamente exemplos da classe majoritária, o que reduz o tempo para a construção de um modelo [3, 36, 37],

2.5 Parâmetros de Desempenho

2.5.1 Tipos de Erros

Os dados em sua maioria, não são representados de forma exata em sua coleta ou após sofrerem um processamento, podendo serem afetados por incertezas durante sua coleta, arredondamento devido a limitação de processamento e truncamento. As medidas de erros que são normalente utilizadas são os erros absoluto e relativo [11].

O erro absoluto é dado por:

$$|x - \overline{x}| \tag{2.4}$$

onde x é um número real e \overline{x} , a aproximação [11].

O erro relativo dessa aproximação de \overline{x} , é definido como:

$$\frac{|x-\overline{x}|}{|x|}, x \neq 0 \tag{2.5}$$

como o erro relativo é adimensional, também pode ser expresso em porcentagem [11].

$$\frac{|x - \overline{x}|}{|x|} * 100\% \tag{2.6}$$

2.5.2 Acurácia e Precisão

A acurácia é a quantidade de acertos, divido pelo número total de dados utilizados, é a relação entre o resultado medido/obtido e o valor/classificação que deveria realmente ocorrer [12, 42].

$$Acurácia = \frac{Verdadeiros Positivos + Verdadeiros Negativos}{Total}$$
(2.7)

Já a precisão é a quantidade de exemplos que foram classificados corretamente, dividido pela soma de verdadeiros positivos e falsos positivos (exemplo classificados em uma classe, mas que deveriam ser de outra classe) [12, 42].

$$Precisão = \frac{Verdadeiros Positivos}{Verdadeiros Positivos + Falsos Positivos}$$
(2.8)



Figura 2.15. Exemplo de acurácia e precisão. Quanto mais próximos forem os valores dos dados obtidos ao valor real pretendido, maior a acurácia, enquanto que quanto maior a proximidade entre si dos valores obtidos dos dados, maior a precisão. Adaptado de [42].

A Figura 2.15 ilustra e exemplifica a definição de acurácia e orecisão, no canto inferior esquerdo à baixa acurácia e baixa precisão, no superior esquerdo, maior acurária e baixa precisão, no inferior direito maior precisão e baixa acurácia, e no superior direito, maior precisão e maior acurácia.

2.5.3 Desvio Padrão

O desvio padrão pode ser definido como uma medida de dispersão de dados relativo a média dos dados, ou um dado alvo, e é definido através da equação 2.9 [24].

$$DP = \sqrt{\frac{\sum_{i=1}^{n} (x - \overline{x})}{n - 1}} \tag{2.9}$$

onde DP é o desvio padrão, x é o valor obtido/medido, \overline{x} é a média ou valor alvo, n é o número de termos [24].

2.5.4 F1 Score

É uma métrica combinada de precisão e recall (que é definido como a frequência que o classificador utilizado, realmente classifica os dados nas classes corretas) [20]. O recall é dado por:

$$Recall = \frac{Verdade iros Positivos}{Verdade iros Positivos + Falsos Negativos}$$
(2.10)

Com essa combinação é possível apresentar um valor que indica a qualidade do modelo de classificação adotado [20]. A F1 Score é definida como:

$$F1 = \frac{2 * Precisão * Recall}{Precisão + Recall}$$
(2.11)

quanto mais próximo de 1 (um), melhor será a qualidade do modelo adotado [20].

3 MATERIAIS E MÉTODOS

Os sinais de ECG e PPG utilizados para estimar a PA, foram previamente adquiridos do banco de dados MIMIC-III do site physionet [29], sendo previamente processados por [3]. A Figura 3.1, apresenta o diagrama de blocos de como ocorre a filtragem dos sinais, treinamento e teste do algorítmo de classificação e regressão utilizada por [3], que também é utilizada na análise comparativa com os resultados obtidos neste trabalho.



Figura 3.1. Diagrama de blocos do processamento dos sinais da base de dados realizado por [3] a esquerda, e o diagrama de blocos realizado neste trabalho.

A esquerda da Figura 3.1 é apresentado o diagrama de blocos do processamento realizado por [3], onde após a etapa de Pré-processamento restaram apenas 42 registros de sinais (considerando sinais de PPG, ECG e PA). A direita é apresentado o diagrama de blocos realizado neste trabalho, onde na etapa de pré-processamento são utilizados os sinais separados por [3], que resultou em 38458 registros adquiridos, a partir desses registros ocorreu um novo processamento para adquirir períodos de registros sem interrupção, para aumentar o volume de dados utilizados. Os 42 registros utilizados por [3], entraram na etapa de extração de características.

3.1 Banco de dados

Os sinais de ECG, PPG e PA foram adquiridos do banco de dados *The MIMIC-III Waveform Database* [29], que é um banco de dados gratuito, contendo sinais fisiológicos de pacientes em Unidades de Terapia Intensivo (UTI). Os registros podem conter até oito formas de ondas simultâneas, incluindo as ondas de sinais já citadas, sendo estes os sinais de interesse para o trabalho. Cada registro possuí um arquivo de cabeçalho com suas informações, como taxa de amostragem, tamaho do sinal, quantidade de sinais dentro do registro, e nome dos sinais. Os sinais de ECG, PPG e PA estão amostrados a uma taxa de 125 Hz e com resoluções de oito, dez e doze bits [3, 29].

O pré-processamento realizado por [3], utilizou um algoritmo em *python*, que buscou registros no banco de dados que continham pelo menos um sinal de ECG, um sinal de PPG e um sinal de PA, caso fossem encontrados os três sinais, o download do arquivo .dat (arquivo com o sinal), e .hea (arquivo com cabeçalho), era realizado. Com esse processo foram adquiridos 38458 registros com os sinais de ECG, PPG e PA [3].



Figura 3.2. Exemplo de trecho de sinal de ECG da base de dados [29], préprocessado e adquirido por [3].

Na Figura 3.2 é apresentado um trecho de um sinal de ECG selecionado e filtrado por [3], onde no eixo horizantal é o tempo do sinal dado em segundos, e o no eixo vertical a aplitudo do sinal em mV.



Figura 3.3. Exemplo de sinal de PPG da base de dados [29], pré-processado e adquirido por [3].

Na Figura 3.3 é apresentado um trecho de um sinal de PPG selecionado e filtrado por [3], onde no eixo horizantal é o tempo do sinal dado em segundos, e o no eixo vertical a aplitudo do sinal em mV.

3.1.1 Filtragem de Sinais do Banco de Dados Pré-processado

Alguns desses registros previamente adquiridos por [3] possuem interrupções em seus sinais, sendo necessário a seleção de trechos do sinal que não possuam interrupções, sendo assim, um algorítmo de seleção foi desenvolvido utilizando o software MatLab R2020a 64-bit STUDENT.

O primeiro processamento foi realizado com conjunto de registros adquiridos previamente, possuindo apenas um ciclo cardíaco, com isso, foi desenvolvido um algorítmo que buscou os sinais de ECG, PPG e os valores de PA referentes aos mesmos, caso essa condição fosse satisfeita, era feita a comparação do tamanho do sinal de ECG e PPG, sendo esses sinais de mesma dimensão selecionados. Dentro desse conjunto, haviam alguns registros com dimensões maiores que um ciclo cardíaco, portanto, foi necessário readequa-los para que fizessem parte do conjunto de sinais selecionados, sendo assim, todos os sinais passaram a ter um ciclo cardíaco. Com esse processo, foram selecionados 29168 registros de 31229 iniciais. Em um segundo momento foi realizada uma seleção por limiarização, onde seus limiares foram definidos empiricamente, e os sinais de PPG e ECG que possuiam valores maiores do que os definidos foram descartados juntamente com os respectivos valores de PA, totalizando 21843 registros de um ciclo cardiaco selecionados.

Uma segunda seleção de sinais com registros que possuem mais de um ciclo cardiaco, ocorreu utilizando o mesmo processo, onde a partir de 15644 registro iniciais, foram selecionados 14020 registros, após o processo de limiarização, restaram 12135 registros. Para a seleção desses registros, foi necessário também estipular um tamanho máximo devido ao limite computacional do equipamento utilizado.

3.2 Filtragem de Sinais

Ao realizar o processamento prévio de sinais, [3] projetou filtros de Resposta ao Impulso Finita, do inglês *Finite Impulse Response* (FIR), que possuem linearidade de fase, o que causa a preservação da resposta impulsional, que é importante para não causar distorções nos sinais [3].

3.2.1 Filtragem dos Sinais de Eletrocardiografia

Analisando os sinais de ECG, [3] identificou ruídos de 60Hz proveninetes da rede elétrica, uma variação da linha de base, próxima a 0Hz, como solução, foi projetado um filtro rejeita-faixa FIR com ordem de 2000. Sabendo que a taxa de amostragem do sinal é de 125Hz, a banda é limitada em 62,5Hz, com isso o sinal não tem harmônica de 120Hz, e para eliminar a linha da base do sinal, foi projetado um filtro passa-alto FIR com ordem de 1000, e com frequência de corte de 0,5Hz [3].



Figura 3.4. Processo de filtragem do sinal de ECG: em (a) é apresentado o sinal bruto, em (b) no domínio da frequência, com a componente em 60Hz e 0Hz. Em (c) o sinal filtrado no domínio do tempo, e em (d) é observado que a componente em 60Hz é eliminada e a redução das componentes próximas a 0Hz. Adaptado de [3].

A Figura 3.4 mostra o processo de filtragem do sinal de ECG, onde do lado esquerdo é aprensentado o sinal sem filtro (na parte superior), e o sinal filtrado (na parte inferior), e do lado direito os sinais no domínio da frequência, sendo possível observar que a componente em 60Hz é eliminada e a redução das componentes próximas a 0Hz.

Como foi utilizada a mesma base de dados, espera-se que os todos os sinais de ECG, ou sua maioria, apresente o mesmo ruído que os descritos por [3], dessa forma, esse processo de filtragem dos sinais de ECG também é aplicado aos sinais selecionados conforme explicado em 3.1.1, para que seja possível a utilização de uma base de dados maior que a quantidade de dados utilizados nos estudos que serão utilizados para a análise de comparativa.

3.2.2 Filtragem dos Sinais de Fotopletismografia

Analisando os sinais de PPG, [3] verificou a necessidade de filtrar a linha de base do sinal, sendo projetado um filtro passa-alto FIR, com uma ordem de 1000 e frequência de corte de 0,25Hz [3].



Figura 3.5. Processo de filtragem do sinal de PPG: em (a) é apresentado o sinal bruto, em (b) no domínio da frequência, com a componente em 0Hz. Em (c) o sinal filtrado no domínio do tempo, e em (d) é observado a redução das componentes próximas a 0Hz. Adaptado de [3].

A Figura 3.5 mostra o processo de filtragem do sinal de PPG, onde do lado esquerdo é aprensentado o sinal sem filtro (na parte superior), e o sinal filtrado (na parte inferior), e do lado direito os sinais no domínio da frequência, sendo possível observar a redução das componentes próximas a 0Hz.

Como foi utilizada a mesma base de dados, espera-se que todos os sinais de PPG, ou sua maioria, apresente o mesmo ruído que os descritos por [3], dessa forma, esse processo de filtragem dos sinais de PPG também é aplicado aos sinais selecionados, conforme explicado em 3.1.1, para que seja possível a utilização de uma base de dados maior que a quantidade de dados utilizados nos estudos que serão utilizados para a análise de comparativa.

3.3 Caracterísitcas dos Sinais

3.3.1 Sinal de Eletrocardiografia

Uma característica de grande importância no sinal de ECG, é a extração dos picos R, que é utilizado no método PTT de estimação da PA, e também é utilizado no janelamento realizado neste trabalho. O algoritmo utilizado por [3] foi o *Pan Tompkins*, e somente os sinais que [3] realizou a extração dessas características, são utilizados na classificação baseada nas características extraídas.



Figura 3.6. Sinal de ECG com a identificação dos picos.

O resultado da extração dos picos R em um sinal de ECG da base de dados, utilizando o método de *Pan Tompkins*, é mostrada na Figura 3.6.

3.3.2 Sinal de Fotopletismografia

Para a extração de características dos sinais de PPG [3] também utilizou o algorítmo de *Find Peaks*, desta forma, somente os sinais de PPG que tiveram suas características extraídas por [3] são utilizados para a classificicação baseada na extração de características.



Figura 3.7. Sinal de PPG com a identificação de picos e vales.

O resultado da extração dos picos e vales um sinal de PPG da base de dados, utilizando o método de *Find Peaks*, é mostrada na Figura 3.7.

3.4 Processo de Janelamento

Após a utilização dos sinais de um ciclo cardiaco para a estimação da PA, é feito o janelamento dos mesmo sinais, realizando um processo de *shift*, onde os sinais são replicados após o seu próprio final de ciclo, aumentando o sinal de entrada utilizado para o teste com regressão, tanto para o teste com classificação direta utilizando CNN.

O segundo janelamento realizado, ocorre com os sinais utilizados por [3], com o objetivo de realizar a classificação baseada na extração de características. Para cada sinal dos 42 (quarenta e dois) sinais utilizados por [3], é realizado um janelamento de 10 segundos para a extração de características de cada janelamento.

O algortitmo desenvolvido procura pelo pico e pelo vale do sinal de PPG dentro da janela e também pela localização do pico R do sinal do ECG, com essas informações, é realizada a busca pelo valor da PAS e PAD, formando um janelmaento de 10 segundos, com valores de PA, valores de vale e pico de PPG e pico R do sinal de ECG. Com as informações necessárias definidas, o algoritmo faz a extração da informações temporais do janelamento conforme explicado em 3.4.1 para a estimação da PA e classificação dos sinais.

3.4.1 PTT

Esse janelamento serve para que os sinais sejam sobrepostos já com seus picos detectados, e os trechos selecionados estejam no mesmo instante de tempo. Para isso o algoritmo desenvolvido recebe o sinal de PPG, o sinal de ECG, a localização dos picos da onda R, e a quantidade de picos de onda R identificados, para que os sinais tenham também o mesmo tamanho no janelamento.

O algoritmo de janelamento que é aplicado ao PTT, procura pelos picos R de ECG, em sequência procura pelos picos do PPG, para validar o trecho dos sinais, o algoritmo verifica se após a localização desse pico existe um pico de PPG antes do próximo pico R do ECG, caso essa condição seja satisfeita, é verificado se antes do PPG, existe um pico de ECG [3].

Para efeito de comparação de desempenho dos estudos utilizados como parâmetro, será apenas utilizado o método de PTT para estimação da PA, que conforme a literatura, é a mais utilizada, o intervalo entre o pico da onda R do sinal de ECG, e o pico do sinal de PPG, é nomeado como PTT_P [3]. Esse método pode ser observado na Figura 3.8.



Figura 3.8. Sinal de PPG em verde, e sinal de ECG em vermelho. R peak, é o pico R do sinal de ECG, PPG Peak, o pico do sinal de PPG. A diferença entre esses picos é chamada de PTT. Adaptado de [17].

O intervalo PTT_P é dado por:

$$PTT_P = PPG_P - ECG_R \tag{3.1}$$

A outra característica extraída é o intervalo entre o pico da onda R do sinal de ECG, e o vale do sinal de PPG, sendo esta chamada de PTT_V [3]. Essa característica pode ser observada na Figura 3.9.



Figura 3.9. Sinal de PPG pontilhado, e sinal de ECG continuo. A diferença entre o pico do ECG e do vale do PPG é chamada de PTT_V . Adaptado de [3].

O intervalo PTT_V é dado por:

$$PTT_V = PPG_V - ECG_R \tag{3.2}$$



Figura 3.10. Exemplo de janelamento dos sinais de ECG e PPG, com o mesmo período de tempo, onde os sinais são sobrepostos para a realização da estimação da PA.

Esse processo de janelamento é repetido para todos os sinais de ECG e PPG selecionados. A partir do janelamento dos sinais, será feito o processamento dos sinais para estimação da PA.

3.5 Estimação de Pressão Arterial

Para a estimação da PA com a extração de características, é utilizado o método do PTT utilizando SVM e Robust boosting, variando o paramêtro de seções de teste em busca de um melhor resultado. Cada janela obtida, é considerada uma entrada, que tem como alvo o valor da PAS e PAD também obtidos no janelamento. Com esses mesmos valores obtidos, é realizada a classificação direta dos sinais em duas classes, pressão alta, ou pressão normal, tendo como referência os valores definidos em [35].

Utilizando os sinais de um ciclo cardíaco previamente tratados, é utilizada a CNN com e sem regressor para a estimação da PA, tendo como alvo os valores de PAS e PAD referentes a cada sinal, além da classificação direta dos sinais em pressão alta ou normal, de acordo com os valores de referência defincios em [35], normalizando os dados na entrada e/ou na saída da CNN. Os parâmetros da rede são variados para obter um melhor resultado, sendo eles a quantidade de filtros, o tamanho do Kernel, a camada de MaxPolling, a taxa de aprendizagem, o batch size, e o número de épocas.

3.6 Procedimento Experimental

O processamento de dados, treinamentos e testes foram realizados com um notebook que possui processador Intel Core i7-4510U 2.00GHz com 4 núcleos, 16GB de memória RAM, e com sistema operacional Windows 10 Home, utilizando os programas MatLab R2020a 64-bit STUDENT, para extração dos picos e vales, e o aplicativo Anaconda3 2020.11, utilizando Python3 para os janelamentos, treinamentos e testes.

Para o primeiro grupo de experimento foi escolhida a CNN como regressor, utilizando os sinais de um ciclo cardíaco selecionados da base de dados. O primeiro cenário de teste foi utilizando os sinais de ECG e PPG, cada um como um índice de entrada para a CNN, onde 30% dos dados são utilizados para teste, e 70% para treinamento. Este primeiro cenário é repetido tendo como alvo os valores de PAS e PAD. Para o segundo cenário, as entradas para a CNN são normalizadas, a proporção de dados para teste e validação também são mantidas (30% e 70% respectivamente), esse cenário é repetido uma segunda vez, também sendo realizada a normalização na saída dos dados da CNN, também sendo repetido para os valores de PAS e PAD como alvo. O terceiro cenário para este experimento, utiliza a normalização dos dados de entrada, e também a normalização dos dados alvo de PAS e PAD, sendo também repetido com a normalização das saídas dos dados.

O segundo experimetno utiliza os valores de PAS e PAD para a classificação direta em pressão alta ou não, também utilizando a CNN. Para o primeiro cenário, são utilizados os sinais com um ciclo cardíaco, também classificando utilizando a PAS e a PAD, sendo esse cenário repetido também utilizando a normalização dos dados de entrada. O segundo cenário realiaza o aumento dos sinais de um ciclo, onde é aplicado um processo de shift nos sinais, tornando-o um sinal de dois ciclos, sendo esse cenário realizado para PAS e PAD, e sendo repetido com a normalização da entrada de dados.

O terceiro experimento utiliza a SVM e o Robust boosting, utilizanda extração de características para a classificação dos valores de PAS e PAD em pressão alta ou não. As características extradas são o PTT em relação ao vale do PPG e o pico R do ECG, o PTT em relação ao pico do PPG e o pico R do ECG, e a distância entre o pico e o vale do PPG. Para este terceiro experimento, são utilizados os sinais selecionados e utilizados por [3], são 42 registros de sinais de ECG, PPG, e seus respectivos valores de PAS e PAD.

3.7 Avaliação de Desempenho

De forma a avaliar o desempenho dos algoritmos desenvolvidos e dos experimentos realizados, serão utilizados os resultados obtidos por [3], que faz uso de diversos regressores e também realiza testes de calibração, também sera comparado com os resultados obtidos por [19], que utiliza regressão linear e redes neurais de 4 e 21 neurônios de entrada, utilizando os parâmetros descritos por [45], que também terá seus resultados analisados, onde utiliza regressão linear, rede neural de 9 neurônios de entrada, e SVM, também será analisado os resultados obtidos por [6] que utilizou o método de PPI (do inglês, *Peak-to-Peak Interval*), os resultados obtidos por [23], que também utiliza regressão linear. Para comparar com estes estudos serão utilizados o erro absoluto e relativo, que também são apresentados como resultados destes estudos.

O banco de dados utilizado, [29], disponibiliza o valor da PA para os sinais que medidos, sendo esses valores utilizados como referência para a avaliação de desempenho, assumindo-os como valores corretos a serem obtidos por este trabalho.

Para a avaliação dos resultados da proposta deste trabalho de forma isolada, além da estratégia de reamostragem aleatórioa, onde cada sessão de treinamento utiliza um subconjunto de dados aleatório, do conjunto completo, de forma ao treinamento de cada seção, ser diferente do treinamento de outra seção, a cada reamostragem são calculados os verdadeiros positivos, verdadeiros negativos, falsos positivos, falsos negativos, sendo realizada a média de todos os valores para a o calculo da acurácia, precisão, e F1 Score, descritos em 2.5.

4 **Resultados**

4.1 Regressão utilizando CNN

4.1.1 Estimação de PA utilizando os sinais de PPG e ECG

O primeiro cenário de teste utilizou os sinais de um ciclo cardíaco filtrados e selecionados do banco de dados. De forma aleatória, 30% dos sinais foram separados para teste, e 70% para treino. Foram repetidos várias seções de treinos, com essa separação de dados para teste e treinamento sempre ocorrendo de forma aleatória, sempre utilizando os sinais de ECG e PPG em conjunto para a entrada da CNN, tendo como alvo os valores de PAS associados a estes sinais.

Tabela 4.1. Regressão com CNN para estimação de PAD utilizando sinais de ECG e PPG em conjunto

Épocas	MAE
100	31.11
300	30.89
500	31.57

Como mostrado na Tabela 4.1, os resultados obtidos para esse teste não foram satisfatórios, obteve-se ainda um MAE (*Mean Absolute Error*, em português Erro Absoluto Médio), entre cada valor de PAD encontrado, e o valor alvo, em torno de 16.5. Com esse resultado, optou-se por não prosasguir com os testes para esse cenário, visto que mesmo testando com épocas diferentes, tamanhos de filtros diferentes, tamanho de conjuntos diferentes, o resultado não teve alteração significativa.

O segundo cenário de teste também utilizou os sinais de um ciclo cardíaco filtrados e selecionados do banco de dados. De forma aleatória, 30% dos sinais foram separados para teste, e 70% para treino. Foram repetidos várias seções de treinos, com essa separação de dados para teste e treinamento sempre ocorrendo de forma aleatória, sempre utilizando

os sinais de ECG e PPG em conjunto para a entrada da CNN, tendo como alvo os valores de PAS associados a estes sinais

Tabela 4.2. Regressão com CNN para estimação de PAD utilizando sinais de ECG e PPG em conjunto, com normalização da entrada de dados para a CNN

Épocas	MAE
100	30.68
300	30.70
500	31.21

Como mostrado na Tabela 4.2, os resultados obtidos para esse teste não foram satisfatórios, obteve-se ainda um MAE entre cada valor de PAD encontrado, e o valor alvo, em torno de 15. Como para esse teste ocorre a normalização da entrada, o teste foi repetido normalizando a saída obtida também, embora durante o processo de treinamento, resulte em uma MAE em torno de 0.039, ao ser finalizado e utilizar a métrica de desempenho para os valores testados, em relação aos resultados obtidos, a MAE tem um salta para uma média de 107, dessa forma este cenário foi descartado para a continuação dos testes.

O terceiro cenário de teste, também utiliza o procedimento explicado nos cenários anteriores, entretanto neste teste, também é realizada a normalização dos dados de PAS e PAD. Foram repetidos várias seções de treinos, com a separação de dados para teste e treinamento sempre ocorrendo de forma aleatória, sempre utilizando os sinais de ECG e PPG em conjunto para a entrada da CNN, tendo como alvo os valores de PAS e PAD também normalizados.

Tabela 4.3. Regressão com CNN para estimação de PAD utilizando sinais de ECG e PPG em conjunto, com normalização da entrada de dados e dados alvo da CNN

Épocas	MAE	MAE(Resultado normalizado)
100	0.007	0.010
300	0.0049	0.0034
500	0.0037	0.0031

Como mostrado na Tabela 4.3, na segunda coluna (MAE), observou-se um valor muito baixo, com isso, o teste foi repetido normalizando a saída, o que resultou em valores menores, entretando ao se observar na Figura 4.1, MAE e sua validação, e a Figura 4.4 da função *loss*, e sua validação, observa-se que o resultado não é confiável, onde desde o inicio do treinamento os valores já convergem a próximo de zero.



Figura 4.1. Retorno da função MAE e sua validação com o terceiro cenário de teste, apresentado convergência para zero desde o princípio.



Figura 4.2. Retorno da função *loss* e sua validação com o terceiro cenário de teste, apresentado convergência para zero desde o princípio.

Ainda dentro desse experimento, também foi testado a estimação da PA, utilizando

somente o sinal de PPG, que com os sinais de um ciclo cardíaco, não se mostrou suficiente para se obter um bom resultado.



Figura 4.3. Retorno da função MAE e sua validação com o terceiro cenário de teste, utilizando somente o sinal de PPG, apresentando uma variação muito grande entre os resultados obtidos, de MAE e sua validação.

Como ultimo teste dentro desse experimento, também foi testado a estimação da PA, utilizando somente o sinal de ECG, que com os sinais de um ciclo cardíaco, não se mostrou suficiente para se obter um bom resultado, sendo observado que a validação convergia de forma oposta ao valor obtido pelo MAE.



Figura 4.4. Retorno da função *MAE* e sua validação com o terceiro cenário de teste, utilizando somente o sinal de ECG, apresentando uma variação muito grande entre os resultados obtidos, de MAE e sua validação.

4.1.2 Classificação de PA utilizando CNN com os sinais de PPG e ECG

O segundo experimento consiste em usar utilizar a CNN para regressão, e classificar os valores obtidos diretamente em pressão alta ou não. Durante os testes foi percebido um desnivelamento entre a quantidade de dados em cada classe, desta forma a quantidade máxima de amostras só poderia ser igual ou menor, a quantidade de dados encontrados na menor classe. A partir de testes iniciando o algoritmo desenvolvido, sabendo-se que seria obtido um resultado com erro, e observando qual a quantidade de dados escolhida apresentava erro, chegou-se ao resultado de 2330 conjuntos de sinais para uma das classes (pressão alta ou não pressão alta). Foi definido em um primeiro teste um valor de referência para a PAS através dos parâmetros indicados em [35], para PAD considerada alta acima de 80mmHg, obteve-se os seguintes resultados:



Figura 4.5. Classificação de PAD utilizando CNN, para PAD considerada alta acima de 80mmHg, apresentando as curvas de acurácia do treino e de validação dos dados utilizados.



Figura 4.6. Função *loss* e sua respectiva validação para a classificação de PAD utilizando CNN, para PAD considerada alta acima de 80mmHg

É possível observar nas Figuras 4.5 e 4.6, um comportamento de *overfit* para a classificação direta de PAD alta.

Analisando os sinais e os valores de PAD da maioria do sinais, percebeu-se que a maioria apresenta valores abaixo do normal para os padrões de PAS e PAD, com isso realizou-se um novo teste, tendo como parâmetro para PAS conisderada alta 60mmHg.



Figura 4.7. Classificação de PAD utilizando CNN, para PAD considerada alta acima de 60mmHg, apresentando as curvas de acurácia do treino e de validação dos dados utilizados.



Figura 4.8. Função *loss* e sua respectiva validação para a classificação de PAD utilizando CNN, para PAD considerada alta acima de 60mmHg

Atavés das Figuras 4.7 e 4.8, é possível observar uma melhora utilizando como parâmetro para PAD alta, um valor acima de 60mmHg, a partir do teste realizado, mesmo alterando os parâmetros da rede, não houve uma melhora significativa, algumas vezes voltando a apresentar o comportamento de *overfit*. Com essa informação sobre os valores de PAS e PAD, realizou-se o teste de classificação para PAS utilizando o valor de 130 mmHg para pressão alta.



Figura 4.9. Classificação de PAS utilizando CNN, para PAS considerada alta acima de 130mmHg, apresentando as curvas de acurácia do treino e de validação dos dados utilizados.



Figura 4.10. Função *loss* e sua respectiva validação para a classificação de PAS utilizando CNN, para PAS considerada alta acima de 130mmHg

É possível observar através das Figuras 4.9 e 4.10 o comportamento de *overfit*, ressaltando que para este cenário foram utilizados os sinais de um ciclo cardíaco.

Seguindo o mesmo procedimento utilizado para a PAD, os sinais de ECG e PPG também tiveram o processo de *shift* dos sinais, de forma a aumentá-los para dois ciclos e a normalização da entrada dos dados, e o procedimento de classificação repetido, obtendo-se os resultados mostrados a seguir.



Figura 4.11. Classificação de PAS utilizando CNN, para PAS considerada alta acima de 130mmHg, com os sinais de PPG e ECG possuindo dois ciclos cardíacos, apresentando as curvas de acurácia do treino e de validação dos dados utilizados.



Figura 4.12. Função *loss* e sua respectiva validação para a classificação de PAS utilizando CNN, para PAS considerada alta acima de 130mmHg com os sinais de PPG e ECG possuindo dois ciclos cardíacos.

É possivel observar uma leve melhora, embora, caso o treinamento possuísse mais épocas, provavelmente voltaria a ser percebido o efeito de *overfit*.

4.2 Classificação de PA utilizando SVM e Robust boosting com os sinais de PPG e ECG

O terceiro experimento utiliza SVM e *Robust boosting*, utilizando as características extraídas por [3], para a classificação dos valores de PAS e PAD em pressão alta ou não. Utilizando as características extraídas de localização e valores de picos R do ECG, e picos e vales do PPG, dos sinais utilizados por [3], utilizou-se o método de PTT, que é a diferença entre o pico do PPG e o pico R do ECG, e o vale do PPG, e o pico R do ECG, além da relação de distância entre o pico e o vale em sequência do sinal de PPG.

A primeira parte realizou o procedimento de classificação para a PAD, utilizando como valor referência 80mmHg. Variando o número de iteraçõe entre 50 e 1000. Observando-se os resultados obtidos, e analisando os sinais utilizados, encontrou-se a mesma situação dos sinais de um ciclo cardíaco, onde os valores de PAD estavam abaixo, portanto, a classificação foi repetida tendo como alvo 60 mmHg, 65 mmHg e 70 mmHg, definindo as

iterações testadas anteriormente.

O mesmo procedimento foi adotado para a classificação da PAS, utilizando 500, 750 e 1000 iterações, e valores de 110 mmHg, 120 mmHg e 130 mmHg como referência para ser considerada pressão alta, visto que os valores de PAS também estavam abaixo do considerado ideal.

Como forma de avaliar os resultados obtidas são usadas as métricas de Acurácia, Precisão, F1 Score e Sensibilidade, que são apresentados na Seção 4.3

4.3 Avaliação de Desempenho

4.3.1 Regressão para Estimação da PA

Como forma de avaliar o desempendo obtido com a metodologia utilizada neste trabalho, são utilizados os resultados apresentados por [3, 6, 19, 23, 43, 45].

A	Mátada	PAS	PAD	Parâmetro de Desempenho
Autor	Metodo	(mmHg)	(mmHg)	MAE
	SVR Calibrado	3.98	1.36	-
[3]	SVR Sem calibrar	18.87	5.76	-
	Bagging Predictors	2.63	2.21	-
	Regressão Linear	6.04	5.04	-
	NLMS+KF (PPG)	_	-	2.69 ± 2.14
[6]	RLS + KF (PPG)	-	-	$1.54{\pm}0.64$
	Regressão Linear	$9.80 {\pm} 8.09$	$5.88 {\pm} 5.11$	-
[19]	Rede Neural (4 Neurônios)	$5.19 {\pm} 5.01$	$2.91{\pm}2.92$	-
	Rede Neural (21 Neurônios)	3.8 ± 3.46	$2.21{\pm}2.09$	-
[23]	MLP (PPG)	5.63 ± 11.9	$5.37 {\pm} 10.88$	$6.57 {\pm} 0.11$
	Regressão Linear	$9.80 {\pm} 8.09$	$8.94{\pm}7.57$	-
[43]	RSVM	$5.07 {\pm} 4.84$	4.31 ± 3.83	-
	ANN	402 ± 2.79	$2.27{\pm}1.82$	-
	Regressão Linear	$12.22{\pm}10.71$	$9.20{\pm}7.05$	-
[45]	Rede Neural (9 Neurônios)	$11.89{\pm}10.18$	$8.83 {\pm} 7.15$	-
	SVM	11.64 ± 8.20	$7.61{\pm}6.78$	-
O Autor	CNN	-	± 16.5	30.89
	CNN	-	± 15	31.21
	CNN	-	± 12	0.0037

Tabela 4.4. Avaliação de desempenho de métodos de regressão utilizados neste trabalho, em comparação com os resultados obtidos em trabalhos de referência

Como pode-se observar na Tabela 4.12, a proposta de utilizar a CNN como método de regressão para a obtenção de estimação da PA, não se mostrou efetivo para os sinais de um ciclo, visto que para PAS a variação entre o valor real e o valor obtido chegou a 16.5, enquanto que a MAE alcançou um valor de 30.89, apresentando sempre um comportamento de *overfit*. Para um cenário de estimação utilizando a CNN, obteve-se uma variação entre valor real e valor obtido de PAS, em torno de 12, e para o MAE, um valor muito baixo de 0.0037, que mesmo em porcentagem (0.37%) se torna um valor não confiável, visto o comportamento final do treinamento, gerando um *overfit*, e do valor de variancia entre valor real e valor obtido.

4.3.2 Classificação da PA

Para a classificação da PA utilizando regressores e classificação direta, é utilizada como comparação para o resultado obtido, o trabalho realizado por [3].

Tabela 4.5. Classificação de PAS após regressão por CNN com sinais de um ciclo cardíaco, para pressão alta tendo PAS ≥ 130

Parâmetro	Resultado (%)
Acurácia	55%
Sensibilidade	76%
Precisão	54%
F1 Score	63%

Tabela 4.6. Classificação de PAS após regressão por CNN aplicando o processo de *shift* nos sinais, para pressão alta tendo PAS ≥ 130

Parâmetro	Resultado (%)
Acurácia	66%
Sensibilidade	67%
Precisão	66%
F1 Score	67%

Observando os resultados obtidos e apresentados na Tabela 4.5 e na Tabela 4.6, é possível observar uma melhora dos resultados ao utilizar um sinal com mais amostras, visto o salto de 10% em relação a acurácia, e a precisão, o que representa uma proximidade maior com o valor real, e uma consistência maior com os resultados obtidos.

Tabela 4.7. Classificação de PAD após regressão por CNN com sinais de um ciclo cardíaco, para pressão alta tendo PAD ≥ 80

Parâmetro	Resultado (%)
Acurácia	59%
Sensibilidade	65%
Precisão	58%
F1 Score	61%

Parâmetro	Resultado (%)
Acurácia	64%
Sensibilidade	56%
Precisão	67%
F1 Score	61%

Tabela 4.8. Classificação de PAD após regressão por CNN aplicando o processo de *shift* nos sinais, para pressão alta tendo PAD ≥ 80

Como foi observado anteriormente que os valores de PAD estavam em sua maioria abaixo do ideal, foi também testado a classificação da PAD, sendo considera pressão alta $PAD \ge 60$.

Tabela 4.9. Classificação de PAD após regressão por CNN com sinais de um ciclo cardíaco, para pressão alta tendo PAD ≥ 60

Parâmetro	Resultado (%)
Acurácia	57%
Sensibilidade	65%
Precisão	56%
F1 Score	60%

Tabela 4.10. Classificação de PAD após regressão por CNN aplicando o processo de shift nos sinais, para pressão alta tendo PAD ≥ 60

Parâmetro	Resultado (%)
Acurácia	66%
Sensibilidade	67%
Precisão	66%
F1 Score	67%

Foi possível observar que mesmo com o tamanho dos sinais sendo aumentados, mesmo com a modificação dos parâmetros de aprendizado, e mesmo a mudança do alvo para a classificação, para a PAD não houve diferença considerável, enquanto que para a PAS, em alguns parâmetros houve aumento de 10% nos resultados.

A última abordagem deste trabalho é a classificação de PA utilizando um regressor SVM e sem regressão utilizando o algoritmo *Robust Boosting*, utilizando os sinais também utilizados por [3].

Tabela 4.11. Avaliação de desempenho de classificação direta de pressão alta para PAD, comparando com os resultados obtidos por [3].

Autor	Método	PAD	Parâmetro de Desempenho			
		(mmHg)	Acurácia	Sensibilidade	F1-Score	Precisão
[3]	Robust boosting	$80 < PAD \le 90$	99%	94%	95%	96%
	Robust boosting	$70 < PAD \le 80$	66%	86%	34%	22%
O autor	Robust boosting	$65 < PAD \le 75$	78%	94%	73%	61%
	Robust boosting	PAD > 65	85%	95%	82%	73%
	Robust boosting	PAD > 60	92%	89%	92%	96%
O autor	SVM	$70 < PAD \le 80$	88%	-	-	-
	SVM	$65 < PAD \le 75$	77%	58%	60%	68%
	SVM	PAD > 65	76%	66%	68%	75%
	SVM	PAD > 60	92%	89%	86%	85%

Tabela 4.12. Apresentação dos resultados obtidos e apresentad
p a avaliação de desempenho de classificação direta de pressão alta para PAS

Autor	Método	PAS	Parâmetro de Desempenho			
		(mmHg)	Acurácia	Sensibilidade	F1-Score	Precisão
	Robust boosting	$130 < \text{PAD} \le 139$	56%	-	-	4.7%
Oautor	Robust boosting	$100 < PAS \le 110$	64%	-	-	23%
O autor	Robust boosting	PAS > 140	63%	64%	70%	81%
	Robust boosting	PAS > 130	67%	65%	74%	90%
	SVM	$130 < PAS \le 139$	94%	-	-	-
O autor	SVM	$100 < PAS \le 110$	88%	-	-	-
	SVM	PAS > 140	80%	93%	86%	81%
	SVM	PAS > 130	86%	93%	90%	89%

Para a classificação com o valor ajustado para os valores encontrados nos sinais utilizados, o método *Robust boosting* e SVM apresentaram resultados promissores. Para a classificação da PAS, devido a alguns problemas com eficiência computacional do equipamento utilizado, não foi possível obter todos os valores para os parâmetros de desempenho.

5 CONCLUSÃO

O principal objetivo dessa pesquisa foi, a estimação de PA de forma não invasiva utilizando os sinais de PPG e ECG como informação. Durante o desenvolvimento desse trabalho foram avaliados diferentes algorítmos de regressão e classificação direta de PA, utilizando seleção aleatória dos sinais para teste e treinamento dos algoritmos, tanto para a estimação da PA utilizando a CNN com regressores, a classificação direta com e sem regressores.

A seleção de sinais para aumentar a base de dados, ocorreu de forma satisfatória quando referente aos sinais de um ciclo cardíaco, possibilitando a utilização de mais de 20000 amostras, a seleção de sinais maiores, também ocorreu, entretando devido ao desempenho do equipamento utilizado, não foi possível finalizar toda a preparação para a utilização nos algoritmos desenvolvidos.

A proposta inicial de utilizar somente o sinal de PPG na CNN para a estimação de PA e classificação da PA em pressão alta ou não, mostrou-se pouco eficaz, sendo observado, que possivelmente os dados utilizados para este objetivo, não foram suficientes.

Para a utilização da CNN e o resultado obtido, observou-se que para os sinais utilizados de um ciclo cardíaco, o algoritmo apresenta um cenário de *underfit* inicialmente, quando a rede de treinamento foi aumentada, e os valores normalizados, buscando uma melhor eficiência da rede, a mesma apresentou um comportamento de *overfit*, mesmo no treinamento o erro sendo baixo, no conjunto de testes, o erro era amplificado.

Pode-se concluir também, que ao utilizar a CNN e seu modelo de regressão para a classificação dos valores de PAS e PAD em pressão alta ou não, ao realizar o processo de *shift* nos sinais, e duplicá-los de tamanho, o resultado melhorou em torno de 10% para a PAS, enquanto que para a PAD não houve diferença considerável, podendo ser o desequilibrio na quantidade de amostras, e os valores encontrados nas amostras, onde a maioria delas estava em torno de 60 mmHG, valor que o padrão de pressão, é considerado baixo.

A classificação de PA utilizando Robust boosting e SVM, apresentou resultados me-

lhores que os resultados obtidos com a regressão da CNN, entretando os dados utilizados também são diferentes, são os mesmos dados utilizados por [3], ao utilizar valores alvo menores que o padrão, a taxa de sucesso para a classificação ficou em torno de 90% em ambos os algoritmos, apresentando valor próximo ao obtido por [3].

Um problema enfrentando durante a pesquisa e que afetou diretamente o tempo de trabalho e os resultados obtidos, é o poder de processamento do equipamento utilizado, em alguns testes realizados, foi percebida a melhora no desempenho dos algoritmos desenvolvidos, entretanto, alguns testes demoravam de 6 a 10 horas para sua execução, devido aos parâmetros utilizados nos treinamentos e testes, com isso, houve uma limitação no tempo de trabalho, visto que alguns momentos ocorria o travamento do equipamento, aliado ao tempo curto do semestre em questão e as situações e dificuldades enfrentadas em tempo de pandemia.

Para trabalhos futuros será necessário utilizar um equipamento com maior poder de processamento, para a utilização da base de dados estendida com sinais de maiores, e com mais amostras, visto que ao realizar o *shift* nos sinais menores, os algoritmos já apresentaram uma melhora, e a classificação com os algoritmos de *Robust boosting* e SVM utilizados com sinais maiores, também esbarraram com esse problema, visto que ao utilizar um maior número de iterações no processo de classificação, o tempo de processamento aumentou consideravelmente, mas o resultado começou a ser mais promissor e interessante de ser observado.
Referências Bibliográficas

- [1] Data Science Academy. Capítulo 8 função de ativação.
- [2] S. M. Acosta, A. L. Amoroso, and A. M. O. Santanna. Modelagem de um processo produtivo utilizando regressÃo por vetores suporte. XXXVI ENCONTRO NACIO-NAL DE ENGENHARIA DE PRODUCÃO, 2016.
- [3] R. Amaral. Estimativa contínua e não invasiva da pressão arterial com base na análise do tempo de trânsito de pulso em sinais de eletrocardiografia e fotopletimografia. Dissertação de mestrado em engenharia biomédica, Universidade de Brasília, Brasília, DF, 2020.
- [4] A. F. Baia. Estrutura competitiva de redes neurais convolucionais autoassociativas para classificaÇÃo de arritmias. 2019.
- [5] G. L. Bakris. Hipertensão arterial, 2019.
- [6] T. Benetti. Estimativa robusta da frequência cardíaca a partir de sinais de fotopletismografia de pulso. Dissertação de mestrado em engenharia elétrica, Pontifíca Universidade Catótlica do Rio Grande do Sul, Porto Alegre, RS, 2018.
- [7] L. W. J. Borget and J. J. van Lieshout. Non-invasive pulsatile arterial pressure and stroke volume changes from the human finger. *Experimental Physiology*, pages 437 - 446, 07 2005.
- [8] E. Chung and et al G. Chen, B. Alexander. Non-invasive continuous blood pressure monitoring: A review of current applications. *Frontiers of medicine*, 7, 01 2013.
- [9] I. Corazza, L. Fabbiani, L. Marras, et al. The arterial pressure auscultatory method. *High Blood Pressure & Cardiovascular Prevention*, 13(4):179–183, Dec 2006.
- [10] D.Buxi, J. Redouté, and M. R. Yuce. Blood pressure estimation using pulse transit time from bioimpedance and continuous wave radar. *IEEE Transactions on Biomedical Engineering*, 64(4):917–927, 2017.
- [11] UFRGS IME Recursos Educacionais Abertos de Matemática. 2.5 tipos de erros.

- [12] M. Filho. As métricas mais populares para avaliar modelos de machine learning.
- [13] J. Y. A. Foo, S. J. Wilson, G. Williams, et al. Pulse transit time as a derived noninvasive mean to monitor arterial distensibility changes in children. *Journal of human hypertension*, 19(9):723 – 729, 2005.
- [14] M. A. M. Gomes, A. M.G. Pierin, C. A. Segre, et al. Monitorização residencial da pressão arterial e monitorização ambulatorial da pressão arterial versus medida de pressão arterial no consultório. Arquivos Brasileiros de Cardiologia, 71:581 – 585, 10 1998.
- [15] A. R. Gonçalves. Fundamentos e aplicações de técnicas de aprendizado de máquina, 2008.
- [16] A.C. Guyton and J.E. Hall. Tratado de Fisiologia Médica. Elsevier, 12^a edition, 2011.
- [17] X. He, R. A. Goubran, and X. P. Liu. Evaluation of the correlation between blood pressure and pulse transit time. In 2013 IEEE International Symposium on Medical Measurements and Applications (MeMeA), pages 17–20, 2013.
- [18] W. R. O. Junior. O uso de redes neurais convolucionais e totalmente conectadas para a categorização de textos em idiomas português e inglês. page 129, 2018.
- [19] Y. Kurylyak, F. Lamonaca, and D. Grimaldi. A neural network-based method for continuous blood pressure estimation from a ppg signal. volume 80, 05 2013.
- [20] R. S. Leal. Métricas comuns em machine learning: como analisar a qualidade de chat bots inteligentes métricas (3 de 4).
- [21] A. Lima. Parte1: Métodos automáticos de medida indireta de pressão arterial. o que são?, 2011.
- [22] D. C. Malta, R. P. F. Gonçalves, Í. E. Machado, et al. Prevalência da hipertensão arterial segundo diferentes critérios diagnósticos, pesquisa nacional de saúde. *Revista Brasileira de Epidemiologia*, 21, 00 2018.
- [23] J. Martins, C. Silva, F. Ramalho, et al. Método não invasivo para predição da pressão arterial com pletismografia e inteligência computacional. 01 2019.
- [24] M. E. G. Martins. Desvio padrão amostral. Revista de Ciência Elementar, 1, 2013.
- [25] C. Molnar and J. Gair. Concepts of biology 1st canadian edition. 2015.
- [26] U. Neves. Crescimento dos casos de hipertensão em jovens é preocupante no brasil, 2019.

- [27] E. A Nogueira. Aplicação de rede neural convolucional para a extração de características e classificação de falhas no motor de indução trifásico. 2020.
- [28] T. Papadopoulos, F. Bittencout, F. Leroy, et al. Redes neurais artificiais na predição do preço futuro de fechamento de papéis com alta e baixa volatilidade negociados na bovespa e na bolsa de valores de nova iorque. pages 873–884, 08 2016.
- [29] Physionet. The mimic-iii waveform database, 2020.
- [30] M. D. Polito and P. T. V. Farinatti. Considerações sobre a medida da pressão arterial em exercícios contra-resistência. Revista Brasileira de Medicina do Esporte, 9:25 – 33, 02 2003.
- [31] M. P. D. Pont. Plataforma de aquisição para fotoplestimografia com módulos de monitoramento. Dissertação de mestrado em engenharia elétrica, Universidade Federal de Santa Catarina, Florianópolis, SC, 2016.
- [32] C. C. Y. Poon, Y. M. Wong, and Y. Zhang. M-health: The development of cuffless and wearable blood pressure meters for use in body sensor networks. In 2006 IEEE/NLM Life Science Systems and Applications Workshop, pages 1–2, 2006.
- [33] S. Puke, T. Suzuki, K. Nakayama, et al. Blood pressure estimation from pulse wave velocity measured on the chest. Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference, 2013:6107–6110, 07 2013.
- [34] J. Readhead. Aprendizagem de máquinas: Como as máquinas de vetores de suporte podem ser utilizadas nas negociações, 2014.
- [35] C. I. S. Rodrigues, K. C. Ortega, A. M. G. Pierin, et al. Diagnóstico e classificação. Brazilian Journal of Nephrology, 32:05 – 13, 09 2010.
- [36] C. Seiffert, T. M. Khoshgoftaar, J. Van Hulse, et al. Rusboost: Improving classification performance when training data is skewed. In 2008 19th International Conference on Pattern Recognition, pages 1–4, 2008.
- [37] C. Seiffert, T. M. Khoshgoftaar, J. Van Hulse, et al. 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.
- [38] G. B. Silva. Sistema de monitormaento de pressão arterial. Master's thesis, Universidade Estadual de Londrina, Londrina, 2011.
- [39] G. V. Silva. Blood pressure variability: another puzzle piece. Brazilian Journal of Nephrology, 39:102 – 103, 06 2017.

- [40] D. U. Silverthorn. Fisiologia Humana: Uma abordagem integrada. Artmed, 7^a edition, 2017.
- [41] P. H. B. Souza. Método para estimação da frequência cardíaca e variabilidade cardíaca com base em fotopletismografia por vídeo. Dissertação de mestrado em engenharia biomédica, Universidade de Brasília, Brasília, DF, 2019.
- [42] Unicamp. 2 medição de dados experimentais, incerteza e propagação de erro.
- [43] L. Wang, W. Zhou, Y. Xing, et al. A novel neural network model for blood pressure estimation using photoplethesmography without electrocardiogram. *Journal of Healthcare Engineering*, 2018:1–9, 03 2018.
- [44] C. Yi, C. Jian, and J. Wenqiang. Continuous blood pressure measurement based on photoplethysmography. In 2019 14th IEEE International Conference on Electronic Measurement Instruments (ICEMI), pages 1656–1663, 2019.
- [45] Y. Zhang and Z. Feng. A sym method for continuous blood pressure estimation from a ppg signal. In *Proceedings of the 9th International Conference on Machine Learning and Computing*, ICMLC 2017, page 128–132, New York, NY, USA, 2017. Association for Computing Machinery.