

INTELIGÊNCIA ARTIFICIAL APLICADA AO PROCESSAMENTO DE SINAIS CARDÍACOS

Sarah R. R. Pereira¹ (IC), João Paulo R. R. Leite (PQ)¹

¹Universidade Federal de Itajubá (UNIFEI).

Resumo: A presente pesquisa propõe um algoritmo, baseado em técnicas de *machine learning*, para estimação da pressão arterial através de sinais de fotopleletismografia. Este método possui vantagens com relação ao método tradicional, em que a pressão sanguínea é obtida através do esfigmomanômetro, uma vez que pode ser utilizado para medição contínua quando embutido em um dispositivo *wearable* e não causa desconforto ao paciente. Os dados para treinamento foram retirados da base de dados da Universidade da Califórnia Irvine, baseados na tradicional base de dados MIMIC. No total foram analisados mais de 18000 batimentos cardíacos de 85 pacientes, obtendo um resultado comparável a outros trabalhos do estado da arte e que satisfaz os padrões internacionais de precisão de instrumentação propostos pela AAMI (Associação Americana para o Avanço da Instrumentação Médica).

Palavras-chave: Fotopleletismografia. Machine Learning. Pressão Arterial.

Introdução

A pressão arterial (PA) é a força exercida pelo sangue contra a parede das artérias. Há dois tipos de PA, a sistólica (PAS), pressão máxima observada nas artérias durante a fase sistólica do ciclo cardíaco (contração do músculo cardíaco), e a diastólica (PAD), pressão mínima detectada na aorta e seus ramos durante a fase diastólica (relaxamento do músculo cardíaco) [1].

A aferição da PA é muito importante, pois é responsável pela detecção de diversas condições, como a hipertensão, a hipertensão mascarada e a de avental branco. Tais condições e suas consequências, como o acidente vascular cerebral (AVC) e a insuficiência cardíaca, são responsáveis por cerca de 15% das internações da população adulta no Brasil [2] e podem levar, em muitos casos, à morte.

Contudo, o método atual de aferição, por esfigmomanômetro, é desconfortável para o paciente, já que ao comprimir o braço, o manguito pode incomodar ou machucar. Ademais, em situações de monitorização contínua, o equipamento pode impedir ou dificultar a realização de atividades do dia a dia por parte do paciente, como tomar banho, praticar atividades físicas ou desfrutar uma noite de sono.

Estudos anteriores [3-4] demonstraram que é possível estimar a pressão arterial através de um único sinal de fotopleletismografia (PPG), comuns em dispositivos *wearables* como *smartwatches*, através de técnicas de Inteligência Artificial (IA). Portanto, a ideia central do presente projeto é propor um algoritmo, baseado em métodos de ciência de dados e *machine learning*, que seja capaz de estimar a pressão arterial de um paciente através do monitoramento do sinal de fotopleletismografia.

Na pesquisa será usada a técnica de Perceptron de múltiplas camadas (MLP) sob os sinais de PPG da

base de dados da Universidade da Califórnia Irvine (UCI).

Metodologia

A base de dados escolhida para a pesquisa foi a da *University of California Irvine* (UCI). É uma base de dados gratuita criada pelos pesquisadores M. Kahueê, M. Mahdi Kiani, H. Mohammadzade, M. Shabany [5], a qual consiste nos sinais limpos e pré-processados da base do MIMIC. É constituída por 3 sinais, sendo eles:

- PPG: sinal de fotopleletismografia do dedo, frequência de 125Hz;
- ABP: sinal de pressão sanguínea ambulatorial (mmHg), frequência de 125Hz;
- ECG: sinal do eletrocardiograma do canal II, frequência de 125Hz.

Foram utilizados somente os sinais de PPG para a extração dos parâmetros de entrada, e seu correspondente valor de ABP, para a as saídas (PAS PAD) de pacientes cujo as gravações eram superiores a 5 minutos, de maneira a aproveitar apenas a captura de sinais estáveis. Para segmentar o sinal e obter uma grande quantidade de padrões de entrada, necessários para o treinamento do modelo, foi feito o “janelamento” dos sinais. O sinal, para cada paciente, foi dividido em segmentos de 6s, com passos de 2s, gerando sobreposição de 4s entre os segmentos adjacentes.

Para cada segmento obtido no processo de janelamento, foram calculados os seguintes parâmetros. extraídos de acordo com a Figura 1, escolhidos como

entrada para o modelo [2]:

- CP, SUT, DT;
- DW10, SW10+DW10;
- DW25, SW25+DW25;
- DW33, SW33+DW33;
- DW50, SW50+DW50;
- DW66, SW66+DW66;
- DW75, SW75+DW75.

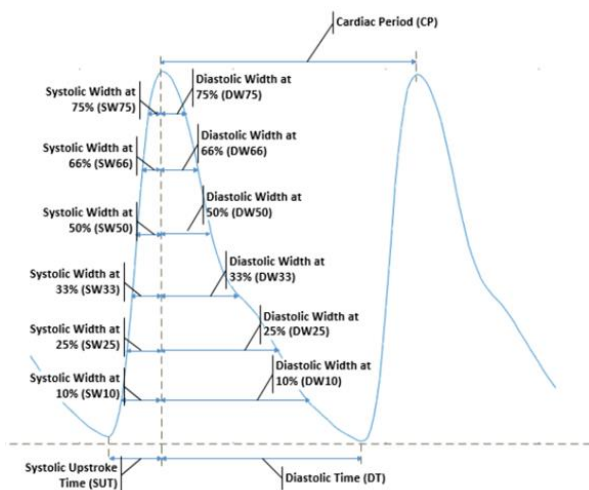


Figura 1- Sinal de PPG com os parâmetros usados nas pesquisas

As saídas, PAS e PAD, foram calculadas sendo os valores de máximo e mínimo, respectivamente, do sinal ABP. Foram extraídos os dados de 85 pacientes, totalizando mais de 18000 batimentos cardíacos.

A arquitetura da rede neural proposta para o treinamento dos dados, foi um Perceptron de Múltiplas Camadas (*MLPRegressor*) com propagação adiante (*feedforward*), ou seja, alimentada adiante de camada em camada. O número de camadas escondidas e neurônios que apresentaram melhor desempenho foi de 6 camadas, com 95-80-65-50-35-20 neurônios.

A fim de melhorar os resultados obtidos, os parâmetros foram normalizados. Além disso, acrescentou-se aos valores de entrada os parâmetros de Hjorth [6], além daqueles descritos anteriormente. São três novos parâmetros: Atividade, Mobilidade e Complexidade.

De acordo com a “*US Association for the Advancement of Medical Instrumentation*” (*AAMI*) o erro e o desvio padrão das previsões feitas devem estar abaixo de 5 mmHg, para a PAD (pressão diastólica), e 8 mmHg, para o PAS (pressão sistólica), em um estudo feito em, no mínimo, 85 pacientes. Se este resultado for obtido, a pesquisa é considerada aceitável para a implementação em dispositivos reais [7].

Resultados e discussão

A Tabela 1 faz uma comparação dos resultados obtidos neste trabalho (Modelo Proposto) com os dos trabalhos de outros autores ([2] e [3]). Pela comparação, nota-se que o resultado obtido na pesquisa é muito próximo aos de trabalhos já conceituados e publicados em veículos científicos internacionais, sendo o melhor entre os três.

Trabalho	Método	PAS	PAD
[2]	MLPRegressor (2 camadas)	3.80 ± 3.46	2.21 ± 2.09
[3]	SVM	11.64 ± 8.20	7.62 ± 6.78
Modelo Proposto	MLPRegressor (6 camadas)	3.53 ± 4.33	2.15 ± 2.34

Tabela 1 - Comparação entre os resultados obtidos na pesquisa com trabalhos anteriores.

Houve uma melhora significativa em relação ao modelo de SVM proposto por Y. Zhang et al [3], o qual usa menos parâmetros de entrada. Em relação ao trabalho de Y. Kurylyak et al [2], o modelo proposto nesta pesquisa apresenta um erro percentual médio ligeiramente inferior. Não houve uma grande melhora com relação a este último, mas foi possível alcançar desempenho muito semelhante, mostrando que o algoritmo é satisfatório e comparável ao estado da arte.

Além disso, a pesquisa satisfaz a condição da AMMI, o que a torna viável para a implementação em dispositivos reais.

Conclusões

O objetivo deste trabalho foi apresentar um novo método não invasivo de estimação da pressão arterial, a partir de técnicas de ciência de dados e *machine learning* aplicadas a sinais de PPG, visando maior conforto aos pacientes e uma maneira simples de monitoramento contínuo do sinal vital. A partir dos resultados obtidos, conclui-se que o trabalho atingiu o objetivo desejado, visto que os valores de erro absoluto médio de 3.53 ± 4.33 para a pressão sistólica e 2.15 ± 2.34 para a pressão diastólica, estão dentro do limite determinado pela AAMI, sendo assim considerada uma pesquisa viável para a aplicação em instrumentos de aferição.

Além disso, o resultado da pesquisa se mostrou pareado aos de estudos recentes já conceituados, havendo uma melhora nos resultados em relação aos dois trabalhos bases [2] e [3], ainda que sutil em relação ao primeiro. Portanto, demonstra que os objetivos acadêmicos, de estudo, pelo aluno, das técnicas de aprendizado de máquinas, codificação e análise de dados, também foram atingidos.

Agradecimento

Ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), pela bolsa de estudos e auxílio financeiro que possibilitou a dedicação integral ao programa de iniciação científica.

Ao meu orientador, o professor Dr. João Paulo R. Leite, por proporcionar a oportunidade da Iniciação Científica e pelas lições nesse ano de convívio.

Referências

- [1] Sociedade Brasileira de Cardiologia, [Online]. Disponível em: <http://departamentos.cardiol.br/dha/consenso3/capitulo1.asp>
- [2] IBGE, [Online]. Disponível em: <https://sidra.ibge.gov.br/tabela/7826#resultado>
- [3] KURYLYAK, Yuriy; LAMONACA, Francesco; GRIMALDI, Domenico. A Neural Network-based method for continuous blood pressure estimation from a PPG signal. In: **2013 IEEE International instrumentation and measurement technology conference (I2MTC)**. IEEE, 2013. p. 280-283.
- [4] ZHANG, Yue; FENG, Zhimeng. A SVM method for continuous blood pressure estimation from a PPG signal. In: **Proceedings of the 9th international conference on machine learning and computing**. 2017. p. 128-132.

[5] KACHUEE, Mohamad et al. Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time. In: **2015 IEEE international symposium on circuits and systems (ISCAS)**. IEEE, 2015. p. 1006-1009.

[6] LEITE, João Paulo RR; MORENO, Robson L. Heartbeat classification with low computational cost using Hjorth parameters. **IET Signal Processing**, v. 12, n. 4, p. 431-438, 2018

[7] CHOWDHURY, Moajjem Hossain et al. Estimating blood pressure from the photoplethysmogram signal and demographic features using machine learning techniques. **Sensors**, v. 20, n. 11, p. 3127, 2020.