

Biomarcador Acústico de Hipertensão Arterial: Avaliação da Viabilidade da Detecção por Sinais de Fonocardiograma e Classificação Binária

Gustavo Esmanhotto Baretta
Universidade Tecnológica Federal do
Paraná (UTFPR)
Curitiba, PR, Brazil

Wemerson Delcio Parreira
Pontifícia Universidade Católica de
Campinas (PUC-Campinas),
Escola Politécnica
Campinas, SP, BRA

Renata Coelho Borges
Universidade Tecnológica Federal do
Paraná (UTFPR)
Programa de Pós-Graduação em
Engenharia Biomédica (PPGEB)
Curitiba, PR, BRA

José Jair Alves Mendes Júnior
Universidade Tecnológica Federal do
Paraná (UTFPR)
Curitiba, PR, Brazil

Fábio Pires Itturriet
Universidade Tecnológica Federal do
Paraná (UTFPR)
Programa de Pós-Graduação em
Engenharia Biomédica (PPGEB)
Curitiba, PR, Brazil

ABSTRACT

This study investigates the feasibility of using phonocardiogram (PCG) signals to support the early identification of pre-hypertension through supervised machine learning. Hypertension induces subtle mechanical changes in the cardiac cycle, affecting the acoustic properties of heart sounds (S1 and S2) and the timing of systole and diastole. Using a dataset of 78 participants, we extracted temporal, spectral, and statistical features from raw PCG recordings using the TSFRESH library. Correlation-based Feature Selection (CFS) was applied to identify relevant attributes. Several classification models were evaluated to distinguish between normotensive and pre-hypertensive/hypertensive subjects. The Logistic Regression model achieved the most consistent baseline performance, with an accuracy of 62.54% and an AUC of 0.62. While preliminary, these results suggest that PCG signals contain latent information correlated with blood pressure levels. This reinforces PCG's potential as a low-cost, passive, and non-invasive screening tool for cardiovascular monitoring, warranting further research into advanced signal processing to enhance predictive power.

KEYWORDS

Pre-hypertension detection, Phonocardiogram (PCG), Machine Learning, Feasibility Study

1 INTRODUÇÃO

A hipertensão arterial (HA) permanece um dos desafios mais críticos da saúde pública global, figurando como o principal fator de risco modificável para doenças cardiovasculares (DCVs) [1]. Devido à sua natureza frequentemente assintomática, uma grande parcela da população desconhece sua condição, tornando-a uma doença perigosamente subdiagnosticada [2, 3].

O diagnóstico precoce é o pilar fundamental para evitar desfechos graves, permitindo intervenções no estilo de vida antes que a terapia medicamentosa se torne indispensável [4]. Tradicionalmente, esse diagnóstico depende da esfigmomanometria (o uso do

manguito inflável), seja em consultório, seja por meio de métodos de monitorização ambulatorial (MAPA) e residencial (MRPA) [5]. Embora seja considerado o padrão-ouro, apresenta uma limitação intrínseca: a descontinuidade. O processo de inflar o manguito é um evento “ativo” que comprime a artéria, gera desconforto físico e, frequentemente, desperta o paciente durante o sono, alterando justamente os parâmetros hemodinâmicos que se busca medir. Além disso, a natureza episódica dessas medições deixa lacunas temporais nas quais picos hipertensivos transientes – muitas vezes gatilhos para eventos cardiovasculares – podem passar despercebidos [6].

Nesse contexto, a nova Diretriz Brasileira de Hipertensão Arterial (2025) introduz mudanças paradigmáticas. O documento não apenas introduz a classificação de “pré-hipertensão arterial” (PHA) para valores de pressão arterial sistólica (PAS) entre 120 e 139 mmHg e de pressão arterial diastólica (PAD) entre 80 e 89 mmHg, mas também enfatiza fortemente a necessidade de monitoramento fora do consultório [7]. Essa diretriz cria uma demanda urgente por tecnologias de monitoramento residencial mais simples, contínuas e confortáveis do que os métodos atuais.

É neste cenário que a fonocardiografia (FCG) digital surge como uma alternativa promissora. Por utilizar um sensor puramente passivo, essa tecnologia é ideal para a viabilização de dispositivos vestíveis (*wearables*), permitindo o acompanhamento cardiovascular contínuo sem interferir na rotina ou no sono do paciente [8].

A premissa para o uso clínico dessa tecnologia reside na relação mecânica intrínseca entre os sons e a pressão. O ciclo cardíaco produz os sons fundamentais conhecidos como S1 e S2 [9, 10], e a literatura sugere que a intensidade e o espectro acústico desses sons refletem diretamente as alterações na resistência vascular periférica típicas da pré-hipertensão [11, 12].

O grande volume de dados produzidos pelo monitoramento contínuo e registro de sinais vitais com FCG representa uma oportunidade promissora para o desenvolvimento de técnicas de aprendizado de máquina voltadas à predição e ao diagnóstico da HA, uma

vez que as alterações provocadas pela condição nos sons cardíacos podem ser utilizadas como treinamento de modelos capazes de detectar precocemente a doença [13, 14].

A presente proposta investiga a viabilidade técnica de utilizar o sinal de fonocardiograma (FCG) como biomarcador para a detecção de alterações na pressão arterial. Utilizando uma base de dados publicada em 2025 como “prova de conceito” fisiológica, o estudo emprega técnicas de extração massiva de características e de aprendizado de máquina sobre os registros acústicos. Adotou-se uma abordagem de classificação binária, agrupando indivíduos pré-hipertensos e hipertensos em uma única classe-alvo (estado de alerta) confrontada com a classe de normotensos. O objetivo central é verificar se o sinal de FCG contém padrões discriminativos suficientes para identificar, de forma global, o risco cardiovascular, o que fundamenta o desenvolvimento de futuros dispositivos de monitoramento passivo, não invasivo e verdadeiramente contínuos.

2 TRABALHOS RELACIONADOS

Nos últimos anos, diversos estudos têm investigado a correlação entre sinais fonocardiográficos (PCG) e a pressão arterial, buscando alternativas menos invasivas para estimá-la de forma contínua ou pontual. Os resultados recentes demonstram que as informações acústicas do ciclo cardíaco contém padrões fisiológicos importantes associados à pressão arterial, que são predominantemente explorados em tarefas de regressão para estimar valores absolutos.

Nesse contexto, trabalhos como o de [15] empregaram modelos baseados em Máquinas de Vetores de Suporte (SVM) utilizando apenas o sinal de PCG para estimar os valores da pressão arterial sistólica (PAS) e diastólica (PAD). Avançando na extração de características, [16] combinaram sinais de PCG com dados demográficos por meio de modelos de *Deep Learning* (CNN com blocos SE) para estimar PAS e PAD. Em outra vertente, [17] propuseram a regressão focada na PAS, empregando o algoritmo *Random Forest* sobre uma combinação multimodal de sinais de PCG e de balistocardiograma (BCG).

Diferentemente dessas abordagens voltadas à regressão de valores contínuos, o presente estudo propõe uma estratégia de classificação binária, comparando o desempenho de diferentes modelos de aprendizado de máquina em dados de PCG e demográficos. O foco principal não é a predição exata da pressão, mas sim a triagem direta de indivíduos em risco (pré-hipertensão e hipertensão) com base no sinal de áudio, estabelecendo uma prova de conceito para a detecção de grupos de alerta.

3 METODOLOGIA

Esta seção apresenta a metodologia adotada para o desenvolvimento deste trabalho. A Figura 1 ilustra, por meio de um diagrama de blocos, o fluxo geral do processo metodológico, descrevendo desde a aquisição e pré-processamento dos dados até a avaliação dos resultados.

3.1 Base de Dados e Pré-processamento

Utilizou-se a base pública *Phonocardiogram Signal Dataset Paired with Blood Pressure Measurements* [18], contendo registros de 78 participantes (40 em alerta para pré-hipertensão e 38 normotensos). Os áudios, coletados com estetoscópio digital (2000 Hz), foram filtrados




Figura 1: Diagrama de blocos da metodologia proposta.

na faixa de 60–500 Hz para isolar os componentes principais dos sons cardíacos (S1 e S2) e mitigar ruídos de baixa e alta frequência.

3.2 Extração e Seleção de Características

Adotou-se uma abordagem de extração massiva de características utilizando a biblioteca TSFRESH [19]. A partir do sinal de áudio, extraíram-se 778 descritores (estatísticas descritivas, entropia, coeficientes espectrais e *wavelets*) por paciente, aos quais se somaram dados demográficos (idade, peso, altura e gênero). Para evitar sobreajuste, aplicou-se o algoritmo *Correlation-based Feature Selection* (CFS) [20], que reduziu o espaço para os 18 atributos de maior correlação com a classe-alvo e menor redundância entre si.

3.3 Treinamento e Avaliação

O problema foi modelado como classificação binária, avaliando-se os algoritmos supervisionados: Regressão Logística (LR), *Random Forest* (RF), SVM (kernels RBF e Polinomial), XGBoost, KNN e *Multilayer Perceptron* (MLP) [21]. A validação adotou a divisão 75/25 (treino/teste) com 100 repetições aleatórias, garantindo robustez na extração das métricas (Acurácia, F1-Score, Precisão, Recall e AUC).

4 RESULTADOS PRELIMINARES

A análise experimental buscou quantificar a capacidade dos modelos de aprendizado de máquina de identificar padrões associados à hipertensão diretamente a partir dos sinais de fonocardiograma. O desempenho consolidado dos diferentes classificadores avaliados é apresentado na Tabela 1.

O modelo de Regressão Logística apresentou o desempenho mais equilibrado, alcançando uma acurácia média de 62,54% e um F1-Score de 62,01%. A AUC (*Area Under the Curve*) de 0,62 indica que o modelo possui capacidade discriminativa superior à aleatoriedade (0,50), o que valida a hipótese de que o sinal de áudio contém informações relevantes sobre o estado pressórico.

Tabela 1: Métricas de desempenho (Sinal Completo).

Modelo	Acc (%)	F1 (%)	Prec (%)	Rec (%)	AUC
LogisticRegression	62.54	62.01	62.90	61.14	0.62
MLP	59.37	59.07	59.51	58.64	0.59
RandomForest	59.12	58.79	59.26	58.33	0.59
SVM (RBF)	58.80	58.59	58.90	58.28	0.58
XGBoost	53.75	53.45	53.80	53.11	0.53
SVM (POLI)	52.55	51.39	52.68	50.16	0.52
KNN	51.62	51.95	51.60	52.30	0.51

A Figura 2 apresenta a matriz de confusão do classificador de Regressão Logística. Observa-se um equilíbrio razoável entre falsos positivos e falsos negativos, o que é desejável em uma primeira etapa de triagem, a fim de evitar alarmismo excessivo ou negligência de casos de risco.

Valores Reais	Negativo	Verdadeiro Negativo 63,90%	Falso Positivo 36,10%
	Positivo	Falso Negativo 22,40%	Verdadeiro Positivo 77,60%
		Negativo	Positivo
		Valores Previstos	

Figura 2: Matriz de confusão (Regressão Logística).

Embora métricas na faixa de 60-65% não sejam suficientes para diagnóstico clínico definitivo, elas demonstram viabilidade técnica. O fato de um modelo linear simples (Regressão Logística) superar modelos mais complexos como XGBoost sugere que, com o conjunto atual de características extraídas do sinal bruto, a relação sinal-ruído é baixa e modelos complexos tendem ao sobreajuste. Isso indica que as alterações acústicas causadas pela hipertensão estão presentes, porém sutis e podem ser mascaradas por componentes do sinal não relacionados à hemodinâmica.

5 CONSIDERAÇÕES FINAIS

Este estudo preliminar avaliou a viabilidade da detecção de pré-hipertensão e hipertensão arterial por meio de sinais de fonocardiografia combinados com técnicas de aprendizado de máquina. Os resultados indicam que é possível extrair informações relevantes dos sinais de PCG para distinguir indivíduos normotensos de hipertensos, alcançando desempenho superior ao acaso (AUC de 0,62), mesmo com o uso de características globais do sinal.

A análise evidencia o potencial da fonocardiografia como técnica passiva, não invasiva e de baixo custo, adequada para aplicações em sistemas de monitoramento contínuo. Entretanto, o desempenho moderado obtido a partir do processamento do sinal completo sugere que parte das informações fisiologicamente relevantes pode não estar sendo explorada de forma ideal. Considerando que eventos-chave do ciclo cardíaco, como os sons S1 e S2 associados ao fechamento valvar, ocupam intervalos temporais específicos e relativamente curtos, a análise global do áudio tende a diluir padrões acústicos associados às alterações hemodinâmicas da hipertensão.

Dessa forma, o presente trabalho estabelece uma base metodológica para investigações subsequentes. Como continuidade, pretende-se explorar técnicas mais avançadas de pré-processamento e segmentação dos sinais de PCG, com ênfase no isolamento dos sons cardíacos fundamentais e na extração de características temporais e espectrais específicas do ciclo cardíaco. Espera-se que tais abordagens contribuam para o aprimoramento do desempenho preditivo dos modelos, aproximando a proposta de aplicações clínicas mais robustas.

REFERÊNCIAS

- [1] GAO, G. et al. Impact of hypertensive heart disease, risk factors, and age-period-cohort models across 204 nations and regions from 1990 to 2019: a global perspective from the 2019 global burden of disease study. *Frontiers in Cardiovascular Medicine*, Volume 11 - 2024, 2024. ISSN 2297-055X. Disponível em: <<https://www.frontiersin.org/journals/cardiovascular-medicine/articles/10.3389/fcvm.2024.1417523>>.
- [2] ORGANIZATION, W. H. *Cardiovascular diseases (CVDs)*. <https://www.who.int/health-topics/cardiovascular-diseases>. Acesso em: 18/11/2025.
- [3] ORGANIZATION, W. H. *Hypertension*. <https://www.who.int/news-room/fact-sheets/detail/hypertension>. Acesso em: 18/11/2025.
- [4] SLAMA, M.; SUSIC, D.; FROHLICH, E. D. Prevention of hypertension. *Current Opinion in Cardiology*, v. 17, n. 5, p. 531-536, set. 2002.
- [5] BARROSO, W. K. S.; AL. et. *Diretrizes Brasileiras de Hipertensão Arterial - 2020*. Sociedade Brasileira de Cardiologia. Acesso ao Capítulo 3.
- [6] PIOLI, M. R. et al. White coat syndrome and its variations: differences and clinical impact. *Integrative Blood Pressure Control*, Dove Medical Press, v. 11, p. 73-79, 2018.
- [7] BRANDÃO, A. A.; AL. et. *Diretriz Brasileira de Hipertensão Arterial - 2025*. 2025. Brazilian Guidelines of Hypertension - 2025.
- [8] KARIO, K. et al. The promise and illusion of continuous, cuffless blood pressure monitoring. *Current Hypertension Reports*, Springer, v. 25, p. 363-370, 2023.
- [9] BRAGGION-SANTOS, M. F. et al. *Physiology, Heart Sounds*. Treasure Island (FL): StatPearls Publishing, 2023.
- [10] WALKER, H. K.; HALL, W. D.; HURST, J. W. (Ed.). *Clinical Methods: The History, Physical, and Laboratory Examinations*. 3. ed. Boston: Butterworths, 1990. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK341/>. ISBN 0-409-90077-X.
- [11] ZHANG, D. et al. Relations between the timing of the second heart sound and aortic blood pressure. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 55, n. 4, p. 1291-1297, 2008.
- [12] CASTRO, A.; MATTOS, S. S.; COIMBRA, M. T. Noninvasive blood pressure and the second heart sound analysis. In: *36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.]: IEEE, 2014. p. 5494-5497.
- [13] EL-HAJJ, C.; KYRIACOU, P. A. Cuffless blood pressure estimation from phonocardiogram signals using deep learning techniques. *Biomedical Signal Processing and Control*, Elsevier, v. 65, p. 102381, 2021.
- [14] CHEN, W. et al. Deep learning for heart sound analysis: A literature review. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 11, n. 5, p. e1419, 2021.
- [15] PENG, Y.-H.; KUO, P.-C.; ZHANG, Y.-T. Cuffless and continuous blood pressure estimation from the heart sound signals. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, p. 6058-6061, 2015.
- [16] JUMPHOO, T.; CHOKSATCHAWAN, S.; PUMRIN, S. Deep learning-based blood pressure estimation using phonocardiogram features and demographic data. *Symmetry*, v. 17, n. 1943, 2025.
- [17] GONZALEZ-LANDAETA, R.; RAMIREZ, B.; MEJIA, J. Estimation of systolic blood pressure by random forest using heart sounds and a ballistocardiogram. *Scientific Reports*, Nature Publishing Group, v. 12, n. 17196, 2022.
- [18] KOKKHUNTHOD, K. et al. *Phonocardiogram Signal Dataset Paired with Blood Pressure Measurements*. [S.l.]: Data in Brief, 2025.
- [19] CHRIST, M. et al. Time series feature extraction on basis of scalable hypothesis tests (tsfresh - a python package). *Neurocomputing*, Elsevier, v. 307, p. 72-77, 2018.
- [20] HALL, M. Correlation-based feature selection for discrete and numeric class machine learning. In: . [S.l.: s.n.], 2000. p. 359-366.
- [21] AMEEN, A. et al. Advances in ecg and pcg-based cardiovascular disease classification: a review of deep learning and machine learning methods. *Journal of Big Data*, Springer, v. 11, n. 1, p. 159, 2024.