

Detecção de Hipertensão Arterial usando Fotopletismografia e Aprendizado de Máquina

Douglas Henz, André Luís del Mestre Martins, Juliano Costa Machado, Fábio Pires Itturriet

douglashenz.ch078@academico.ifsul.edu.br, {andremartins,julianomachado,fabioitturriet}@ifsul.edu.br

Instituto Federal de Educação, Ciência e Tecnologia Sul-rio-grandense

Charqueadas, RS, Brazil

ABSTRACT

Hypertension is the leading cause of death worldwide, considering cardiovascular diseases. In its initial phase, it presents no symptoms and is usually diagnosed when it has already affected other organs. Continuous blood pressure monitoring allows the discovery of the first temporary and sporadic events of hypertension. This work proposes using the non-invasive photoplethysmography (PPG) signal in conjunction with machine learning techniques to detect hypertension events. Morphological information is extracted from signals acquired from a database fed to models trained with the k-Nearest Neighbors (kNN) and Support Vector Machines (SVM) techniques. As a result, models were obtained with an accuracy of up to $82,96 \pm 2,12(\%)$, F1-Score of up to $81,90 \pm 2,11(\%)$, and false negative rate of up to $17,30 \pm 2,90(\%)$ for the kNN technique and SVM models have obtained performances of $76,80 \pm 2,18(\%)$, $78,20 \pm 2,65(\%)$ and $3,60 \pm 3,48(\%)$ accuracy, F1-Score, and false negative rate, respectively.

KEYWORDS

Hypertension, Continuous Monitoring, photoplethysmography, Machine Learning

1 INTRODUÇÃO

As doenças cardiovasculares (DCVs) são a principal causa de morte por doença no mundo. Anualmente, ocorrem mais de 18 milhões de mortes no globo causadas por DCVs, das quais aproximadamente 9,96 milhões são associadas a elevação da pressão arterial (PA) [1]. A elevação da PA traz complicações que são associadas a 53% de todas as doenças e mortes relacionadas a DCVs no mundo e apesar dos esforços para o controle da hipertensão arterial (HA), a incidência tem crescido muito nos últimos anos, passando de 600 milhões de pessoas em 1980, para 1,3 bilhão em 2019 [1]. Em brasileiros de 18 anos ou mais residentes nas capitais do país, 26,3% já tem diagnosticado a HA, sendo 27,1% entre as mulheres e 25,4% entre homens [2].

A HA é uma doença crônica não transmissível caracterizada pela elevação persistente da PA Sistólica (PAS) e/ou PA Diastólica (PAD). Indivíduos com PAS maior ou igual a 140 mmHg e/ou PAD maior ou igual a 90 mmHg são diagnosticados como hipertensos e abaixo desses valores como normotensos [3]. Por ser uma doença assintomática e relativamente comum, muitas pessoas não sabem que tem a doença (28% das mulheres e 43% dos homens na América Latina e Caribe) [4]. Em sua fase inicial, geralmente não recebe o devido acompanhamento e os diagnósticos tardios ocorrem quando a doença já está estabelecida. Nesta fase, a HA é considerada como um dos maiores fatores de risco no desenvolvimento de acidente cerebral vascular isquêmico e hemorrágico, insuficiência cardíaca,

ataque cardíaco, doença arterial coronária e doença renal crônica [1, 3, 5, 6]. O diagnóstico precoce de HA torna-se primordial, pois permite um tratamento voltado apenas para mudança de hábitos cotidianos como aumento de exercícios físicos, redução no consumo de sal e suspensão no consumo de álcool e cigarro [7]. É realizado por um médico de acordo com um protocolo que consiste em aferições regulares de PA em consultas médicas de rotina. Em geral, essas aferições são realizadas manualmente por profissionais com um dispositivo específico chamado esfigmomanômetro em conjunto com um estetoscópio. No mercado também existem os aferidores automáticos e semiautomáticos de PA, de mais fácil utilização, porém demandam calibração periódica [5, 8, 9]. Ambas abordagens demandam repouso do paciente e apresentam resultados amostrais descontinuados e demorados gerando incerteza em aferições e diagnósticos [10].

Diante dos desdobramentos graves da HA e das limitações para diagnóstico precoce, o monitoramento contínuo de pressão arterial emerge como grande alternativa na detecção de HA. Oxímetros de dedo, *SmartBands* e *Smartwatches* são exemplos de dispositivos vestíveis que realizam a aquisição de sinais vitais continuamente. Em geral, todos estimam dados como a saturação do oxigênio do sangue arterial (SpO_2) e frequência cardíaca (FC) utilizando uma técnica óptica não invasiva chamada fotopletismografia (PPG). Com ela é possível acessar a variação de sangue nos tecidos vasculares durante o ciclo cardíaco, junto de diferentes parâmetros extraídos diretamente da forma de onda PPG [11]. A HA é um exemplo de DCV que modifica a morfologia do sinal elétrico da PPG devido sua ligação direta com o sistema circulatório [12].

O volume de dados gerado pelo monitoramento contínuo de sinais vitais se apresenta como oportunidade para o desenvolvimento de técnicas de inteligência artificial para predição e diagnóstico de doenças. Técnicas de *Machine Learning* supervisionado como *k-Nearest Neighbors* (kNN) e *Support Vector Machines* (SVM) se mostram com boa relação entre complexidade e desempenho para detecção de doenças em dispositivos vestíveis. A mudança na morfologia dos sinais de PPG em indivíduos com HA pode ser utilizada como base de treinamento para os modelos de detecção da doença.

O objetivo deste trabalho é propor um método de detecção de eventos de hipertensão arterial baseado no uso de sinais de fotopletismografia (PPG) através de técnicas de inteligência artificial possibilitando o monitoramento contínuo de pessoas utilizando dispositivos vestíveis.

Na Seção 2 são expostos trabalhos acadêmicos relacionados. Seção 3 traz toda a metodologia de pesquisa aplicada no presente trabalho, expondo todos os processos e etapas executadas. Seção 4 mostra os resultados dos experimentos efetuados no estudo, buscando

evidenciar os detalhes empregados em cada um dos experimentos. Por fim, Seção 5 conclui o trabalho e direciona trabalhos futuros.

2 TRABALHOS RELACIONADOS

Durante a etapa de pesquisa bibliográfica foram analisados artigos que apresentam técnicas de inteligência artificial para detecção de Hipertensão Arterial utilizando sinais de PPG.

No trabalho [13], é proposto uma abordagem utilizando a técnica de SVM para detecção de hipertensão arterial com base em PPG e dados clínicos. O estudo utiliza um conjunto de dados que combina características extraídas de sinais de PPG com informações clínicas dos pacientes, incluindo idade, sexo, índice de massa corporal (IMC) e histórico familiar de hipertensão. Os resultados obtidos mostraram uma acurácia de 71,42% e F1-Score de 76% na detecção de hipertensão arterial. No entanto, é destacado que combinar as características extraídas dos sinais PPG com as informações clínicas, não resultou em melhora se comparadas na utilização de cada um dos conjuntos separadamente, em termos de acurácia e F1-Score.

Em [14], o estudo concentra-se em utilizar a análise dos sinais de fotopleletismografia (PPG) como meio de avaliar três importantes indicadores de saúde: obesidade, faixa etária e hipertensão. O estudo explorou o potencial das características dos sinais de PPG, como amplitude, frequência cardíaca e variabilidade da frequência cardíaca, para identificar e avaliar essas condições de saúde. Para realizar essa análise, foram aplicadas técnicas de aprendizado de máquina, incluindo *kNN* e SVM. Os resultados mostraram que o modelo baseado em *kNN* alcançou uma acurácia de 92,2% na detecção de hipertensão, enquanto o modelo SVM obteve uma acurácia de 87,4%.

O trabalho de [15] avaliou a capacidade de algumas métricas extraídas do sinal da fotopleletismografia para classificar indivíduos entre três classes (hipertensos, normotensos e hipotensos) e estimar a pressão arterial média, sistólica e diastólica em pacientes críticos. Foram utilizados índices do domínio do tempo, da frequência e não lineares obtidos através do sinal PPG com resultados em torno de 70% de acurácia, 75% de especificidade e F1-Score de 50%. Neste trabalho também foram avaliados quais as melhores métricas para estimação e quais os métodos de inteligência artificial, dentre os principais utilizados no meio acadêmico, que tem o melhor desempenho.

Em [16], o autor estudou a relação entre características morfológicas do sinal PPG com a PAS. Neste trabalho foram exploradas 125 características da morfologia do sinal PPG, onde utilizando seis métodos de seleção de características, foi estabelecido que 10 delas haviam relação com a PAS. Após a seleção das características, foram avaliados alguns modelos de algoritmos como: *Linear Discriminant Analysis (LDA)*, *k-Nearest Neighbors (kNN)*, *Linear Regression (LR)* e *Support Vector Machines (SVM)*. Neste trabalho foram utilizadas três classes: normotenso, pré-hipertenso e hipertenso. Os autores reportaram F1-score de 72,97% para normotenso versus pré-hipertenso, 81,82% para normotenso e pré-hipertenso versus hipertenso, e 92,31% para normotenso versus hipertensos.

Baseado no contexto acadêmico previamente apresentado, as principais contribuições do trabalho são:

- Desenvolvimento de um método de treinamento que utiliza um algoritmo para a determinação das classes a partir dos

sinais de ABP, sem a necessidade de prévia análise médica dos sinais de PPG.

- Criação de dois cenários voltados para avaliação do Percentual de Ciclos Hipertensos (PCH) dentro da janela de análise.
- Exploração de espaço de projeto buscando pelas melhores características temporais para cada técnica e cenário criado.

3 METODOLOGIA

Nesta seção serão apresentados todos os passos que compõem a solução proposta ao problema de pesquisa previamente mostrado.

3.1 SELEÇÃO DOS SINAIS DE PPG

A base de dados escolhida foi a *PhysioBank* [17], que é uma plataforma de acesso livre que concentra milhares de registros de dados vitais e fisiológicos. Dentro dessa plataforma o banco de dados selecionado foi o MIMIC-III [18], contendo uma significativa variedade de sinais vitais, medicamentos, medições ambulatoriais, entre outros. Os sinais de PPG deste banco de dados foram captados através do método transmissivo em pacientes em repouso com frequência de amostragem de 125 Hz. Nessa base não há marcadores (*labels*) indicando se os indivíduos estão normotensos ou hipertensos. Entretanto, a base apresenta alguns registros de Pressão Arterial (em inglês, *Arterial Blood Pressure (ABP)*) sincronizados com os sinais de PPG. Esses sinais foram captados por um método invasivo, considerado o padrão ouro em medições de ABP [19], também com frequência de amostragem de 125 Hz. A busca foi realizada na plataforma *PhysioBank Record Search* [20], por registros contendo sinais específicos de ABP e PPG sincronizados.

3.2 SEPARAÇÃO DOS FRAMES NAS RESPECTIVAS CLASSES

A Figura 1 apresenta o fluxo de processamento que os sinais de ABP são submetidos para a separação dos sinais de PPG em cada classe. a) O ponto de partida é a segmentação dos sinais de PPG e ABP sincronizados em janelas, chamadas *frames*, com cinco minutos de duração conforme a Figura 1. Esse tempo é escolhido por ser considerado suficiente para refletir a dinâmica de curto prazo do sistema nervoso autônomo [15]. b) Posteriormente, o *frame* ABP passa por um filtro passa-baixas *Butterworth* de quarta ordem com frequência de corte de 12 Hz. c) Um algoritmo foi desenvolvido para analisar os *frames* de ABP visando identificar os ciclos cardíacos indicados por linhas verticais tracejadas em vermelho. d) Além disso, o algoritmo também busca por valores de PAS (máximos) e PAD (mínimos) em cada ciclo cardíaco. e) Caso os valores de PAS e PAD encontrados em cada ciclo cardíaco sejam de PAS ≥ 140 mmHg e/ou PAD ≥ 90 mmHg, o ciclo é considerado hipertenso (classe HIPER), caso contrário, o ciclo é considerado normotenso (classe NORMO). Um *frame* completo analisado pode conter centenas de ciclos cardíacos e a definição de sua classe depende da proporção entre ciclos normotensos e ciclos hipertensos. f) Essa proporção é formalizada no trabalho como o Percentual de Ciclos Hipertensos (PCH) e representa a relação de ciclos hipertensos em relação ao número total de ciclos do *frame* analisado. g) No exemplo da Figura, o PCH foi definido arbitrariamente em 51%, ou seja, todos os *frames* que tiverem entre 51 e 100% do ciclos cardíacos hipertensos, serão

considerados da classe HIPER. Caso contrário, serão considerados da classe NORMO.

A Figura 2 apresenta um exemplo de *frame* de ABP com um total de 412 ciclos cardíacos identificados, sendo que destes 388 foram classificados como ciclos hipertensos, totalizando uma taxa de 94% do total de ciclos. Nesse caso, esse *frame* seria considerado da classe HIPER apenas se o PCH estivesse definido entre 51 e 94%. Ao final dessa etapa, todos os *frames* de PPG ficam selecionados em uma das duas classes.

3.3 EXTRAÇÃO DE CARACTERÍSTICAS

Os *frames* PPG previamente classificados são inicialmente processados por um filtro Passa baixas do tipo *Chebyshev* Tipo II de ordem 4, com frequência de corte em 12 Hz [21–23]. Após a filtragem, todos os ciclos cardíacos são identificados no *frame* baseado nos valores mínimos e máximos do sinal de PPG. Com esta identificação, as características morfológicas são extraídas em cada ciclo do *frame* e uma média com os valores obtidos é realizada, gerando um único valor para cada métrica representando o *frame* analisado. Depois das características extraídas de todos os *frames*, as mesmas são normalizadas e organizadas na forma de uma matriz composta de m colunas (número de características) por n linhas (número de *frames* analisados). As sete características morfológicas temporais utilizadas neste trabalho foram selecionadas com base nas mais utilizadas nos trabalhos relacionados [15, 16, 24–26]. As características utilizadas são:

AVG é a duração média dos intervalos entre batimentos no período analisado, definida na Equação 1, onde *IBI* são os intervalos entre batimentos cardíacos.

$$AVG = \frac{1}{N} \sum_{i=1}^N IBI(i) \quad (1)$$

SDNN é definida como o desvio padrão dos intervalos entre batimentos e sua definição pode ser vista em Equação 2.

$$SDNN = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |IBI(i) - AVG|^2} \quad (2)$$

RMSSD é a valor quadrático médio das diferenças sucessivas dos intervalos entre batimentos, definido pela Equação 3.

$$RMSSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} |IBI(i+1) - IBI(i)|^2} \quad (3)$$

NN50 é o número de diferenças entre intervalos sucessivos entre batimentos que sejam maiores que 50 ms, definido na Equação 4. A variável δ assumirá valor igual a 1 quando a condição for atendida, caso contrário, é igual a 0.

$$NN50 = \sum_{i=1}^{N-1} \delta(|IBI(i+1) - IBI(i)| \geq 50ms) \quad (4)$$

pNN50 é a proporção do número de diferenças entre intervalos sucessivos entre batimentos maiores que 50 ms, com o número total de batimentos do período analisado, definido na Equação 5.

$$pNN50 = \frac{NN50}{N-1} \quad (5)$$

SD2 é a dispersão de Poincaré ao longo da linha de identidade do gráfico e é definida na Equação 6

$$SD2 = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} \frac{(IBI(i+1) - IBI(i) - \overline{IBI})^2}{2}} \quad (6)$$

COM é definida como a soma normalizada das distâncias entre cada ponto do gráfico de Poincaré e seu centroide, representado na Equação 7.

$$COM = \frac{\sum_{i=1}^{N-1} |IBI(i+1) - IBI(i)|^2}{N-1} \quad (7)$$

3.4 ALGORITMOS DE APRENDIZADO DE MÁQUINA

O uso de técnicas de aprendizado de máquina, como o *kNN* e *SVM*, tem sido amplamente empregado na análise de sinais de PPG para detecção de condições de saúde, como hipertensão [27]. Essas técnicas são reconhecidas por sua eficácia na classificação de dados e têm sido aplicadas em diversas áreas biomédicas. Estudos anteriores, como os de [15] e [28], demonstraram a utilidade do *kNN* e do *SVM* na análise de dados de PPG, fornecendo resultados confiáveis e precisos na detecção de hipertensão arterial. Além disso, o *kNN* e o *SVM* são algoritmos bem estabelecidos e amplamente utilizados em problemas de classificação devido à sua simplicidade e interpretabilidade [29]. Essas características os tornam adequados para aplicação em estudos que visam a detecção de hipertensão com base em sinais de PPG. Portanto, a escolha dessas técnicas neste estudo é fundamentada em sua capacidade de lidar com problemas de classificação em sinais de PPG, sua eficácia na detecção de hipertensão e sua aceitação no meio científico.

O princípio de funcionamento do algoritmo *kNN* baseia-se no cálculo das distâncias entre o objeto a ser classificado e um conjunto de objetos previamente conhecidos e distribuídos em suas respectivas classes [30]. Os hiperparâmetros dessa técnica são o valor k , ou o tamanho do grupo cuja distância da amostra é comparada, o cálculo da distância, o peso da distância e também a quantidade de características utilizadas. Existem diversas maneiras de calcular a distância da amostra para o grupo, sendo a mais utilizada a Euclidiana, também utilizada nesse trabalho.

O *SVM* é também um algoritmo de aprendizado de máquina supervisionado utilizado originalmente para problemas de classificação binária, podendo ser expandido para multiclases. A ideia principal por trás do *SVM* é encontrar um hiperplano que melhor separe os dados em classes distintas [31]. Para o conjunto de treinamento, os dados são representados por um vetor de características (atributos) e suas classes correspondentes. O *SVM* utiliza o conceito de função *kernel* para mapear os dados de entrada para um espaço de maior dimensionalidade, onde é mais fácil encontrar um hiperplano que separe as classes.

Existem diferentes tipos de funções *kernels*, como o Linear, Polinomial e o *RBF* (*Radial Basis Function*), entre outras [32]. A função *kernel* Linear é a mais simples e direta, calculando o produto escalar entre os dois vetores de entrada. O *kernel* Polinomial mapeia os

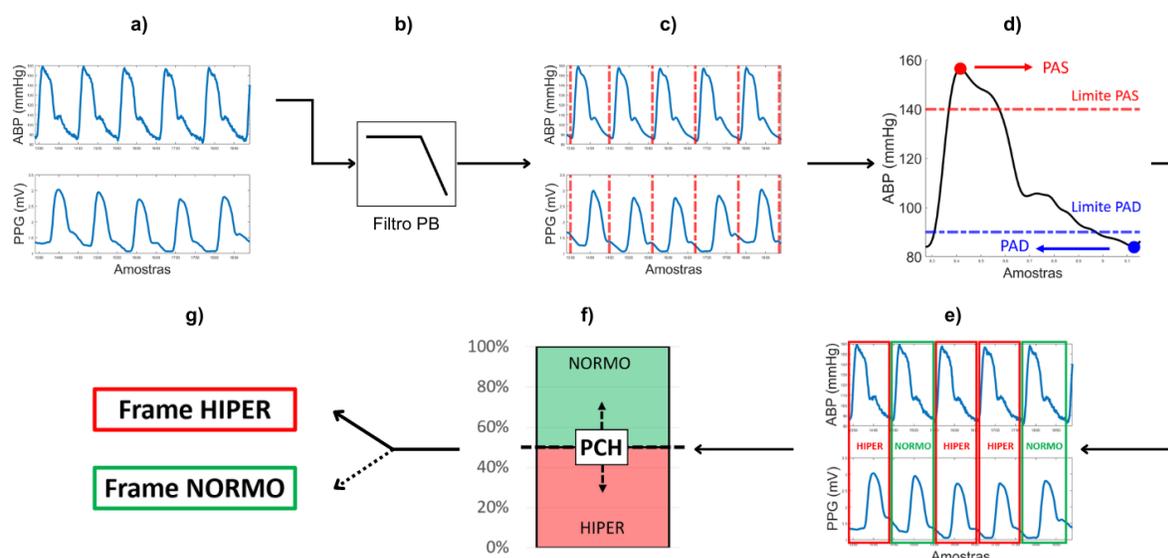


Figura 1: Fluxo dos processos em que o sinal ABP é submetido. a) Registros com sinais ABP e PPG sincronizados. b) Filtragem do sinal ABP. c) Identificação dos ciclos cardíacos. d) Extração dos valores de PAS e PAD de cada ciclo cardíaco e verificação dos limites. f) Com todos os ciclos definidos, é verificada a PCH. g) Caso o percentual de ciclos hipertensos seja maior ou igual ao PCH o *frame* (ABP e PPG) são classificados como HIPER.

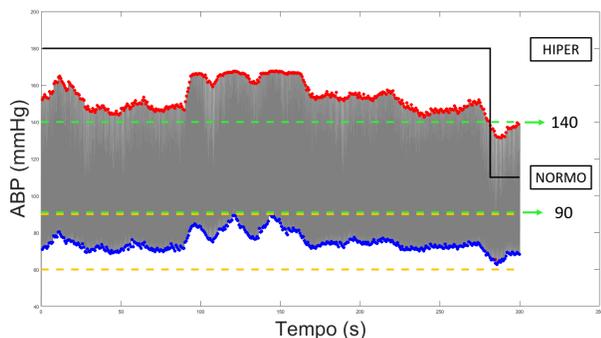


Figura 2: Exemplo de um *frame* de ABP classificado (cinza) com as faixas de valores normais para PA sistólica (verde) e diastólica (laranja) e o resultado da classificação (preto). O resultado é um vetor em que cada posição, representa a classe de um ciclo cardíaco.

dados de entrada para um espaço de maior dimensão usando uma função polinomial e por fim, a função *RBF* mapeia os dados de entrada em um espaço dimensional infinito e assume a forma de uma distribuição gaussiana, permitindo hiperplanos mais complexos.

Na etapa de treinamento, o *SVM* busca encontrar o hiperplano que melhor separa as classes, onde o objetivo é maximizar a margem, que é a distância entre o hiperplano e os pontos mais próximos de cada classe, chamados de vetores de suporte (*support vectors*). Após o treinamento, o *SVM* pode ser usado para classificar novos exemplos, calculando a posição do exemplo em relação ao hiperplano e atribuindo a ele uma classe com base em sua posição relativa.

3.5 MÉTRICAS DE AVALIAÇÃO DO DETECTOR

Para evitar dependência do grupo de treinamento, os escores de classificação serão realizados através da média de uma validação cruzada do tipo *k-fold*, com $k = 10$, significando que os dados para treino e teste são separados em 10 porções, onde 9 são utilizadas para treino e a restante para classificação, repetindo 10 vezes esse processo sempre com um conjunto de treino diferente [33].

Os resultados serão apresentados em uma matriz confusão através dos Verdadeiros Positivos (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN). No contexto deste trabalho, a classe positivo é a classe HIPER, que representa os *frames* hipertensos, já a classe negativa é a NORMO, que são os *frames* normotensos.

A partir dos resultados obtidos pela matriz confusão, será avaliada a Acurácia (ACC) geral do classificador, ou seja, a proporção de VP e VN em relação ao conjunto total de teste.

A Taxa de Falsos Negativos (TFN) é a razão entre os Falsos Negativos com a soma de Falsos Negativos e Verdadeiros Positivos e no contexto deste trabalho merece uma atenção especial. FNs aqui são amostras da classe hipertensa que foram classificadas como normotensa e no caso da hipertensão isto é um problema, por tratar-se de uma doença que normalmente já tem diagnóstico tardio em função de ser assintomática.

Outras métricas de performance *Precisão (PRE)* e *Recall/Revocação (REC)* estão relacionadas aos VP e VN. A *PRE* pode ser resumida como quantas classificações estão corretas, dentre todas as Positivas, já a *REC* se resume em quantas classificações estão corretas, dentre todas as situações em Positivos com valor esperado.

Por fim, o *F1-Score (F1)* é uma das métricas de performance mais utilizadas na avaliação de modelos. Este índice é uma combinação de *PRE* e *REC*, sendo calculado através da média harmônica entre

os mesmos. Um F1-Score é um indicativo de que ou a precisão ou a *recall* está baixo, fornecendo assim uma medida um pouco mais completa do que a acurácia.

4 RESULTADOS E DISCUSSÕES

A presente seção apresentará os resultados e discussões deste trabalho. A subseção 4.1 descreve todos os critérios selecionados e parâmetros utilizados para os experimentos. Na subseção 4.2, será avaliado os resultados da seleção das características extraídas dos sinais. Por fim, as métricas de desempenho dos modelos treinados são expostos na subseção 4.3, em conjunto de sua discussão.

4.1 SETUP EXPERIMENTAL

A busca por sinais de ABP e PPG sincronizados apresentada na Seção 3.1 retornou 6600 registros. Uma análise mais detalhada mostrou inúmeros registros corrompidos, deturpados com ruído e até mesmo com a falta de um dos sinais (ABP ou PPG). A baixa confiabilidade na base de dados escolhida exigiu uma verificação na integridade dos registros selecionados. Dentre eles, apenas 299 registros de indivíduos contendo ABP e PPG sincronizados com 1 hora de duração atenderam esses requisitos. Cada registro corresponde a um indivíduo diferente e foram segmentados em *frames* de 5 minutos, totalizando 3256 *frames*.

Com os sinais segmentados, partiu-se para a etapa de classificação com o auxílio do sinal de ABP. Nesta etapa cada um dos *frames* foi submetido à sequência de processos exposto na Figura 2 e apresentados na Seção 3.2. A classificação dos 3256 *frames* depende do PCH determinado durante a execução do experimento. Os dois cenários criados foram *i*) PCH = 50% (50+), onde no mínimo metade dos ciclos são da classe HIPER e *ii*) PCH = 90% (90+) onde no mínimo 90% dos ciclos são da classe HIPER. Fisiologicamente, o cenário 50+ seria correspondente a mapear indivíduos pré-hipertensos (fase inicial da Hipertensão arterial) pois a medida que PAS e PAD se aproximam do limiar 140mmHg e/ou 90mmHg, respectivamente, oscilações poderiam ser captadas pelo detector. Já o cenário 90+ poderia indicar indivíduos cuja doença encontra-se estabelecida servindo como métrica, por exemplo, para a avaliação da eficácia das medicações para redução da pressão arterial (anti-hipertensivos) que naturalmente diminuem ao longo do tempo.

Por serem mais difíceis de encontrar, os *frames* 90+ determinaram o total dos conjuntos de dados utilizados nos dois cenários. O total de *frames* utilizados em cada um dos dois cenários foi de 900, distribuídos em 450 para a classe HIPER e 450 para a classe NORMO.

4.2 SELEÇÃO DE CARACTERÍSTICAS

Em cada um dos dois cenários (50+ e 90+), as sete características exploradas na Seção 3.3 foram extraídas de cada *frame*. Todas as características extraídas foram normalizadas e tabeladas de acordo com sua classe, e então partiu-se para o treinamento e avaliação do desempenho das diversas combinações das mesmas. Para isto, foram executadas todas as combinações de características para então utilizá-las no treinamento dos modelos, sendo que no total foram avaliadas 120 combinações utilizando as métricas citadas na Seção 3.5. Os resultados foram selecionados com base na maior

média das *k-folds* de cada combinação possível e para cada valor de *k* na técnica *kNN* e para cada função *kernel* na técnica *SVM*.

As Tabelas 1 e 2 apresentam as combinações de características (indicadas pelo símbolo ●) que obtiveram as maiores médias (μ) de ACC e F1 e menores médias (μ) de TFN de *k-folds* para os modelos utilizando a técnica *kNN* para diferentes valores de *k* nos cenários 50+ e 90+ respectivamente.

As Tabelas 3 e 4 apresentam as combinações de características (indicadas pelo símbolo ●) que obtiveram as maiores médias (μ) de ACC e F1 e menores médias (μ) de TFN de *k-folds* para os modelos utilizando a técnica *SVM* linear, *SVM* com *kernel* RBF com valores de $\sigma=\{0.5, 1, 1.5, 2\}$ e *SVM kernel* Polinomial variando a ordem do polinômio $n=\{4, 6, 8, 10\}$ nos cenários 50+ e 90+ respectivamente. Os parâmetros das funções *kernel* foram estipulados baseados nos trabalhos relacionados.

4.3 AVALIAÇÃO DE DESEMPENHO

Os resultados mostrados nas Tabelas 1, 2, 3 e 4 são apresentados graficamente na Figura 3, permitindo uma comparação visual entre as técnicas sob a ótica de cada métrica em cada cenário. Para a técnica *kNN*, a legenda é composta pela letra *K* seguida do valor de *k* utilizado enquanto que a legenda criada para o *SVM* é mostrada na Tabela 5.

A seleção de características proposta na seção 4.2 do trabalho apresentou melhores resultados nas métricas ACC e F1 para as técnicas *kNN*, *SVM* linear e *SVM* com *kernel* RBF e mostrou-se mais evidente no cenário 50+. Para o *SVM* com *kernel* Polinomial, os resultados médios de ACC e F1 foram praticamente os mesmos em ambos os cenários, com exceção da métrica F1 no cenário 50+, com uma sutil diferença em favor do uso de características selecionadas. Levando em conta a ACC e F1, o melhor desempenho foi alcançado no cenário 90+ para o *kNN* com $k = 3$ com médias e desvios-padrão de $82,96 \pm 2,12(\%)$ e $81,90 \pm 2,11(\%)$, respectivamente. Em ambas as métricas apenas a característica COM não foi utilizada, indicando que ela não apresenta relevância neste experimento.

Para a métrica TFN, a seleção de características não apresentou uma melhoria significativa para o *kNN* em ambos os cenários. Para o *SVM* essa diferença mostra-se mais aparente, principalmente no cenário 50+. O melhor resultado foi obtido através da técnica *SVM* (função *kernel* RBF, $\sigma = 2.0$ - SVM5) com média e desvio-padrão de $6,90 \pm 2,75(\%)$ no cenário 50+ utilizando apenas as características SDNN e COM.

5 CONCLUSÕES E TRABALHOS FUTUROS

O objetivo deste trabalho foi propor um método de detecção de eventos de hipertensão em pacientes, baseado no uso da Fotoplethismografia e técnicas de aprendizado de máquina. Os resultados obtidos mostram um promissor caminho para a detecção destes eventos utilizando características temporais extraídas do sinal PPG. Esse sinal é amplamente utilizado em dispositivos vestíveis mostrando o potencial comercial da solução.

Em geral, os resultados apontaram a importância da seleção adequada de características para modelos *kNN* e *SVM*, bem como a influência dos diferentes cenários na performance dos modelos. Ademais, em geral os modelos *kNNs* necessitaram de mais características para atingir os melhores resultados. Essas conclusões

Tabela 1: Cenário 50+ *kNN* - Combinações de características que resultaram nos maiores valores de μ para as métricas de Acurácia e F1-Score, bem como os menores médias para Taxa de Falsos Negativos. Na tabela é exibida a combinação específica para cada valor de *k* em conjunto com os valores de μ e desvio-padrão (DP) da métrica.

Características	Acurácia (ACC)								F1-Score (F1)								Taxa de Falsos Negativos (TFN)								
	k								k								k								
	1	3	5	7	9	11	13	15	1	3	5	7	9	11	13	15	1	3	5	7	9	11	13	15	
AVG	•	•	•	•	•	•	•	•	•	•	•	•	•	•	•	•	-	•	•	•	•	•	•	•	•
SDNN	•	•	-	•	-	-	•	-	•	•	-	•	•	-	•	•	-	•	•	•	•	-	-	-	-
RMSSD	-	-	•	-	-	-	-	-	-	-	•	-	-	-	-	-	-	-	-	-	•	•	•	•	•
NN50	•	-	•	•	•	•	-	•	•	-	•	•	•	•	-	-	-	-	-	-	•	•	•	•	•
pNN50	•	•	•	•	•	-	-	•	•	•	•	-	-	-	-	-	-	-	-	-	-	•	•	•	•
COM	•	•	-	•	•	•	-	•	•	•	-	•	-	•	•	•	•	-	-	-	•	•	•	•	•
SD2	•	•	•	•	•	•	•	•	•	•	•	•	•	•	•	•	•	-	-	-	•	•	•	•	•
μ (%)	77,1	77,5	76,3	74,9	73,4	72,7	70,8	69,7	76,8	77,4	75,9	74,2	73,0	71,8	71,7	69,9	32,4	30,4	30,9	29,3	30,9	31,5	33,3	36,0	
DP (%)	1,37	2,06	2,61	1,37	1,42	2,45	4,26	3,15	0,97	1,54	2,45	1,66	2,04	2,82	3,71	3,71	4,78	4,48	4,48	4,48	2,28	5,09	5,09	5,09	

Tabela 2: Cenário 90+ *kNN* - Combinações de características que resultaram nos maiores valores de μ para as métricas de Acurácia e F1-Score, bem como os menores valores para Taxa de Falsos Negativos. Na tabela é exibida a combinação específica para cada valor de *k* em conjunto com os valores de μ e desvio-padrão (DP) da métrica.

Características	Acurácia (ACC)								F1-Score (F1)								Taxa de Falsos Negativos (TFN)								
	k								k								k								
	1	3	5	7	9	11	13	15	1	3	5	7	9	11	13	15	1	3	5	7	9	11	13	15	
AVG	•	•	•	•	•	•	•	•	•	•	•	•	•	•	•	•	•	-	•	•	•	•	-	•	•
SDNN	•	•	-	-	•	-	-	-	•	•	•	-	-	-	-	-	-	-	-	-	-	-	-	-	-
RMSSD	•	•	•	•	•	•	•	•	•	•	-	•	•	•	•	•	-	-	-	-	•	•	•	•	•
NN50	•	•	•	-	-	•	•	•	•	•	•	-	-	•	•	•	-	-	-	•	•	-	•	•	•
pNN50	•	•	•	•	•	•	•	-	•	•	•	•	•	•	•	•	•	-	-	-	•	•	-	•	•
COM	-	-	-	•	-	-	-	•	-	-	•	•	-	-	-	•	-	-	-	•	•	-	•	•	•
SD2	•	•	•	•	•	•	•	•	•	•	-	•	•	•	•	-	-	•	-	•	•	•	•	•	•
μ (%)	82,5	84,7	84,3	83,4	83,3	83,1	81,1	81,3	82,4	84,5	84,1	83,7	83,6	83,5	81,6	81,8	22,9	21,5	19,3	19,8	20,0	19,3	18,9	17,3	
DP (%)	2,18	2,38	1,59	2,11	2,11	2,10	2,12	2,38	2,38	2,36	1,49	2,08	2,08	2,09	2,10	2,37	5,37	4,88	4,89	3,25	2,93	4,88	2,93	2,90	

Tabela 3: Cenário 50+ *SVM* - Combinações de características que resultaram nos maiores valores de μ para as métricas de Acurácia e F1-Score, bem como os menores valores para Taxa de Falsos Negativos. Na tabela é exibida a combinação específica para cada função *kernel* em conjunto com os valores de μ e desvio-padrão (DP) da métrica.

Caract.	Acurácia (ACC)										F1-Score (F1)										Taxa de Falsos Negativos (TFN)									
	RBF					Polinomial					RBF					Polinomial					RBF					Polinomial				
	Linear	$\sigma = 0.5$	$\sigma = 1.0$	$\sigma = 1.5$	$\sigma = 2.0$	n = 4	n = 6	n = 8	n = 10	Linear	$\sigma = 0.5$	$\sigma = 1.0$	$\sigma = 1.5$	$\sigma = 2.0$	n = 4	n = 6	n = 8	n = 10	Linear	$\sigma = 0.5$	$\sigma = 1.0$	$\sigma = 1.5$	$\sigma = 2.0$	n = 4	n = 6	n = 8	n = 10			
AVG	•	-	•	•	•	•	•	•	•	-	-	-	-	-	•	-	-	-	-	-	-	-	-	-	-	-	-			
SDNN	-	•	-	-	•	•	•	•	-	•	•	-	-	-	•	•	•	•	-	•	•	-	•	•	-	•	•			
RMSSD	-	-	•	-	-	-	•	•	-	-	-	-	-	-	•	-	-	-	-	•	-	-	-	-	•	•	•			
NN50	-	-	-	-	-	-	-	•	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	•	•	•			
pNN50	-	-	•	-	-	•	•	•	•	-	-	-	-	-	•	•	•	•	-	-	-	-	-	-	-	-	-			
COM	-	-	-	•	-	-	•	•	•	-	-	-	•	•	•	•	-	-	•	•	•	•	•	•	•	•	-			
SD2	•	•	•	-	•	•	•	-	•	•	•	-	•	•	•	•	•	•	•	-	-	•	-	•	-	-	-			
μ (%)	60,3	63,1	62,9	61,8	61,7	62,8	63,6	66,6	67,4	65,7	65,1	64,6	67,4	66,1	66,9	66,3	69,1	70,0	6,9	19,5	17,3	8,22	3,6	15,6	16,4	16,2	15,8			
DP (%)	1,29	1,37	2,91	1,03	1,29	4,16	3,68	3,90	4,38	2,20	2,20	6,73	0,35	1,21	5,78	3,52	8,08	8,47	2,75	5,75	3,48	2,75	3,48	5,68	5,32	6,98	11,45			

Tabela 5: Tabela com a legenda do SVM com respectivo Kernel e parâmetros.

Legenda	kernel	Parâmetro	Legenda	kernel	Parâmetro
SVM1	Linear	-	SVM6	Poli.	$n = 4$
SVM2	RBF	$\sigma = 0.5$	SVM7	Poli.	$n = 6$
SVM3	RBF	$\sigma = 1.0$	SVM8	Poli.	$n = 8$
SVM4	RBF	$\sigma = 1.5$	SVM9	Poli.	$n = 10$
SVM5	RBF	$\sigma = 2.0$			

Com base nos resultados e conclusões apresentadas neste trabalho, algumas possibilidades de trabalhos futuros são:

- Investigar outros algoritmos de classificação;
- Explorar *frames* com durações diferentes;
- Incorporar índices de qualidade para descartar *frames* com alta incidência de ruído;
- Colaborar com especialistas clínicos para avaliar a solução proposta.
- Realizar uma análise dos dados experimentais de forma mais robusta através do uso de ferramentas estatísticas.

REFERÊNCIAS

- [1] World Heart Federation (WHF). Roadmap for hypertension. Disponível em: <https://world-heart-federation.org/cvd-roadmaps/whf-global-roadmaps/hypertension/>. Acesso em: 15 fevereiro de 2023, 2021.
- [2] Vigilte Brasil 2021 - estimativas sobre frequência e distribuição sociodemográficas de fatores de risco e proteção para doenças crônicas. Disponível em: <https://www.gov.br/saude/pt-br/centrais-de-conteudo/publicacoes/publicacoes-svs/vigilte/vigilte-brasil-2021-estimativas-sobre-frequencia-e-distribuicao-sociodemografica-de-fatores-de-risco-e-protacao-para-doencas-cronicas/view>. Acesso em: 27 setembro de 2022, 2021.
- [3] Weimar Kunz Sebba Barroso, Cibele Isaac Saad Rodrigues, Luiz Aparecido Bortolotto, Marco Antônio Mota-Gomes, Andréa Araujo Brandão, Audes Diógenes de Magalhães Feitosa, Carlos Alberto Machado, Carlos Eduardo Poli-de Figueiredo, Celso Amodeo, Décio Mion Júnior, et al. Diretrizes brasileiras de hipertensão arterial-2020. *Arquivos Brasileiros de Cardiologia*, 116:516-658, 2021.
- [4] Organização Pan-América de Saúde OPAS. Doenças cardiovasculares continuam sendo principal causa de morte nas Américas. Disponível em: <https://www.paho.org/pt/campanhas/dia-mundial-da-hipertensao-2022>. Acesso em: 28 setembro de 2022, 2021.
- [5] Tasbiraha Athaya and Sunwoong Choi. An estimation method of continuous non-invasive arterial blood pressure waveform using photoplethysmography: A u-net architecture-based approach. *Sensors*, 21(5):1867, 2021.
- [6] Thomas Unger, Claudio Borghi, Fadi Charchar, Nadia A Khan, Neil R Poulter, Dorairaj Prabhakaran, Agustin Ramirez, Markus Schlaich, George S Stergiou, Maciej Tomaszewski, et al. 2020 international society of hypertension global hypertension practice guidelines. *Hypertension*, 75(6):1334-1357, 2020.
- [7] FDA U.S. Food & Drug Administration. High blood pressure—understanding the silent killer. Disponível em: <https://www.fda.gov/drugs/special-features/high-blood-pressure-understanding-silent-killer>. Acesso em: 05 de Outubro de 2022, 2022.
- [8] Jay A Pandit, Enrique Lores, and Daniel Battle. Cuffless blood pressure monitoring: promises and challenges. *Clinical Journal of the American Society of Nephrology*, 15(10):1531-1538, 2020.
- [9] Daichi Shimbo, Marwah Abdalla, Louise Falzon, Raymond R Townsend, and Paul Muntner. Role of ambulatory and home blood pressure monitoring in clinical practice: a narrative review. *Annals of internal medicine*, 163(9):691-700, 2015.
- [10] Manuja Sharma, Karinne Barbosa, Victor Ho, Devon Griggs, Tadesse Ghirmai, Sandeep K Krishnan, Tzung K Hsiai, Jung-Chih Chiao, and Hung Cao. Cuffless and continuous blood pressure monitoring: a methodological review. *Technologies*, 5(2):21, 2017.
- [11] Panicos A Kyriacou and John Allen. Photoplethysmography: Technology, signal analysis and applications. 2021.
- [12] Mohamed Elgendi, Richard Fletcher, Yongbo Liang, Newton Howard, Nigel H Lovell, Derek Abbott, Kenneth Lim, and Rabab Ward. The use of photoplethysmography for assessing hypertension. *NPJ digital medicine*, 2(1):60, 2019.
- [13] Erick Martínez-Ríos, Luis Montesinos, and Mariel Alfaro-Ponce. A machine learning approach for hypertension detection based on photoplethysmography and clinical data. *Computers in Biology and Medicine*, 145:105479, 2022.
- [14] Hany Ferdinando, Matti Huotari, and Teemu Myllylä. Photoplethysmography signal analysis to assess obesity, age group and hypertension. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 5572-5575. IEEE, 2019.
- [15] Elisa Mejía-Mejía, James M May, Mohamed Elgendi, and Panayiotis A Kyriacou. Classification of blood pressure in critically ill patients using photoplethysmography and machine learning. *Computer Methods and Programs in Biomedicine*, 208:106222, 2021.
- [16] Yongbo Liang, Zhencheng Chen, Rabab Ward, and Mohamed Elgendi. Hypertension assessment using photoplethysmography: a risk stratification approach. *Journal of clinical medicine*, 8(1):12, 2018.
- [17] PhysioBank. PhysioBank databases. Disponível em: <https://archive.physionet.org/physiobank/>. Acesso em: 28 setembro de 2022, 2022.
- [18] Alistair EW Johnson, Tom J Pollard, Lu Shen, Li-wei H Lehman, Mengling Feng, Mohammad Ghassemi, Benjamin Moody, Peter Szolovits, Leo Anthony Celi, and Roger G Mark. Mimic-iii, a freely accessible critical care database. *Scientific data*, 3(1):1-9, 2016.
- [19] Kathrina B Siaron, Michaela X Cortes, Sonja E Stutzman, Aardhra Venkatachalam, Khalid Mohamed Ahmed, and DaiWai M Olson. Blood pressure measurements are site dependent in a cohort of patients with neurological illness. *Scientific reports*, 10(1):1-7, 2020.
- [20] PhysioBank. PhysioBank record search. Disponível em: <https://archive.physionet.org/cgi-bin/pbs/pbsearch>. Acesso em: 30 de setembro de 2022, 2022.
- [21] Yongbo Liang, Mohamed Elgendi, Zhencheng Chen, and Rabab Ward. An optimal filter for short photoplethysmogram signals. *Scientific data*, 5(1):1-12, 2018.
- [22] Khawaja Taimoor Tanweer, Syed Rafay Hasan, and Awais Mehmood Kamboh. Motion artifact reduction from ppg signals during intense exercise using filtered x-lms. In *2017 IEEE international symposium on circuits and systems (ISCAS)*, pages 1-4. IEEE, 2017.
- [23] M Raghu Ram, K Venu Madhav, E Hari Krishna, Nagarjuna Reddy Komalla, and K Ashoka Reddy. A novel approach for motion artifact reduction in ppg signals based on as-lms adaptive filter. *IEEE Transactions on Instrumentation and Measurement*, 61(5):1445-1457, 2011.
- [24] Jingjie Feng, Zhongyi Huang, Congcong Zhou, and Xuesong Ye. Study of continuous blood pressure estimation based on pulse transit time, heart rate and photoplethysmography-derived hemodynamic covariates. *Australasian physical & engineering sciences in medicine*, 41:403-413, 2018.
- [25] Paul S Addison. Slope transit time (stt): A pulse transit time proxy requiring only a single signal fiducial point. *IEEE Transactions on Biomedical Engineering*, 63(11):2441-2444, 2016.
- [26] Yongbo Liang, Zhencheng Chen, Rabab Ward, and Mohamed Elgendi. Hypertension assessment via ecg and ppg signals: An evaluation using mimic database. *Diagnostics*, 8(3):65, 2018.
- [27] Gabriel FS Silva, Thales P Fagundes, Bruno C Teixeira, and Alexandre DP Chiavegatto Filho. Machine learning for hypertension prediction: a systematic review. *Current Hypertension Reports*, 24(11):523-533, 2022.
- [28] Yue Zhang and Zhimeng Feng. A svm method for continuous blood pressure estimation from a ppg signal. In *Proceedings of the 9th international conference on machine learning and computing*, pages 128-132, 2017.
- [29] Christopher M Bishop and Nasser M Nasrabadi. *Pattern recognition and machine learning*, volume 4. Springer, 2006.
- [30] Zhi-Hua Zhou. *Machine learning*. Springer Nature, 2021.
- [31] Peter Harrington. *Machine learning in action*. Simon and Schuster, 2012.
- [32] Alex J Smola and Bernhard Schölkopf. *Learning with kernels*, volume 4. Citeseer, 1998.
- [33] Sebastian Raschka and Vahid Mirjalili. *Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2*. Packt Publishing Ltd, 2019.